



T.C.

TOKAT GAZİOSMANPAŞA ÜNİVERSİTESİ

LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

DOKTORA PROGRAMI

**RÜZGAR HIZI TAHMİNLEMESİ İÇİN DERİN ÖĞRENME VE
AYRIKLAŞTIRMA TEMELLİ UYARLANABİLİR HİBRİT TAHMİN
MODELİ GELİŞTİRİLMESİ**

DOKTORA TEZİ

MUSTAFA TAN

Danışman: Doç. Dr. Cem EMEKSİZ

TOKAT- 2024

ETİK SÖZLEŞME

Tokat Gaziosmanpaşa Üniversitesi Lisansüstü Eğitim Enstitüsü tez yazım kılavuzuna göre, Doç. Dr. Cem EMEKSİZ danışmanlığında hazırlamış olduğum “Rüzgar Hızı Tahminlemesi İçin Derin Öğrenme Ve Ayrıklaştırma Temelli Uyarlanabilir Hibrit Tahmin Modeli Geliştirilmesi” adlı Doktora tezinin bilimsel etik değerlere ve kurallara uygun, özgün bir çalışma olduğunu, aksinin tespit edilmesi halinde her türlü yasal yaptırımını kabul edeceğimi beyan ederim.

.../.../2024

Mustafa TAN



JÜRİ KABUL VE ONAY

Mustafa TAN tarafından hazırlanan “Rüzgar Hızı Tahminlemesi İçin Derin Öğrenme Ve Ayrıklaştırma Temelli Uyarlanabilir Hibrit Tahmin Modeli Geliştirilmesi” adlı tez çalışmasının savunma sınavı 11.11.2024 tarihinde yapılmış olup aşağıda verilen Jüri tarafından Oy Birliği ile Tokat Gaziosmanpaşa Üniversitesi Lisansüstü Eğitim Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim Dalı’nda Doktora Tezi olarak kabul edilmiştir.

Jüri Üyeleri (Unvanı, Adı Soyadı)

İmzası

ONAY

...../...../.....

Lisansüstü Eğitim Enstitüsü Müdürü

ÖNSÖZ

Tezimin hazırlanmasında çalışmamın her aşamasında yanımda olan değerli hocalarım, ailem ve arkadaşlarıma kucak dolusu sevgimi, muhabbetimi ve şükranlarımı sunarım.

MUSTAFA TAN

11 Kasım 2024



ÖZET

RÜZGAR HIZI TAHMİNLEMESİ İÇİN DERİN ÖĞRENME VE AYRIKLAŞTIRMA TEMELLİ UYARLANABİLİR HİBRİT TAHMİN MODELİ GELİŞTİRİLMESİ

Tan, Mustafa

Doktora, Elektrik – Elektronik Mühendisliği Ana Bilim Dalı

Tez Danışmanı: Doç. Dr. Cem Emeksiz

Kasım 2024, xi + 97 sayfa

Rüzgar hızının doğru ve güvenilir tahminlenmesi rüzgar enerjisi güç sistemlerinin yönetilmesi ve işletilmesinde kilit rol oynamaktadır. Bu nedenle bu çalışmada rüzgar hızı tahminlenmesinde kullanılmak üzere derin öğrenmeye dayalı yenilikçi adaptif bir tahminleme modeli (NAEM) geliştirilmiştir. Geliştirilen bu model uyarlanabilir gürültü ile geliştirilmiş tam topluluk ampirik mod ayrıştırması (ICEEMDAN), sürekli dalgacık dönüşümü (CWT), kontrast sınırlı uyarlanabilir histogram eşitleme (CLAHE), parçacık sürüsü optimizasyonu (PSO) ve evrişimli sinir ağı (CNN)'dan oluşmaktadır. Kullanılan modelin veri ön işleme aşamasında klasik veri matris dönüşümü yöntemine ayırıştırma tekniği kullanılarak alternatif bir yaklaşım sunulmuştur. Model 3 farklı vaka çalışmasında test edilmiş ve elde edilen performans metrikleri (RMSE, MAPE ve R2) incelendiğinde özellikle diğer kıyaslama modellerine (CNN-RNN, GRU, LSTM) göre daha doğru ve güvenilir sonuçlar sergilemiştir. Elde edilen sonuçlar sunulan modelin özellikle rüzgar hızı tahminlemesinde iyi bir alternatif olacağını göstermektedir.

Anahtar Kelimeler: Yenilenebilir Enerji, Rüzgar Hızı Tahmini, Ayrıştırma Teknikleri

ABSTRACT

DEVELOPMENT OF A DEEP LEARNING AND DISCRETIZATION BASED ADAPTIVE HYBRID FORECAST MODEL FOR WIND SPEED FORECASTING

Tan, Mustafa

Doctoral Thesis, Department Of Electrical And Electronics Engineering

Advisor: Assoc.Prof.Dr. Cem Emeksiz

November 2024, xi + 97 pages

Estimating the wind speed correctly and reliably plays a key role in managing and operating wind energy power systems. Therefore an novelty adaptive estimation model (NAEM) combined with deep learning-based mode discretization has been developed for use in wind speed estimation in this study. This developed model consists of the improved complete ensemble empirical mode decomposition with adaptive noise (ICEEMDAN), the continuous wavelet transforms (CWT), the contrast limited adaptive histogram equalization (CLAHE), the particle swarm optimization (PSO), and convolutional neural network (CNN). Adaptive estimation model using decomposition method was presented as an alternative to the traditional data matrix transformation used in data preprocessing stage. Thus, the usage of this model for the first time in the data preprocessing stage and the creation of a hybrid structure by combining the methods included in this method for the first time constitute the most important innovative aspect of the study. Proposed model (NAEM) was tested in different case studies and RMSE, MAPE, and R2 were used as performance metrics. In the comparison with commonly used deep learning models (CNN-RNN, GRU, LSTM) the root means square error (RMSE) values decrease by 25.80%, 61.17% and 63.60% respectively. In addition, the power density value of the actual wind speeds was approached by 95.1% with the proposed NAEM.

Keywords: Renewable Energy, Wind Speed Estimation, Decomposition Techniques

İÇİNDEKİLER

Sayfa

ETİK SÖZLEŞME SAYFASI	i
JÜRİ KABUL VE ONAY.....	ii
ÖNSÖZ	iiHata! Yer işareti tanımlanmamış.
ÖZET	Hata! Yer işareti tanımlanmamış.v
ABSTRACT.....	v
İÇİNDEKİLER.....	vi
ÇİZELGE LİSTESİ.....	xi
ŞEKİL LİSTESİ.....	ix
SİMGELER VE KISALTMALAR	xi
1. GİRİŞ	1
2. LİTERATÜR TARAMASI	5
3. RÜZGAR ENERJİSİ	1010
3.1 Rüzgar Enerjisi Potansiyeli, Avantajı ve Dezavantajı.....	10
3.2 Rüzgar Gücü ve Hızı İçin Tahminleme Metodları.....	20
3.2.1 Naive ve Fiziksel Tahminleme Yöntemleri	33
3.2.2 İstatistiksel Yaklaşım Metodları.....	35
3.2.3 Ayrıştırma Tabanlı Metodlar ı	38
3.2.4 Hibrit Modeller.....	42
3.3 Dünya’da ve Türkiye’de Rüzgar Enerjisi isi	47
4. MATERYAL VE YÖNTEM.....	54
4.1 Veri Çıkarma Bölümü	55
4.2 Veri Önileme Bölümü.....	57
4.2.1 Uyarlanabilir Gürültüyle Tamamlanan Topluluk Ampirik Mod Ayrıştırma (ICEEMDAN)	57
4.2.2 Sürekli dalgacık dönüşümü (CWT).....	58
4.2.3 Kontrast sınırlı uyarlanabilir histogram eşitleme (CLAHE).....	60
4.3 Tahminleme Bölümü.....	64
4.3.1 Evrişimsel sinir ağları (CNN).....	64
4.3.2 Parçacık sürü optimizasyonu (PSO).....	68

4.4	Çalışma Performansını Ölçme ve Değerlendirme.....	71
5.	ARAŞTIRMA BULGULARI VE TARTIŞMA.....	72
5.1	Vaka 1: NAEM kullanılarak haftalık ortalama rüzgar hızı tahmini	72
5.2	Vaka 2: Veri matrisi dönüşümü kullanılarak haftalık ortalama rüzgar hızı tahmini	80
5.3	Vaka 3: NAEM'in diğer derin öğrenme modelleriyle karşılaştırılması.....	82
6.	SONUÇLAR	85
7.	KAYNAKLAR	87
8.	EKLER.....	96
9.	ÖZGEÇMİŞ.....	97

ÇİZELGE LİSTESİ

<u>Çizelge</u>	<u>Sayfa</u>
Çizelge 3.1. Ampirik modların karşılaştırılması.....	41
Çizelge 4.1. Optimize edilen hiperparametreler.....	70
Çizelge 4.2. PSO parametreleri.....	71
Çizelge 4.3. Performans metrikleri.....	71
Çizelge 5.1. Haftalık rüzgar hızı serilerinin ortalama rüzgar hızı değerleri.....	75
Çizelge 5.2. NAEM ve Model 1'in performans metrikleri	79
Çizelge 5.3. NAEM ve Model 2'nin performans metrikleri.....	81
Çizelge 5.4. NAEM ve CNN-RNN, GRU ve LSTM'nin performans metrikleri.....	83
Çizelge 5.5. Güç yoğunluklarının karşılaştırılması.....	84

ŞEKİL LİSTESİ

<u>Şekil</u>	<u>Sayfa</u>
Şekil 3.1. Rüzgar enerjisinde kullanılan Betz teoremi	12
Şekil 3.2. Türkiye için oluşturulmuş rüzgar enerjisi potansiyel	19
Şekil 3.3. Yıllara göre küresel rüzgar enerji toplam kapasite kurulumları	48
Şekil 3.4. Rüzgar enerjisinin karada ve denizde kurulumlarının yıllara göre değişimi	50
Şekil 3.5.a) 2022 yılı Karasal kapasiteler	50
Şekil 3.5.b) 2022 yılı Deniz üstünde kapasiteler	50
Şekil 3.6. 2022 yılı kaynak bazlı elektrik üretimi	51
Şekil 3.7. 2022 yılı Ağustos ayı itibarıyla kurulu gücümüz	51
Şekil 4.1. Ölçüm direği ve güç kutusu	56
Şekil 4.2.a) Birinci sınıf rüzgar yönü vericisi	56
Şekil 4.2.b) Birinci sınıf gelişmiş çanak anemometre	56
Şekil 4.3. ICEEMDAN'nın uygulama aşamaları	58
Şekil 4.4. CLAHE algoritması	63
Şekil 4.5. CNN mimarisi	64
Şekil 4.6. CNN model parametreleri	66
Şekil 4.7. CNN yapısında yaygın olarak kullanılan aktivasyon fonksiyonları	67
Şekil 4.8. PSO Algoritması Akış Diyagramı	69
Şekil 5.1. 2017 Ocak ayının ilk haftasına ait rüzgar hızları	72
Şekil 5.2. 2018 Ocak ayının ilk haftasına ait rüzgar hızları	73
Şekil 5.3. 2019 Ocak ayının ilk haftasına ait rüzgar hızları	73
Şekil 5.4. 2020 Ocak ayının ilk haftasına ait rüzgar hızları	73
Şekil 5.5. Ocak aylarının ilk haftalarının ortalaması (2017-2020)	74
Şekil 5.6. Her bir haftaya ait ortalama rüzgar hızları	74
Şekil 5.7. CEEMDAN aracılığıyla ayrıştırılan haftalık ortalama rüzgar hız verilerinin IMF serisi	76
Şekil 5.8. Rastgele seçilen haftalara ait 3 boyutlu görüntü verileri	77
Şekil 5.9. ayının 1. haftasına ait artırılmış verilere ait görüntüler	78
Şekil 5.10. NAEM ve Model 1'e ait hata uzaklık değişimleri	79

Şekil 5.11. NAEM ve Model1 kullanılarak yapılan tahminleme sonuçlarının değişimi.....	80
Şekil 5.12. Sinyalin pencereleme yöntemi ile bölünmesi.....	80
Şekil 5.13. Rastgele seçilen haftalara ait data matris dönüşümü kullanılarak elde edilen 3 boyutlu görüntü verileri(.....	81
Şekil 5.14. NAEM ve Model 2'ye ait hata uzaklık değişimleri.....	82
Şekil 5.15. NAEM ve Model2 kullanılarak yapılan tahminleme sonuçlarının değişimi.....	82
Şekil 5.16. NAEM, CNN-RNN, GRU ve LSTM kullanılarak yapılan tahminleme sonuçlarının değişimi	83
Şekil 6.1. İncelenen tüm modellerin hata kaybı grafikleri.....	86

SİMGELER VE KISALTMALAR

Simgeler	Açıklama
a	İvme
A	Süpürme alanı
C_p	Türbin verimi
D	Fraktal katsayı
E_k	Kinetik enerji
G	Gradyan kuvveti
GW	Gigawatt
GWh	Gigawatt saat
H_{ref}	Ölçümün yapıldığı yükseklik
KW	Kilowatt
kWh	Kilowatt saat
m	Kütle
MW	Havanın moleküler ağırlığı
MW	Megawatt
MWe	Megawatt enerji
MWt	Megawatt ısı
P	Mutlak basınç
P_t	Rüzgarın türbin kanatlarına yapacağı basınç
R	İdeal gaz sabiti
R	Rüzgarın döner yarıçapı
T	Kelvin cinsinden mutlak sıcaklık
V	Hacim
V	Rüzgar hızı
λ	Kanat uç hız oranı
μ	Hellmann katsayısı
ω	Açısal dönme hızı
Ω	Dünyanın açısal dönüş hızı
ρ_h	Hava yoğunluğu

Kısaltmalar	Açıklama
ANFIS	Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi (Adaptive Network Based Fuzzy Inference Systems)
AR	Otoregresif
ARMA	Otoregresif hareketli ortalama
ARIMA	Otoregresif Entegre Hareketli Ortalama
BPNN	Geri yayımlı sinir ağı (Back Propagation Neurol Network)
CLSFP	Kaotik yerel arama ile çiçek tozlaşma algoritması (The flower pollination algorithm with chaotic local search)
CEEMDAN	Uyarlanabilir gürültülü bütünleşik ampirik mod ayrıştırma (Complete Ensemble Empirical Mode Decomposition Adaptive Noise)
CSO	Çapraz Optimizasyon (Crisscross Optimization)
CSA	Eşleşmiş simüle tavlama (Coupled Simulated Annealing)
COA	Çapraz optimizasyon algoritması (Cross Optimization Algorithm)
EWT	Ampirik dalgacık dönüşümü (Empirical Wavelet Transform)
ELM	Aşırı öğrenme makineleri (Extreme Learning Machines)
EMD	Ampirik mod ayrıştırma
EPDK	Enerji Piyasası Düzenleme Kurulu
ETKB	Enerji ve Tabii Kaynaklar Bakanlığı
EEMD	Topluluk ampirik mod ayrıştırma (Ensemble Empirical Mode Decomposition)
EPSO	Evrimsel parçacık sürü optimizasyonu (Evolutionary Particle Swarm)
FPA	Çiçek tozu algoritması (Flower-Pollination Algorithm)
GA	Genetik algoritma
GRNN	Genelleştirilmiş Regresyon Sinir Ağları (Generalized Regression Neural Network)
GWEC	Küresel Rüzgar Enerjisi Konseyi (Global Wind Energy Council)
HEA	Hibrit evrimsel uyarlama (Hybrid Evolutionary Adaptive)
IEA	Uluslararası Enerji Ajansı (International Energy Agency)
kNN	k-En Yakın Komşu (K Nearest Neighbor)
MGM	Meteoroloji Genel Müdürlüğü
MSE	Ortalama Karesel Hata (Mean Square Error)
MOSBO	Çok amaçlı saten çardak kuşu optimizasyon
MTEP	Milyon ton eşdeğer petrol

ARX	Doğrusal Olmayan Otoregresif Eksojen (Non-linear Auto-Regressive Exogenous)
OECD	Ekonomik Kalkınma ve İşbirliği Örgütü (Organisation for Economic Co-operation and Development)
RES	Rüzgar Enerji Santrelleri
RİTM	Rüzgar Gücü İzleme ve Tahmin Merkezi
RMSE	Ortalama Karesel Hatanın Karekökü (Root Mean Square Error)
SMO	Sıralı Minimal Optimizasyon (Sequential Minimal Optimisation)
YSA	Yapay Sinir Ağı
WNN	Dalgacık sinir ağı (Wavelet Neural Network)
LSSVM	En küçük kare destek vektör makinesi (Least Square Support Vector Machine)
SVR	Destek vektör regresyon
RBFNN	Radyal temel fonksiyon sinir ağı
NNCT	Olumsuz olmayan kısıtlama teorisi (no negative constraint theory)
KFCM	Çekirdek Bazlı Bulanık C-Aracı Kümeleme (Kernel-based fuzzy c-means clustering)
TÜREB	Türkiye Rüzgar Enerjisi Birliği
WPD	Dalgacık Paket Dönüşümü (Wavelet Packet Decomposition)
YEK	Yenilenebilir Enerji Kaynaklarının
TEİAŞ	Türkiye Elektrik iletim A.Ş.
SHT	Sayısal Hava Tahmini
QR	Kuantil regresyon modelini
GSA	Yerçekimi arama algoritması
SAM	Mevsimsel Ayarlama Yöntemi
ITD	İçsel Zaman Ölçeği Ayırıştırması
IMF	İçsel Salınım Fonksiyonlarına (Intrinsic Mode Function)
VMD	Varyasyonel Mod Ayırıştırma (Validation mode decomposition)
IA	Anlık genlik
IF	Anlık frekans
R ²	Determinasyon katsayısı (Determination Coefficient)
MAPE	Ortalama mutlak hata yüzdesi (Mean Absolute Percent Error)
RMSE	Ortalama Karesel Hatanın Karekökü (Root Mean Square Error)

1. GİRİŞ

Dünya üzerindeki enerji ihtiyacı, artan nüfus ve teknolojik gelişmelere bağlı olarak gün geçtikçe artmaktadır. Bu ihtiyacın karşılanması daha çok fosil yakıt rezervleri ile gerçekleştirilmektedir. Özellikle gelişmekte olan ülkeler çoğunlukla fosil yakıtlara bağımlıdırlar. Ancak bu yakıtların çevreye verdiği zararlar ve sahip olunan rezervlerin yakın gelecekte tükeneceği de bilinen ve kabul edilen bir gerçektir (Mostafaeipour ve ark., 2020). Fosil yakıtların kullanımından dolayı ortaya çıkan sera gazı emisyonlarındaki artış ve küresel ısınma, ozon tabakasındaki incelme, iklim değişiklikleri ve asit yağmurları gibi birçok çevresel tehditler insanların zarar görmesine sebep olmaktadır (Ozturk ve Dincer, 2021; Ozturk M, Dincer ve ark., 2021). Bu nedenle artan küresel enerji talebinin karşılanması için Dünya ülkeleri çevre dostu olan ve tükenmeyen yenilenebilir enerji kaynaklarının kullanılması yönünde çalışmalar başlatmışlardır. Böylece farklı yenilenebilir enerji kaynakları kullanılarak çevresel sorunların hafifletilmesi ve enerji verimliliğinin artırılması beklenmektedir. Güneş, rüzgar, biyokütle ve jeotermal gibi yenilenebilir enerji kaynaklarının bu amacın gerçekleştirilmesinde etkin rol oynaması beklenmektedir.

Hem çevre dostu hem de daha ucuz olmasından dolayı rüzgar enerjisi diğer yenilenebilir enerji kaynakları arasında daha umut verici bir seçenek olarak ön plana çıkmaktadır (Abdullah ve ark., 2012). Bu sayede rüzgar enerjisi dünyada en hızlı gelişen enerji kaynaklarından birisidir. Küresel rüzgar enerji konseyinin raporunda 2022 yılının rüzgar enerjisi endüstrisi için rekor kırılan bir yıl olduğu vurgulanmaktadır. Özellikle 2022 yılında kümülatif kurulu rüzgar gücü 93 GW artmıştır (Anonim, 2022b).

Rüzgar enerjisinden elektrik enerjisi üretimi ve sürdürülebilirliği son yıllarda aktif çalışma konusu olarak önem kazanmaktadır. Buna rağmen rüzgar enerjisi çevrim sistemlerinin en önemli girdisi olan rüzgarın kaotik davranış sergilemesi ve kesintili olması hem güç sistemin güvenilirliğini azaltmakta hem de üretim maliyetini artırmaktadır (He ve atk., 2020; Yang ve ark., 2018b). Ayrıca rüzgarda meydana gelen bu dalgalanmalar şebekedeki giriş çıkış gücünün dengelenmesini zorlaştırmaktadır. Dolayısıyla, rüzgar enerjisi üretim sistemleri için güvenilir ve doğru bir rüzgar hızı tahmini hayati önem taşımaktadır. Böylece hem güç sistemleri için istikrar sağlamış hem

de rüzgar enerjisi endüstrisi için yapılacak olan yatırımlar için duyulan kaygılar giderilmiş olur (Yang ve ark., 2017; Zafar ve ark., 2020). Ayrıca bu alanda yapılan çalışmalarda, rüzgar enerjisi tahminlerinin geliştirilmesi ile önemli ekonomik ve teknik avantajların sağlanabileceği bildirilmektedir (Qian ve ark., 2018; Liu ve ark., 2019). Bu nedenle son yıllarda birçok bilim insanı rüzgar hızı tahminlemesi alanında çeşitli tahmin modelleri geliştirdiler ve bu alanda derinlemesine çalışmalar yaptılar. Özellikle rüzgar hızı tahminlemesi için geliştirilen bu modeller temel olarak 4 ana grupta değerlendirilmektedir ((i) Fiziksel modeller, (ii) istatistiksel modeller, (iii) yapay zeka modeller ve (iv) hibrit modeller) (Aggarwal, 2013).

Fiziksel modeller sıcaklık, rüzgar yönü, rüzgar hızı vb. hava durumu verilerini kullanarak tahminlemelerin gerçekleştirildiği sayısal hava tahmin modelleridir (SHT) (Allen ve ark., 2017). Tahminleme sürecinde sınır koşulları ve fiziksel yasalar kullanılarak meteorolojik süreçler simüle edilir. Özellikle uzun dönem rüzgar hızı tahminlemesinde SHT modellerinin iyi performans sergilediği görülmektedir. Ancak bu modellerin kullanılmasında geniş ve çeşitli tarihsel verilere ihtiyaç duyulur (Giorgi ve ark., 2011; Tom ve Peter, 2010).

İstatistiksel modeller, özellikle zaman-uzay veya geçmiş verileri kullanarak tahmin yapmak istediğinizde fiziksel modellere göre daha fazla tercih edilen bir yaklaşım olabilirler. Bu tür istatistiksel modeller, belirli bir süre boyunca toplanan verilere dayanarak, veriler arasındaki matematiksel ilişkileri kullanarak tahminlerde bulunurlar. Örneğin, hava tahminleri için kullanılabilirler. Basınç, sıcaklık, rüzgar yönü, rüzgar hızı vb. verileri kullanarak geçmiş hava koşulları ile bu veriler arasındaki ilişkileri analiz edebilir ve gelecekteki hava koşullarını tahmin etmeye çalışabilirler. Bu tür tahminler, birçok uygulama için önemlidir, örneğin tarım, enerji üretimi ve hava taşımacılığı gibi alanlarda kullanılır. Böylece bu modeller kısa vadeli rüzgar hızı tahminlemelerinde başarılı sonuçlar elde ederler (Ouyang ve ark., 2017). Kalıcılık modeli (Persistence model, PM), otoregresif (autoregressive, AR) modeli, otoregresif hareketli ortalama (autoregressive moving average, ARMA) modeli ve otoregresif entegre hareketli ortalama (autoregressive integrated moving average, ARIMA) modelleri istatistiksel model olarak kullanılan en yaygın metodlardır (Wang ve Hu, 2015).

Günümüzde bilim insanları istatistiksel modellerin doğruluğunu artırmak için birçok çalışma gerçekleştirmektedirler. Bu çalışmalarda istatistiksel ve yapay zeka modellerini birleştirerek farklı yaklaşımlar sunmaktadırlar (Cadenas ve Rivera, 2010). Özellikle YSA birçok alanda yaygın olarak kullanılan ve içerisinde optimizasyon, tahmin, regresyon, kümeleme, otomatik kontrol vb. barından karmaşık makine öğrenme modelleridir (Guo ve ark., 2012; Salem ve ark., 2017; Moghaddamnia ve ark., 2009). YSA yaklaşık elli yıl önce geliştirilmiş bir yapıdır fakat bilim ve teknoloji alanında efektif olarak son yıllarda kullanılmaya başlanmıştır (Sözen ve ark., 2008). Bununla birlikte rüzgar hızı tahminlemede kullanılan YSA'lara geri beslemeli sinir ağ (backpropagation neural network, BPNN) (Yang ve Wang, 2018), genelleştirilmiş ileri beslemeli sinir ağ (generalized feed-forward neural network, GFNN) (Ramesh ve Jagan, 2015), dalgacık sinir ağ (wavelet neural network, WNN) (Moreno ve Dos Santos, 2018) ve genel regresyon sinir ağ (general regression neural network, GRNN) (Song ve ark., 2018) örnek verilebilir.

Rüzgarın sahip olduğu uzun vadeli bağımlılık gibi karmaşık özelliklerin tanımlanmasında bir takım sıkıntılar yaşanabilmektedir. Özellikle geleneksel sinir ağlar bu tanımlamayı yaparlarken yetersiz kalmaktadırlar. Bu nedenle son dönemde rüzgar hızı tahminlemede bazı derin öğrenme yöntemleri kullanılmaya başlanmıştır (Yang ve ark., 2021). Transfer öğrenme (Hu ve ark., 2016), sinir ağ yapısal öğrenme (neural network structural learning) (Mi ve Zhao, 2020), uzun kısa dönem bellek (long short-term memory, LSTM) (Li ve ark., 2018), tekrarlayan sinir ağ (recurrent neural network, RNN) (Cheng ve ark., 2018), evrimsel sinir ağ (convolutional neural network, CNN) (Zhao ve ark., 2020) gibi derin öğrenme yöntemlerine örnek olarak gösterilebilir.

Farklı konumlarda yer alan rüzgar hızlarında farklılıklar görülmektedir. Bunun nedeni durağan olmayan ve non-Gaussian gibi özelliklerdir. Bu durum rüzgar hızı tahminlemede tek bir modelin her zaman iyi performans sergileyemeyeceğini gösterir (Guo ve ark., 2011). Bu nedenle birçok araştırmacı ön işleme yöntemleri, yapay zeka modelleri ve çeşitli istatistiksel modellerin bir arada kullanıldığı hibrit modellere odaklanmışlardır. Birden çok tekli modellerin biraraya gelmesi ile oluşturulan hibrit modeller tahmin performansını artırmakta ve daha doğru sonuçlar sergilemektedir (Wang ve Li, 2019; Chandra ve ark., 2013). Hibrit modeller genel olarak 2 temel yaklaşımda

gruplandırılırlar. Bunlardan birincisi modellerde kullanılacak algoritmaları optimize etmektir. Diğerleri ise modelin tahmin performansını etkili bir şekilde artırmaya yarayan zaman serisinin ayrıklaştırılmasıdır (Zhuoyi ve ark., 2021; Zhang ve ark., 2016). En yaygın olarak tanınan ayrıklaştırma algoritmaları ampirik mod ayrıklaştırma (empirical mode decomposition, EMD), hızlı entegre EMD (fast integrated EMD, FEEMD), entegre EMD (EEMD), dalgacık paket ayrıklaştırma (wavelet packet decomposition, WPD) ve dalgacık ayrıklaştırma (wavelet decomposition, WD) şeklindedir (Zhang ve ark., 2017; Liu ve ark., 2015).

Tezin içeriği incelendiğinde 6 temel bölümden meydana geldiği görülmektedir. Birinci bölüm içerisinde giriş kısmı bulunmaktadır. İkinci bölümde literatür taraması yer almaktadır. Üçüncü bölümü rüzgar enerjisi konularında bilgileri içermekte olup ayrıca Dünya ve Türkiye'deki rüzgar enerjisi hakkında bilgiler verilmiştir. Dördüncü bölümde de çalışmaya ilişkin materyal ve metot hakkında bilgiler oluşturmaktadır. Beşinci bölümü çalışma sonuçlarından türetilen bulgular sunulmuştur. Altıncı bölümde ise tüm çalışmanın çıktılarına ilişkin sonuçlar yorumlanarak değerlendirilmiştir.

2. LİTERATÜR TARAMASI

Cadenas ve Rivera (2007), yapay sinir ağları (YSA) ve ARIMA metodlarını karşılaştırmışlardır. Çalışmalarında La Venta, Oaxaca, Mexico'daki 7 yıllık rüzgar hızı verilerini kullanmışlardır.

Kavaseri ve Seetharaman (2009), kesirli bir f-ARIMA modeli üzerinde çalışmışlardır. Bu model ile rüzgar güç üretimini ve rüzgar hızını 24h ve 48h saat öncesinden tahmin etmeyi amaçlamışlardır. Elde ettikleri sonuçları PM ile karşılaştırdılar. Önerilen yöntemin daha başarılı olduğunu tespit etmişlerdir.

Erdem ve Shi (2011), çalışmada ARMA modellerine dayalı modeller kullanılarak rüzgar hızı tahminlemesi yapılmış ve bu yaklaşımların performansları karşılaştırmışlardır.

Lalarukh ve Yasmin (1997), rüzgar hızı tahminlemesi için ARMA modelini tercih etmişler. Çalışmalarında non-stationary rüzgar hızı veri setini kullandılar. Elde edilen sonuçlara göre rüzgar ve varyans tahminlerinin kabul edilir aralıkta olduğunu tespit etmişlerdir.

Ding ve ark. (2021), rüzgar hızı zaman serisine ön işleme sürecinde ikincil ayrıştırma yöntemi uyguladılar. Ayrıştırılan seri ile tahminleme yapmak için ARIMA modelini genel yapıya adapte etmişlerdir.

Torres ve ark. (2005), tarafından ARMA ve PM modeli karşılaştırılarak saatlik ortalama rüzgar hızı tahmini yapıldı. Elde edilen sonuçlarda ARMA modelinin performansının daha iyi olduğu gözlemlendi. Özellikle ARMA modelindeki hata oranlarının daha düşük olduğu vurgulanmışlardır.

Sideratos ve Hatziargyriou (2007), tarafından sinir ağları ve bulanık mantık yöntemini birleştiren bir model geliştirmişlerdir.

Kalogirou (2000), yenilenebilir enerji sistemlerinde ANN kullanılmasını incelemiş ve bir fizibilite çalışması yapmıştır. Özellikle çalışmada rüzgar hızı ve güneş radyasyonu tahmini fotovoltaik sistemler güneş enerjili su ısıtma sistemleri ve güneş buhar tesisleri alanında araştırmalar yapılmıştır.

Yayla ve Harmancı (2021), çalışmalarında yeni bir YSA modeli önermişlerdir. Modelde tahminleme işlemi için iki istasyondan toplanan saatlik rüzgar hızı verilerini kullanmışlardır.

Capizzi ve ark. (2012), çalışmalarında wavelet recurrent neural networks (WRNN) kullanmışlardır. Belirlenen ve kabul edilebilir bir hata sınırları içerisinde tahminleme işlemi gerçekleştirmişlerdir.

Li (2003), çalışmasında rüzgar enerjisi üretimini tahminledi. Çalışmada recurrent multilayer perception neural networks (RMLP) kullanıldı. Ağ eğitilirken Kalman tabanlı geri yayılım algoritması denendi. Tahminleme sonuçları kıyaslandığında uzun dönem tahminleme için önerilen metodun daha faydalı olduğunu belirlemiştir.

Carolin ve Fernandez (2008), çalışmalarında YSA modeli kullanmışlardır. Modelde kullanılan girdiler üretim saati, bağıl nem ve rüzgar hızı olarak belirlenmiştir. Elde edilen sonuçların tatmin edici olduğu vurgulanmıştır.

Bosch ve ark. (2007), çalışmalarında YSA için en uygun değişkenleri belirlemeyi amaçladılar. Bu gerçekleştirmek için automatic relevance determination (ARD) metodunu kullanmışlardır.

Bedi ve Toshniwal (2019), elektrik enerjisi talebini tahminlemek için LSTM kullandılar. Uzun dönem tahminlemede mevsimsel verilerden faydalanarak çok girişli ve çok çıkışlı bir yapı oluşturmuşlardır.

Abedinia ve ark. (2020), kısa ve uzun dönem rüzgar enerjisinin tahminlenmesi için 2 boyutlu bir CNN yapısı önerdiler. Veri ön işleminde dalgacık dönüşümünden faydalandılar. Ayrıca CNN ağırlıklarını parçacık sürü optimizasyon algoritması kullanarak belirlemişlerdir.

Niu ve ark. (2020), kısa dönem rüzgar enerjisi tahminlemek için an attention-based Gated Recurrent Unit (AGRU) metodunu önermişlerdir.

Mardani ve ark. (2015), zaman serisi verilerini ayırıklaştırmışlardır. Ayırıklaştırılan veriler kullanılarak sınıflandırma ve karmaşıklığı hesaplamışlardır. Bu işlemlerin gerçekleştirilmesinde LSTM ve bulanık entropi kullanmışlardır.

Kim ve ark. (2019), güç tüketimini esas alarak diğer faktörleri de değerlendirip hibrit bir tahminleme metodu önermişlerdir. Bu metod CNN ve LSTM birleştirilerek kurgulanmış ve tahminleme işlemlerini bu yapı üzerinden gerçekleştirmişlerdir..

Qin ve ark. (2019), çalışmalarında LSTM kullanarak rüzgar hızı tahminlemesi gerçekleştirmişlerdir. Rüzgar hızı otokorelasyonunu belirlemek için maksimum bilgi katsayısı yaklaşımını uygulamışlardır.

Shukur ve Lee (2015), BPNN ve Kalman kullanarak hibrit bir tahminleme modeli oluşturmuşlardır. Özellikle BPNN'ün optimizasyonunu Kalman ile gerçekleştirmişlerdir. Geliştirdikleri hibrit modelin diğer modellere göre daha iyi hata metriklerine sahip olduğunu bildirmişlerdir.

Wang ve ark. (2018), çalışmalarında rüzgar hızı tahminlemesi için birden fazla simir ağını bir araya getirmişlerdir. Her bir ağına sahip olduğu avantajları kullanmayı hedeflediler ve elde edilen sonuçlarda yüksek performans yakalamışlardır.

Chen ve ark. (2019), LSTM ve CNN kullanarak hibrit bir model geliştirmişlerdir. Bu modeli kullanarak rüzgar hızı tahminlemesi yapmak için verileri üç boyutlu matrislere dönüştürmüşlerdir.

Dong ve ark. (2021), çalışmalarında maliyet fonksiyonu üzerine yaptıkları çalışmada CNN'i sezgisel algoritmalarla optimize ederek kullanmayı benimsemişlerdir. Sonuçlara ilişkin bulgularda diğer metodlara göre daha iyi sonuç aldıklarını açıklamışlardır.

Santhosh ve ark. (2018), EEMD tekniğini ve Geliştirilmiş dalgacık sinir ağı (Advanced Wavelet Neural Networks, AWNN) modelini birleştiren hibrit EEMD-AWNN yaklaşımı geliştirmişlerdir. Hibrit EEMD-AWNN modeli rüzgar hızının gelecekteki değerlerini tahmin etmek için kullanarak, önerilen EEMD-AWNN modelinin gelişmiş tahmin doğruluğu ile istenen sonucu elde edebileceğini kanıtlamışlardır.

Zhang ve arkadaşları (2017), rüzgar hızı tahminini iyileştirmek için bir dizi farklı yöntemi bir araya getiren bir çalışma yürütmüşlerdir. Bu yöntem, Komple Uyarlamalı Gürültülü Toplu Ampirik Mod Ayırıştırma (EEMD), Kaotik Yerel Arama ile Çiçek Tozlaşma Algoritması (CLSFPA), beş farklı sinir ağı modeli ve Negatif Kısıtlama Yok Teorisi (NNCT) temel alır. Sonuç olarak, bu birleşik modelin, tek başına sinir ağı modelleri ve ARIMA modeli gibi diğer yaygın kullanılan tahmin yöntemleriyle karşılaştırıldığında en iyi performansı sağladığı bulunmuştur. Bu yeni yaklaşım, rüzgar hızı tahmininde daha kesin ve güvenilir sonuçlara ulaşabilmek için etkili bir yöntem olarak öne çıktığını bildirmişlerdir.

He ve ekibi, kapsamlı bir hibrit sistem geliştirmişlerdir. Çalışmalarında veri işleme aşamasında Ensembled Empirical Mode Decomposition (EEMD) tekniğini, veri kümeleme aşamasında ise Kernel-Based Fuzzy C-Mean Clustering (KFCM) algoritmasını kullanmışlardır. Tahminleri yapmak için de Wavelet Neural Network (WNN) modeli oluşturmuşlardır. Bu hibrit sistem, veriye önceden işlem uygularken EEMD'yi kullanarak veriyi ayırıştırır ve daha sonra KFCM algoritmasıyla bu ayırıştırılmış verileri kümeleyerek benzer veri noktalarını gruplar. Son olarak, tahminleri yapmak için WNN modelini kullanır. Bu yaklaşım, veri analizinden tahminlere kadar geniş bir yelpazede etkili bir şekilde çalışabilir ve sonuçları iyileştirme potansiyeline sahip bir hibrit sistem olduğunu bildirmişlerdir.

Qu ve arkadaşları (2019) tarafından yürütülen çalışmada, yeni bir bütünleşik ayırıştırma yöntemi ile geliştirilen Flower-Pollination Algorithm (FPA) ve Backpropagation Neural Network (BPNN) algoritması kullanmışlardır.. Bu çalışmada karma ayırıştırma tekniği olarak CEEMDAN+EWT tercih etmişlerdir. Sonuçlar, bu önerilen modelin çok adımlı rüzgar hızı tahmininde diğer referans modellere göre önemli ölçüde daha iyi bir performans sergilediğini göstermiş ve bu, rüzgar hızı tahmininde kullanılan yeni ve etkili bir yaklaşımın bulunduğunu vurgulamışlardır.

Qian ve arkadaşları (2019) tarafından gerçekleştirilen çalışma, rüzgar hızı tahmin doğruluğunu artırmak amacıyla kullanılan ayırıştırma tekniklerini incelemişlerdir. Rüzgar hızı veya güç zaman eğrilerinin dayandığı ayırıştırma tabanlı metodlar ile alt kümeler oluşturmuşlardır daha sonra her bir alt küme için tahmin modellerini kullanan bir hibrit

model ailesini meydana getirmişlerdir.. Bu çalışmada, ayrıştırma tabanlı hibrit tahmin modelleri, dalgacık tabanlı modellere, EMD tabanlı modellere ve diğer ayrışma temelli modellere göre sınıflandırılmıştır. Bu sınıflandırma, farklı ayrıştırma yöntemlerini ve bu yöntemlerin rüzgar hızı tahminindeki etkinliğini daha iyi anlamaya yardımcı olur. Bu tür sınıflandırmalar, rüzgar hızı tahmininde daha iyi sonuçlar elde etmek için kullanılabilecek en uygun modelin belirlenmesine yardımcı olabileceğini bildirmişlerdir.



3. RÜZGAR ENERJİSİ

3.1 Rüzgar Enerjisi Potansiyeli, Avantajları ve Dezavantajları

Klasik bir tanım perspektifinden bakıldığında, doğada mevcut olan rüzgar enerjisiyle işleyen türbinler, rüzgarda bulunan kinetik enerjiyi başlangıçta mekanik enerjiye, ardından elektrik enerjisine dönüştüren sistemler olarak kabul edilebilmektedirler. Bu rüzgar enerjisi dönüşüm sürecinde, ilk adım olarak potansiyel rüzgar gücünün belirlenmesi gerekmektedir. Rüzgar gücü, temel olarak hava yoğunluğu ile ilişkilidir. Uluslararası standart atmosfer (ISA) koşullarında (deniz seviyesinde +15°C sıcaklıkta ve 1.013,25 mb atmosfer basıncında) hava yoğunluğu 1.225 kg/m³ olarak kabul edilmektedir. Bu husus, İdeal Gaz Kanunu tarafından ifade edilen denklem 3.1'de ayrıntılı bir şekilde açıklanmıştır (Emeksiz, 2014).

$$P.V = n.R.T \quad (3.1)$$

Hava yoğunluğu, en basit haliyle İdeal Gaz Denklemi'nde (Eşitlik 3.2) tanımlanmıştır.

$$P = \frac{P.MW.10^{-3}}{R.t} \quad (3.2)$$

Eşitlik 3.2'de P, mutlak basınç (atm), mol sayısı (mol), V, hacim (m³), n, R, T, ideal gaz sabiti, kelvin cinsinden mutlak sıcaklık, MW, havanın moleküler ağırlığı olarak tanımlanabilir.

Rüzgar türbinlerinin ürettiği güç, yatay eksenli türbinler için rotorun süpürdüğü alan ile doğru orantılıdır. Rotorun süpürdüğü alan, kanat çapını (R metre) ifade eden Eşitlik 3.3 tarafından belirtilmiştir. Süpürme alanı, yatay eksenli türbinlerde kanat çapının karesi ile orantılıdır (Patel, 2006).

$$A = \frac{\pi}{4R^2} \quad (3.3)$$

netik enerji, rüzgar enerjisi analizinde önemli bir rol oynar ve bu enerji, hareket halindeki hava kütesinin hızına bağlı olarak belirlenir. Daha özel bir ifadeyle, 'm' kütesine sahip bir hava kütlesi, 'V₁' hızıyla hareket ettiğinde, bu kütenin kinetik enerjisi, aşağıda Eşitlik 3.4'te açıklandığı gibi hesaplanabilir.

$$E_k = \frac{1}{2} \cdot m \cdot v_1^2 \text{ (Nm)} \quad (3.4)$$

Bu denklemde, 'E_k' kinetik enerjiyi temsil eder. Rüzgar enerjisi ile ilgilenen bağlamda, bu kinetik enerji, rüzgarın hızına ve aynı zamanda havanın kütesine bağlıdır. Rüzgar enerjisi analizinde, bu tür denklemler rüzgar türbinlerinin performansını değerlendirmek ve enerji üretimini optimize etmek için kullanılmaktadır.

Hareketli durumda olan hava kütlesi türbin rotorunun kanatlarının sahip olduğu alana (A) çarptığında var olan kinetik enerjinin belirli bir kısmı engellenir. Engellenen enerji türbin kanatlarının hareketlenmesinde kullanılır (Çetin, 2006). Kanatlarda engellenen P_h yoğunluğundaki havanın kütesel debisi eşitlik 3.5'de ifade edilmektedir.

$$\dot{m} = p_h \cdot v_1 \cdot A \text{ (kg/s)} \quad (3.5)$$

Burada, 'm' türbin kanatlarına çarpan havanın kütesel debisini temsil eder ve p_h, hava yoğunluğunu ifade eder. Bu denklem, rüzgar enerjisi dönüşümünün temel prensiplerinden birini yansıtarak, enerjinin türbinin çalışmasına nasıl dönüştüğünü açıklamaktadır (Çetin, 2006).

Birim zamanda gerçekleştirilen işin, güç olarak tanımlandığı bir bağlamda, iş yapabilme yeteneği aşağıdaki Eşitlik 3.6 ile ifade edilir:


$$p_r = \frac{\frac{1}{2} \cdot m \cdot v_1^2}{t} \text{ (Nm/s)} \quad (3.6)$$

Bu denklemde, p_r iş yapabilme yeteneğini temsil eder yani ve t süresinde birim zamanda yapılan işi (enerjiyi) ifade eder. Bu formül, enerji dönüşümü ve güç hesaplamalarında

kullanılan temel bir denklemdir. Formüldeki m, zamana karşı türevi 'm' olarak temsil edilebilir ve rüzgardan elde edilebilecek teorik güç m yerine 3.5'deki eşitlik yazıldığında eşitlik 3.7'deki gibi olmaktadır.

$$P_r = \frac{1}{2} \cdot \rho_h \cdot A \cdot v_1^3 \quad (W) \quad (3.7)$$

Rüzgar gücünün etkisi rüzgar türbinlerinde, rotor süpürme alanı ve rüzgar hızının küpü ile doğrudan bağlıdır. Ancak, bir rüzgar türbin sistemlerinde rüzgar gücünden azami %59 oranında faydalanabileceği bir sınıra ulaşır. Bu temel prensibe "Betz Teoremi" denir ve bu teorem, rüzgar enerjisi dönüşümünün teorik sınırlarını belirler (Emeksiz, 2014). Betz teoremi ile alakalı olarak, rüzgar türbininin kanatlarından geçen havanın enerji akışı, Şekil 3.1'de gösterilmiştir. Betz teoremi, rüzgar enerjisi dönüşümünün önemli bir sınırlayıcı faktörünü temsil eder ve bu teoriye göre, bir rüzgar türbini, rüzgarın sadece belirli bir yüzdesini kullanabilir.



Şekil 3.1. Rüzgar enerjisinde kullanılan Betz teoremi (Özpınar, 2007).

Betz Teoremi, Alman fizikçi Albert Betz tarafından 1919'da formüle edilen bir prensiptir. Bu teorem, rüzgar enerjisi dönüşümünün teorik sınırlarını tanımlar. Betz Teoremi, rüzgar enerjisi türbinlerinin maksimum verimini hesaplayan temel bir kavramdır. Betz Teoremi, bir rüzgar türbininin önüne gelen rüzgarın enerjisinin belirli bir sınıra kadar nasıl dönüştürülebileceğini açıklamaktadır. Teoreme göre, bir rüzgar türbini, rüzgarın hızını kesinlikle sıfıra düşüremeyeceği ve maksimum %59,3 oranında enerjiyi

dönüştürebileceği bir sınıra ulaşır. Bu sınıra ulaşmak için türbinin rotor süpürme alanını kullanmaktadır.

Betz Teoremi, rüzgar enerjisi türbinlerinin tasarımı ve verimliliği için temel bir kısıtlama sağlamaktadır. Bu teorem, rüzgar enerjisi türbinlerinin optimal boyutlarını ve performansını hesaplamak için kullanılmaktadır. Aynı zamanda enerji sektöründe rüzgar enerjisi projelerinin tasarımı ve planlaması için önemlidir. Bu teorem, rüzgar enerjisi dönüşümünün fiziksel sınırlarını anlamamıza yardımcı olur ve tasarım kararlarına yol göstermektedir.

Sonuç olarak, Betz Teoremi, rüzgar enerjisi türbinlerinin ne kadar enerjiyi dönüştürebileceğini ve bu dönüşümün teorik sınırlarını belirler. Bu nedenle, rüzgar enerjisi tesislerinin tasarımında ve verimliliğinin artırılmasında önemli bir rol oynamaktadır (Emeksiz, 2014).

üzgar pervanesinden geçen havanın enerji dengesi, rüzgar enerjisi dönüşümünü anlamak ve optimize etmek için önemli bir kavramdır. Bu dengenin temelinde, gelen rüzgarın enerjisinin türbin tarafından nasıl yakalandığı ve dönüştürüldüğü yer almaktadır. Enerji dengesi şu ana unsurları içermektedir:

- Kinetik Enerji: Rüzgar, hareket eden bir hava kütesidir ve bu hava kütlesi belirli bir kinetik enerjiye sahiptir. Bu enerji, rüzgar hızının karesi ile doğru orantılıdır.
- Rotor Süpürme Alanı: Rüzgar türbinin rotoru, rüzgarın belirli bir alanını keser ve bu alan içindeki hava hareketi rotor tarafından yakalanır.
- Rüzgarın Hızının Azalması: Rüzgar türbininin pervanesinden geçen hava, pervane kanatları tarafından yavaşlatılır ve bu nedenle rüzgar hızı azalır. Bu hız azalması, kinetik enerjinin bir kısmının türbin rotoru tarafından alındığı anlamına gelmektedir.
- Mekanik Enerji: Rüzgar türbinin rotoru, yakaladığı hava hareketini mekanik enerjiye dönüştürür. Bu, pervane kanatlarının dönmesi ve türbin şaftının hareket etmesi yoluyla gerçekleşmektedir.
- Elektrik Enerjisi: Mekanik enerji, jeneratör veya alternatör gibi bir elektrik üreten sistem aracılığıyla elektrik enerjisine dönüştürülür.

- Verim Kayıpları, Gerçek dünyadaki rüzgar türbinleri, enerji dönüşümü sırasında bazı verim kayıplarına neden olur. Bu kayıplar sürtünme, titreşimler, elektriksel kayıplar ve diğer faktörlerden kaynaklanabilir.

Enerji dengesi, rüzgar türbininin verimliliğini ve performansını değerlendirmek için kullanılır. Betz Teoremi, rüzgar türbinlerinin maksimum teorik verimini belirlerken enerji dengesini temel alır ve bu teorem, rüzgar enerjisi tesislerinin tasarımı ve işletilmesinde önemli rol oynamaktadır. Türbin kanatların engelleyemediği havanın rüzgar enerji dengesi;

$$E_{kt} = E_{k_1} - E_{k_2} \quad [Nm] \quad (3.8)$$

olarak ifade edebilir. Hareketli olan rüzgarın sahip olduğu kinetik enerji, kinetik enerjinin formülasyonuna göre ayarlanacak olursa eşitlik 3.8, aşağıdaki şekilde yazılabilir:

$$E_{kt} = \frac{1}{2} \cdot m \cdot (v_1^2 - v_2^2) \quad [Nm] \quad (3.9)$$

Literatürde kabul edilen Güç tanımı, t süresinde gerçekleşen iş varsayılırsa, türbinden sağlanabilecek edilecek güç;

$$P_t = \frac{E_{kt}}{t} = \left(\frac{1}{2}\right) \cdot \left(\frac{dm}{dt}\right) \cdot (v_1^2 - v_2^2) \quad [Nm/s] \quad (3.10)$$

Olarak ifade edilebilir. Burada; dm/dt , $\dot{m}$ olarak varsayılırsa, türbinden sağlanabilecek güç;

$$P_t = \frac{E_{kt}}{t} = \left(\frac{1}{2}\right) \cdot \dot{m} \cdot (v_1^2 - v_2^2) \quad [W] \quad (3.11)$$

şeklini alır. Rüzgar türbin kanatlarına uygulanan birim zamandaki basınca bağlı olarak, rüzgarın türbin kanatları üzerinde gerçekleştireceği iş miktarı belirlenir:

$$P_t = S \cdot V \quad [W] \quad (3.12)$$

Türbin kanatlarına rüzgarın uygulayabileceği basınç ise;

$$S = \dot{m} \cdot (v_1 - v_2) \quad [\text{kgm/s}^2] \quad (3.13)$$

olarak tanımlanır. 3.11 ve 3.12’de gösterilen formüller eşitlenip, 3.13’de olduğu gibi yerine konulursa;

$$\dot{m} \cdot v \cdot (v_1 - v_2) = \frac{1}{2} \cdot \dot{m} \cdot (v_1^2 - v_2^2) \quad (3.14)$$

elde edilir. Buradan;

$$v = \frac{1}{2} \cdot (v_1 + v_2) \quad [\text{m/s}] \quad (3.15)$$

şeklinde ifade edilir. Böylece, kanatlarda engellenen ve geçen rüzgar hızlarının ortalaması olduğu sonucuna ulaşılmaktadır. 3.5’de formül kullanılarak, kanatlardan geçen havanın kütleli debisi ($\dot{m}$), 3.11’de yerine konulursa;

$$P_t = \left(\frac{1}{2}\right) \cdot \rho_h \cdot v \cdot A \cdot (v_1^2 - v_2^2) \quad [\text{W}] \quad (3.16)$$

Förmülüne ulaşılır. 3.15’deki eşitlik 3.16’da yerine konulursa;

$$P_t = \left(\frac{1}{4}\right) \cdot \rho_h \cdot A \cdot (v_1 + v_2) \cdot (v_1^2 - v_2^2) \quad [\text{W}] \quad (3.17)$$

Förmülüne ulaşılır. P_t ve P_r değerleri birbirine oranlandığında;

$$C_p = \left(\frac{P_t}{P_r}\right) = \frac{1}{2} \left(1 - \left(\frac{v_2}{v_1}\right)^2\right) \left(1 + \left(\frac{v_2}{v_1}\right)\right) \quad (3.18)$$

türbin verimi olan C_p elde edilir. $\frac{v_2}{v_1} = n$ ile tanımlanırsa;

$$C_p = \frac{1}{2}(1 - n^2)(1 + n) \quad (3.19)$$

şeklinde verim katsayısı fonksiyonu elde edilir. İfadenin türeviden elde edilen n değeri, C_p 'yi maksimize eder ve bu değer $1/3$ olarak bulunur. Bu, C_p 'nin en yüksek olması için kanatların, rüzgarın türbin giriş hızının üç katı olacak şekilde tasarlanması gerektiğini ifade eder. Bu tasarımın sonucunda türbinden elde edilecek maksimum verim 0,5926 olacaktır. Pratikte, bu oran genellikle yaklaşık %45 olarak gözlemlenir. (Çetin, 2001).

Dünya genelinde, enerji ihtiyacını karşılamak için çoğunlukla fosil yakıtlar kullanılmaktadır. Ancak, bu fosil yakıtların sınırlı rezervlere sahip olması ve kullanımlarının doğaya verdiği zararın giderek artması, küresel çapta çevreci yaklaşımların yükselmesine ve yenilenebilir enerji kaynaklarına olan talebin artmasını sağlamıştır. Bu bağlamda, yenilenebilir enerji kaynakları arasında özellikle rüzgar enerjisi, sahip olduğu avantajlar nedeniyle öne çıkmaktadır. İlerleyen zamanlarda, enerji sektöründeki öncü ülkeler, enerji arz güvenliğini sağlama ve enerji ithalatına olan bağımlılığı azaltma amacıyla rüzgar enerjisi üretimini ve kullanımını önemli ölçüde desteklemektedirler. Öngörülüyor ki, dünya genelinde elektrik enerjisi tüketiminin 2040 yılına ulaştığında, rüzgar enerjisi bu talebin %20'sini karşılayacak bir kaynak olarak ön plana çıkacaktır (Bayraç, 2011). Rüzgar enerjisi, yenilenebilir enerji kaynakları arasında önemli bir paya sahiptir ve enerji sektöründeki rolü her geçen gün artmaktadır. Rüzgar enerjisi, çevre dostu ve sürdürülebilir bir enerji kaynağı olarak çeşitli avantajlara sahiptir. Rüzgar enerjisinin başlıca avantajları:

- Çevre Dostu: Rüzgar enerjisi, fosil yakıtların aksine doğaya zarar vermez. Rüzgar türbinleri çalıştığında, sera gazlarının atmosfere salınımını sınırlar ve böylece iklim değişikliğiyle mücadeleye katkı sağlar. Karbon ayak izi oldukça düşüktür.
- Sürdürülebilir Kaynak: Rüzgar enerjisi yenilenebilir bir kaynaktır. Rüzgar her zaman mevcuttur ve tükenmez. Bu, enerji arzının istikrarını sağlar.
- Az Bakım Gereksinimi: Rüzgar türbinleri düşük bakım gereksinimine sahiptir. Teknik olarak bakıldığında, kanatların düzenli bakımı ve türbinlerin çalışma durumlarının izlenmesi gerekir, ancak bu genellikle düşük maliyetli ve basittir.

- Yerel Ekonomiye Destekler: Rüzgar enerjisi projeleri, yerel ekonomiye katkı sağlar. Yerel işlerin yaratılması, altyapının geliştirilmesi ve enerji üretiminin artırılması gibi faktörler, rüzgar enerjisi yatırımlarının bölgeye ekonomik fayda sağladığını gösterir.
- Enerji Bağımsızlığı: Rüzgar enerjisi, enerji ithalatına olan bağımlılığı azaltabilir. Ülkeler, yerel olarak üretilen rüzgar enerjisine dayanarak enerji bağımsızlığını artırabilirler.
- Esneklik: Rüzgar enerjisi, farklı ölçeklerde kullanılabilir. Küçük rüzgar türbinleri evlerde veya çiftliklerde kullanılabilirken, büyük rüzgar çiftlikleri büyük elektrik gridlerine elektrik üretebilir.
- Düşen Maliyetler: Teknoloji geliştikçe, rüzgar enerjisi üretim maliyetleri düşmektedir. Bu, rüzgar enerjisinin rekabetçi hale gelmesine ve daha fazla benimsenmesine yardımcı olur.
- Çok Yönlü Kullanım: Rüzgar enerjisi, elektrik üretiminin yanı sıra su pompalama, deniz suyu tuzundan tuz üretimi, hidrojen üretimi ve diğer endüstriyel uygulamalarda da kullanılabilir.

Ancak rüzgar enerjisinin dezavantajları da vardır, örneğin rüzgarın sürekli olmaması ve yerleşim yerlerine uzak rüzgar çiftliklerinin altyapı maliyetleri gibi. Bu nedenle, rüzgar enerjisi projeleri dikkatli bir şekilde planlanmalı ve bölgenin enerji ihtiyaçlarına uygun olmalıdır.


Rüzgar enerjisi, Türkiye'de giderek artan bir öneme sahip olan yenilenebilir enerji kaynaklarından biridir. Özellikle ülkenin yüksek rüzgar enerjisi potansiyelinin ortaya konulması, rüzgar enerjisinin Türkiye'nin gelecekteki enerji üretiminde önemli bir rol oynayacağı öngörüsünü güçlendirmektedir (Yanıktepe ve ark., 2013).

Türkiye'nin genelinde rüzgar enerjisi potansiyeli değerlendirildiğinde, coğrafi ve fiziki konumlara bağlı olarak bölgeler arasında farklılıklar gözlemlenmektedir. Rüzgar enerjisi yatırımlarında, potansiyel belirleme çalışmaları ilk adımı oluşturur. Ülkemizde rüzgar enerjisi potansiyelini değerlendirmek amacıyla, Meteoroloji Genel Müdürlüğü tarafından 45 farklı meteorolojik istasyonda 10 yıl boyunca kaydedilen saatlik rüzgar hızları kullanılarak "Türkiye Rüzgar Atlası" oluşturulmuştur. Türkiye Rüzgar Atlası, Türkiye

genelindeki farklı bölgelerdeki rüzgar hızlarını ve enerji potansiyelini belirlemek amacıyla uzun süreli rüzgar hızı ölçümleri kullanılarak oluşturulan bir veri setidir. Bu atlas, Türkiye'deki rüzgar enerjisi projelerinin planlanması, tasarlanması ve rüzgar enerjisi yatırımlarının optimize edilmesi için büyük öneme sahiptir. Bu atlas, rüzgar enerjisi tesislerinin kurulacağı yerlerin seçiminde, enerji üretim tahminlerinin yapılmasında ve rüzgar enerjisi projelerinin planlanmasında kullanılmaktadır. Türkiye Rüzgar Atlası, Türkiye'nin farklı bölgelerindeki rüzgar enerjisi potansiyelini belirlerken bazı önemli sonuçlar ortaya koymaktadır: Atlas sonuçlarına göre, Türkiye'nin en yüksek rüzgar potansiyeline sahip bölgeleri genellikle kıyı bölgeleri, özellikle Ege ve Marmara bölgeleri ile Karadeniz sahilidir. Bu bölgelerde yıllık ortalama rüzgar hızları daha yüksektir. İç Anadolu ve İç Ege bölgeleri, rüzgar enerjisi potansiyeli açısından diğer bölgelere göre daha düşük rüzgar hızlarına sahiptir. Bu bölgelerde rüzgar enerjisi projelerinin verimliliği daha düşük olabilir. Türkiye'nin deniz sahilleri, özellikle Karadeniz kıyıları, yüksek rüzgar hızlarına sahiptir ve deniz üstü rüzgar enerjisi projeleri için büyük bir potansiyele sahiptir. Dağlık bölgeler ve yüksek rakımlı alanlar, rüzgar enerjisi potansiyeli açısından önemlidir. Bu bölgelerde rüzgarın yüksek hızlara sahip olma olasılığı daha yüksektir. Türkiye Rüzgar Atlası, rüzgar enerjisi yatırımlarının özellikle yüksek rüzgar potansiyeline sahip bölgelerde yoğunlaşmasını teşvik eder. Bu bölgelerde rüzgar enerjisi tesisleri kurularak enerji üretimi artırılabilir.

Atlas'taki verilere göre, yerden 50 metre yükseklikteki bölgelerde yıllık ortalama rüzgar hızı 7 m/s ve üzeri olan alanlardaki güç yoğunlukları hesaplanarak kullanılabilir alanlar dikkate alınmış ve Türkiye'nin rüzgar enerjisi potansiyeli belirlenmiştir. Şekil 3.2'de gösterildiği gibi, toplam kurulabilecek rüzgar gücü kapasitesi 47 849 MW olarak belirlenmiştir. Bu kapasitenin 10 000 MW'lık kısmı deniz üstü alanlar için, 37 836 MW'lık kısmı ise kara üstü alanlar için hesaplanmıştır. (Soğukpınar ve Bozkurt, 2014).

Türkiye'nin sahip olduğu bu büyük rüzgar enerjisi potansiyeli, enerji üretiminde çevre dostu ve sürdürülebilir bir kaynak olarak rüzgar enerjisinin daha fazla benimsenmesini teşvik etmektedir. Bu potansiyeli etkin bir şekilde kullanmak, ülkenin enerji bağımsızlığını artırabilir ve çevresel sürdürülebilirliğe katkı sağlar.



Şekil 3.2. Türkiye için oluşturulmuş rüzgar enerjisi potansiyeli (Anonim, 2022)

Türkiye Rüzgar Atlası'na incelendiğinde, 50 metre yükseklikteki ve yerleşim yerlerinin dışındaki bölgelerde yapılan hesaplamalarda Doğu Akdeniz, Batı Karadeniz ve Marmara kıyı şeritlerinde yıllık ortalama rüzgar hızının 6 ile 7 m/s aralığında olduğu tespit edilmiştir. İç bölgelerde ise bu hız 4,5 ile 5 m/s aralığına düşmektedir. Kuzeybatı Ege kıyı şeritlerinde ise yıllık ortalama rüzgar hızı 7 ile 8,5 m/s aralığına çıkmaktadır, Ege Bölgesi'nin iç kesimlerinde ise 6,5 ile 7 m/s aralığında bir ortalama gözlemlenmektedir (Yanıktepe ve ark., 2013). Başka bir deyişle Türkiye'deki yedi coğrafi bölgenin değerlendirmesi sonucunda, rüzgar enerjisi sistemleri için en uygun bölgelerin, Ege, Karadeniz ve Marmara olduğu ortaya çıkarken, , Balıkesir, İzmir, Çanakkale, Sinop ve İstanbul'un rüzgar potansiyeli en iyi şehirler olduğu ifade edilmektedir (İlkiliç, 2012).

Türkiye'nin sahip olduğu büyük rüzgar enerjisi potansiyeli, bir dizi önemli faydayı beraberinde getirirken aynı zamanda ülkenin enerji sektörünü çevre dostu ve sürdürülebilir bir yöne taşıma fırsatı sunar:

- Rüzgar türbinleri çalışırken sera gazları veya hava kirliliği salınımına neden olmaz. Bu, Türkiye'nin hava kalitesini ve çevresel sürdürülebilirliği artırabilir.
- Yerel olarak üretilen rüzgar enerjisi, enerji ithalatına olan bağımlılığı azaltabilir. Bu, Türkiye'nin enerji arz güvenliğini artırabilir ve enerji fiyatlarını kontrol etmeye yardımcı olabilir.
- Rüzgar enerjisi projeleri, inşaat, bakım, işletme ve diğer alanlarda istihdam yaratır. Bu, yerel ekonomiye katkı sağlayabilir ve yeşil iş fırsatları oluşturabilir.

- Rüzgar enerjisi projeleri, sürdürülebilir kalkınmanın bir parçası olarak kabul edilir. Temiz enerji üretimi, enerji ihtiyacını karşılarken doğal kaynakların korunmasına katkı sağlar.
- Rüzgar enerjisi teknolojisinin gelişmesiyle birlikte üretim maliyetleri düşer. Bu da enerji fiyatlarının rekabetçi olmasını sağlar ve tüketicilere fayda sağlar.
- Türkiye'nin enerji stratejileri, yenilenebilir enerji kaynaklarını teşvik etmek ve bu kaynakların payını artırmak üzerine odaklanmaktadır. Rüzgar enerjisi, bu hedefleri destekleyen önemli bir bileşendir.

Sonuç olarak, Türkiye'nin sahip olduğu büyük rüzgar enerjisi potansiyeli, ülkenin enerji üretimini çevre dostu ve sürdürülebilir bir şekilde yönlendirmesi için önemli bir fırsattır. Bu potansiyeli etkin bir şekilde kullanmak için yatırımların artırılması, teknoloji geliştirmeleri ve politika destekleri gerekmektedir. Bu sayede Türkiye, enerji sektöründe yeşil bir dönüşümü başarabilir ve gelecekteki enerji ihtiyaçlarını sürdürülebilir bir şekilde karşılayabilir (Anınim, 2022).

3.2 Rüzgar Gücü ve Hızı İçin Tahminleme Metodları

İnsanlar tarih boyunca geleceği tahmin etme ihtiyacını hissetmişlerdir. Tahminler, birçok alanda karar alma süreçlerini ve stratejik planlamayı etkileyen temel bir bileşendir. Bu nedenle, doğru tahminler oluşturmak, bir hedefe ulaşmak veya bir amacı gerçekleştirmek için büyük önem taşır. Ancak, tahminlerin etkili olabilmesi için hedeflenen çalışma amacına uygun olarak uyarlanması gerekmektedir.

Tahminler, ekonomik ve iktisadi alanlar da dahil olmak üzere birçok farklı alanda kullanılır. Örneğin, iş dünyasında gelecekteki pazar talebini tahmin etmek, üretim ve tedarik zinciri planlamasını etkileyebilir. Ekonomi yönetiminde ise enflasyon, faiz oranları, işsizlik gibi faktörlerin tahminleri, ekonomi politikalarının oluşturulmasında önemli bir rol oynar.

Doğru tahminler yapabilmek için verilerin titizlikle toplanması, işlenmesi ve analiz edilmesi gerekmektedir. Bu noktada, istatistiksel yöntemler, zaman serisi analizi, regresyon analizi, makine öğrenimi ve istatistiksel modelleme gibi araçlar önemli bir rol

oynamaktadırlar. Tahminler aynı zamanda risk yönetimi süreçlerinde de hayati bir rol oynar. Olası gelecek senaryolarını tahmin ederek, şirketler ve kurumlar risklere karşı daha hazırlıklı olabilirler. Bu, finansal krizlerin etkilerini hafifletebilir ve iş sürekliliği planlamasını güçlendirebilir.

Sonuç olarak, tahminler gelecekteki belirsizliklerle başa çıkmak için önemli bir araçtır. Doğru tahminler, daha iyi kararlar almak, kaynakları daha etkili bir şekilde yönlendirmek ve stratejileri daha iyi planlamak için vazgeçilmezdir. Bu nedenle, tahmin süreçlerini geliştirmek ve doğru verilere dayalı tahminler yapmak, birçok sektörde başarı için kritik bir unsurdur.

Özellikle rüzgar enerjisi projelerinin tasarımında, başarıya ulaşabilmek için çeşitli faktörlerin dikkate alınması büyük önem taşır. Bu faktörler, projenin etkinliğini ve sürdürülebilirliğini belirlemekte kritik rol oynamaktadırlar (Köse ve ark., 2014). Bbu bağlamda bazı önemli noktalar şunlardır:

- Rüzgar enerjisi projelerinin başarılı bir şekilde hayata geçirilebilmesi için, proje yapılacak bölgenin altyapı imkanlarının iyi bir şekilde bilinmesi gerekmektedir. Elektrik iletim hatları, yollar, su kaynakları ve diğer altyapı unsurları projenin planlamasında dikkate alınmalıdır.
- Rüzgar enerjisi projeleri için en uygun bölgelerin belirlenmesi, o bölgedeki rüzgar enerjisi potansiyelinin doğru bir şekilde hesaplanmasını gerektirir. Rüzgar hızlarının uzun vadeli ölçümleri ve analizleri bu açıdan büyük önem taşır.
- Rüzgar enerjisi üretimi, rüzgar hızlarına bağlı olarak değişkenlik gösterir. Bu nedenle, rüzgar hızlarının tahmin edilmesi ve sürekli olarak izlenmesi önemlidir. İyi tahminler, enerji üretimi ve tüketimi arasındaki dengeyi sağlamada yardımcı olmaktadır.
- Rüzgar enerjisinin dalgalı doğası, şebeke dengelemesi için ek zorluklar yaratabilir. Enerji üretimi ve tüketimi arasındaki dengeyi korumak için akıllı şebeke teknolojileri ve enerji depolama sistemleri gibi çözümler önemli rol oynar.
- Rüzgar gücü tahminleri, projelerin ekonomik ve teknik açıdan daha verimli olmasına yardımcı olabilir. Doğru tahminler, enerji üretimini optimize ederek maliyetleri düşürebilir (Şenkal, 2014).

Rüzgar enerjisi projeleri, başarılı bir şekilde planlanması ve yönetilmesi gereken karmaşık ve dinamik projelerdir. Bölgenin potansiyeli, altyapı imkanları, rüzgar hızı tahminleri ve şebeke dengelemesi gibi faktörler, projelerin başarısını etkileyen temel unsurlardır. Bu nedenle, rüzgar enerjisi projelerinin başarılı bir şekilde geliştirilebilmesi için bu faktörlerin titizlikle ele alınması önemlidir (Soman ve ark., 2010).

Bu yüzden, rüzgar hızı tahminleme konusunda gerçekleştirilen araştırmalar, rüzgar tahminlerinin daha hassasiyetle yapılabilmesinin, iletim sistemlerine entegre olma gereksinimleri, çeşitli veri filtreleme teknikleri ve uygun teknolojik alt yapıya sahip rüzgar türbinlerinin kullanılması yoluyla ele alınabileceğini vurgulamaktır (Uygun ve Eker, 2009).

Rüzgar santralının anlık çıkış gücünü zamanında doğru tahmin edebilmek ve elektrik iletim sisteminin dağıtım planını düzenlemek, elektrik üretimi açısından hayati bir öneme sahiptir (An ve ark., 2012). Rüzgar gücünün hesaplanması yaygın olarak tercih edilen yöntem, rüzgar hızının tahmin edilmesi ve güç eğrileri kullanılarak güç değerlerinin hesaplanmasıdır. Bu nedenle, rüzgar hızının doğru bir şekilde tahmin edilmesi ekonomik açıdan büyük bir önem arz etmektedir. Çünkü enerji üreticileri, belirli bir üretim maliyetiyle üretecekleri enerji miktarını en az bir gün öncesinden bildirmek zorundadır (Tasçıkaraoğlu ve Uzunoğlu, 2011). Ters durumda, yanlış tahminler nedeniyle fazla veya eksik enerji üretimi için cezai yaptırımlarla karşılaşılabilir (Şenkal, 2014). Rüzgar enerjisi tahminlerinin yapılması, bir dizi önemli faydalar sunmaktadır:

- Rüzgar enerjisi tahminleri, enerji üreticilerine rüzgar enerjisi santrallerinin ne kadar enerji üreteceği konusunda bilgi sağlar. Bu, enerji üretiminin daha verimli bir şekilde planlanmasına ve kaynakların daha etkili bir şekilde kullanılmasına yardımcı olmaktadır.
- Rüzgar enerjisi tahminleri, elektrik dağıtım ve iletim sistemlerinin etkin bir şekilde planlanmasına yardımcı olur. Bu sayede enerji şebekeleri, ani dalgalanmalar veya enerji eksiklikleri gibi sorunlarla daha iyi başa çıkabilir.

- Rüzgar enerjisi tahminleri, enerji tedarikçilerine enerji arzını daha iyi tahmin etme imkanı sunar. Bu, tüketici taleplerini karşılamak için gereken enerji miktarını daha hassas bir şekilde hesaplamalarına yardımcı olmaktadır.
- Doğru tahminler, enerji üretim ve dağıtım maliyetlerini azaltabilir. Fazla enerji üretme veya eksik enerji üretme durumlarını önleyerek, enerji kaynaklarının daha verimli bir şekilde kullanılmasına katkı sağlamaktadırlar.
- Rüzgar enerjisi tahminleri, enerji üretiminin çevresel etkilerini azaltabilir. Özellikle enerji talebi ile enerji üretimi arasındaki dengesizlikleri önleyerek fosil yakıtların kullanımını azaltabilirler.
- Doğru tahminler, enerji piyasasının istikrarını artırabilir. Bu, enerji fiyatlarının dalgalanmalarını azaltabilir ve enerji ticaretini daha güvenilir hale getirebilir.
- Rüzgar enerjisi tahminleri, yeni rüzgar enerjisi projelerinin planlanması ve finansmanının sağlanmasında önemli bir rol oynar. Yatırımcılar, gelecekteki enerji üretimi potansiyelini daha iyi anlayarak kararlarını daha bilinçli bir şekilde alabilirler.

Sonuç olarak, rüzgar enerjisi tahminleri, enerji sektörünün verimliliğini artırırken enerji üretimi, dağıtım ve tüketimini daha sürdürülebilir bir şekilde yönetmeye yardımcı olur (Akmador ve ark., 2009).

Rüzgar enerjisi üretiminde, çeşitli problemlerin çözümü için farklı tahmin süreleri ve yöntemleri farklı amaçlarla kullanılmaktadır (Smith ve ark., 2009). Rüzgar enerjisi alanında gerçekleştirilen tahmin çalışmaları temelde iki ana kategoride toplanabilir. İlk kategori, rüzgar enerjisi potansiyelinin hesaplanmasıyla ilgilidir. İkinci kategori ise gelecekteki rüzgar hızını zaman içinde tahmin etmeyle ilgilidir. Bu iki alanda da geniş bir literatür bulunmaktadır (Aoife ve ark., 2012; Türkyılmaz, 1997).

Enerji Piyasası Düzenleme Kurulu (EPDK), Türkiye Elektrik İletim A.Ş. (TEİAŞ) tarafından elektrik iletim sistemlerinin etkili ve verimli bir şekilde yönetilmesini sağlamak amacıyla rüzgar santrallerinden saatlik elektrik üretim tahminlerini iletmelerini zorunlu kılmıştır. Rüzgar, doğrusal olmayan ve durağan olmayan bir zaman serisi olduğu için, rüzgar enerjisini kullanarak üretim yapan şirketler, elektrik enerjisi üretim miktarlarını ölçümleyebilmek için güvenilir 24-48 saatlik rüzgar hızı tahminlerine

gereksinim duymaktadır (Dündar ve ark., 2011). Bu alanda son zamanlarda birçok araştırma yapılmaktadır. Elektrik dağıtım şirketleri ise önceden tahmin edilebilir ve güvenilir rüzgar enerji santrallerine (RES) olan ihtiyaçlarını karşılamak için çaba göstermektedirler (Köse ve ark., 2014).

Tahminlemelerde kullanılan zaman bazında sınıflandırma, birçok farklı bağlamda önemli bir rol oynar ve birçok alanda fayda sağlar. Zaman bazında sınıflandırmanın önemi ve kullanıldığı alanlardan bazıları:

- Verileri zaman dilimlerine ayırarak sınıflandırmak, verilerin daha iyi analiz edilmesine ve anlaşılmasına yardımcı olur. Trendleri, dönemsel değişiklikleri ve olayların kronolojisini belirlemenize olanak tanımaktadır.
- Zaman bazında sınıflandırma, karar verme süreçlerini destekler. Örneğin, işletmeler, finansal verileri aylık veya yıllık bazda sınıflandırarak bütçe ve stratejilerini planlayabilirler. Ayrıca, acil durum yönetimi, lojistik planlama ve üretim süreçleri gibi birçok alanda zaman sınıflandırması kullanılmaktadır.
- Zaman bazında sınıflandırma, bir organizasyonun veya sürecin performansını izlemek ve değerlendirmek için önemlidir. Bu, hedeflere ulaşma ilerlemesini takip etmek ve gerektiğinde düzeltici önlemler almak için kullanılmaktadır.
- Tarih, zamanın bir sınıflandırmasıdır. Tarih bilimi, olayları ve süreçleri kronolojik sırayla incelemek ve anlamak için zaman bazında sınıflandırmayı kullanmaktadır. Tarihçilerin geçmişi anlamalarına ve kayıtları düzenlemelerine yardımcı olmaktadır.
- Haberler, raporlar ve bilgilendirici metinler genellikle zaman sınıflandırması kullanmaktadır. Bu, okuyucuların olayların ve bilgilerin zaman çerçevesini anlamalarını kolaylaştırmaktadır.
- Bilim insanları, deneylerin sonuçlarını ve verileri genellikle belirli bir zaman dilimine göre sınıflandırır. Bu, sonuçların tekrar üretilebilirliğini ve karşılaştırılabilirliğini artırmaktadır.
- Hukuk ve tıp gibi alanlarda zaman sınıflandırması, davalarda veya hastane kayıtlarında önemlidir. Olayların ve tıbbi bilgilerin doğru bir şekilde belgelenmesi ve takip edilmesi gerekmektedir.

- Eğitim materyalleri ve öğretim programları genellikle zaman sınıflandırması kullanır. Öğrencilere belirli bir konuyu veya dersi daha iyi anlamalarına yardımcı olur.

Zaman bazında sınıflandırma, bilgi düzenlemesi, iletişim ve yönetim açısından önemli bir araçtır. İş, bilim, tarih, sağlık ve birçok diğer alanlarda verileri ve olayları daha iyi anlamak ve yönetmek için yaygın bir şekilde kullanılır.

Rüzgar hızı tahminleri zaman bazında sınıflandırılması, meteoroloji ve hava tahmini alanında önemli bir konudur. Rüzgar hızı tahmin modellerinin zamana göre sınıflandırılması, çeşitli hava olaylarını tahmin etmek ve hava koşullarını anlamak için kullanılmaktadır. Rüzgar hızı tahminleri, günlük hava koşullarının yanı sıra büyük çaplı doğal felaketlerin, kasırgaların, şiddetli fırtınaların ve sellerin önceden tahmin edilmesinde kullanılır. Bu bilgiler, halkın ve yetkililerin hava olaylarına karşı hazırlıklı olmasına yardımcı olur. Ayrıca, iklim değişikliğiyle ilgili uzun vadeli tahminler, çevresel etkileri öngörmeye ve kararlar almaya yardımcı olur. Denizcilik sektöründe, gemilerin seyir planları ve güvenli limana dönüşler için rüzgar tahminleri kritik öneme sahiptir. Havacılıkta ise rüzgar tahminleri, uçuş güzergahlarını belirlemek, iniş ve kalkış operasyonlarını planlamak ve uçuş güvenliği için gereklidir. Rüzgar hızı tahminleri, tarım sektöründe tarım ürünlerinin sulanması, hasat zamanlaması ve zararlılara karşı koruma tedbirlerinin alınması için kullanılır. Özellikle kurak bölgelerde sulama yönetimi için rüzgar hızı verileri hayati öneme sahiptir. Meteorologlar ve iklim bilimcileri için temel verilerdir. Bu veriler, hava durumu modellerinin geliştirilmesi, iklim değişikliği analizleri ve çevresel olayların incelenmesi için kullanılır. Acil durum yönetimi ve afet hazırlığı için gereklidir. Kasırgalar, yangınlar, sel ve diğer doğal felaketler sırasında rüzgar tahminleri, tahliye planları ve acil yardım operasyonlarının yönlendirilmesine yardımcı olur.

Rüzgar hızı tahminlerinin zaman bazında doğru bir şekilde sınıflandırılması, yukarıdaki alanlarda etkin ve güvenilir kararlar alınmasına ve toplumların güvenliğine katkı sağlar. Aynı zamanda, enerji üretimi ve doğal kaynak yönetimi gibi ekonomik faktörler üzerinde de önemli etkilere sahiptir. Bu nedenle, zaman bazında sınıflandırılmış doğru rüzgar tahminleri, birçok sektör ve toplum için kritik bir öneme sahiptir.

Rüzgar hızı tahminleri, gelecekteki belirli bir zamanda ve mekanda beklenen rüzgar hızını öngörme sürecidir. Bu tahminler, meteoroloji istasyonları, uydu verileri, hava balonları, radyosondalar ve bilgisayar modelleri gibi bir dizi kaynaktan elde edilen verilere dayanmaktadır.

Rüzgar hızının gelecekteki tahminlerini yapmak amacıyla zaman içinde birçok farklı model ve çalışma geliştirilmiştir. Bu modeller, farklı karakteristiklere sahiptir; örneğin, bazıları kısa vadeli tahminlerde üstün performans sergilerken, diğerleri uzun vadeli tahminler için daha uygundur. Son dönemlerde, matematiksel yöntemler ve yapay zeka alanındaki ilerlemeler, çeşitli yeni yaklaşımların geliştirilmesine olanak tanımıştır (Şahin, 2001; Sfestos, 2000).

Tahminlerin zamana göre sınıflandırılması için kullanılan süre aralıkları, çeşitli kaynaklarda farklı uzunluklarda dikkate alındığı için, bu sınıflandırmaların net ve kesin sınırlarının bulunmadığı bir husus olarak belirtilmektedir (Monteiro ve ark., 2009). Rüzgar hızı tahminleri genellikle farklı zaman aralıklarına göre sınıflandırılır.

a. Rüzgar hızının çok kısa süreli tahminleri, genellikle bir saat veya daha kısa bir süre öncesinden rüzgar hızının gelecekteki değişikliklerini öngörmek amacıyla kullanılmaktadır. Bu tahminler, özellikle rüzgar türbinlerinin aktif kontrolünü, elektrik piyasasındaki dengesizlikleri ve düzenleme faaliyetlerini yönlendirmek amacıyla kullanılmakta olup ayrıca günlük hava durumu tahminleri ve olaylarının yakın gelecekteki etkilerini anlamak için önemlidir (Cantürk, 2018). Bu tür tahminler, aynı zamanda anlık tahminler olarak da adlandırılır (Karık ve ark., 2017).

Çok kısa süreli tahminler, enerji üretimi ve dağıtımı için kritik bir rol oynar. Özellikle rüzgar enerjisi santralleri gibi yenilenebilir enerji kaynaklarının verimli bir şekilde kullanılmasını sağlamak için önemlidir. Ayrıca, elektrik piyasasının dengesini korumak ve elektrik talebine anında yanıt vermek için bu tahminlerin doğruluğu büyük bir öneme sahiptir (Karık ve ark., 2017). Bu nedenle, çok kısa süreli tahminlerin doğruluğunun artırılması, enerji sektörü ve diğer endüstriler için büyük bir avantaj sağlar. Çok kısa süreli tahminlerin temelini sayısal hava durumu modelleri oluşturur. Bu modeller, mevcut hava durumu verilerini kullanarak gelecekteki rüzgar hızını tahmin etmek için matematiksel

denklemleri ve hesaplamaları içerir. Bu modeller, atmosferin farklı katmanlarını ve etkileşimlerini simüle eder. Çok kısa süreli tahminler, sık sık güncellenir. Bu, mevcut hava koşullarındaki değişikliklere hızlı bir şekilde yanıt verilmesini sağlar. Yeni veriler alındıkça tahminler revize edilir. Çok kısa süreli tahminler, meteoroloji istasyonları, hava alanları, denizcilik operasyonları, enerji üretimi ve günlük yaşam için önemli olan birçok sektöre iletilir. Bu tahminler, halkın günlük etkinliklerini ve kararlarını planlamasına yardımcı olmaktadır (Anonim, 2022).

Çok kısa süreli tahminler, günlük yaşamın birçok yönünü etkileyen güncel hava koşullarını anlama ve yönetme açısından da hayati bir rol oynamaktadır. Özellikle acil durumlar, seyahat planlaması, enerji üretimi ve dış mekan etkinlikleri gibi alanlarda büyük önem taşımaktadır.

b. Kısa süreli tahminler, hava koşulları, enerji üretimi, elektrik piyasası yönetimi ve birçok diğer sektör için kritik bir rol oynar. Genellikle 30 dakika ile 6 saat arasındaki zaman dilimlerini kapsayan bu tahminler, birçok uygulamada kullanılır. Elektrik üreticileri, enerji üretimini ve iletimini planlamak ve optimize etmek için kısa süreli tahminlere güvenirlir. Bu tahminler, enerji tüketiminin dalgalı doğası ile başa çıkmalarına yardımcı olmaktadır.. Rüzgar enerjisi ve güneş enerjisi gibi yenilenebilir enerji kaynakları için özellikle önemlidir, çünkü bu kaynakların verimli bir şekilde kullanılabilmesi için gelecekteki enerji üretimini tahmin etmek gerekmektedir (Köse ve ark., 2014).

Elektrik piyasası, enerji talebini karşılamak ve fiyatları dengelemek için kısa süreli tahminlere dayanır. Elektrik fiyatları, bu tahminlere göre belirlenir ve enerji şirketleri, talebi karşılamak için ne kadar enerji üreteceklerini bu tahminlere dayanarak planlamaktadırlar. Güç şebekeleri, istikrarlı bir şekilde çalışması gereken karmaşık sistemlerdir. Kısa süreli tahminler, bu şebekelerin yönetiminde kritik bir rol oynar. Elektrik iletimi, frekans kontrolü ve yük dengelemesi gibi operasyonlar, tahminlere dayanarak planlanmakta ve yönlendirilmektedirler.. Hava durumu tahminleri, kısa süreli tahminlere dayalıdır. Bu tahminler, hava koşullarının yakın gelecekteki değişikliklerini öngörmek için kullanılır. Hava tahminleri, tarım, hava seyahati, acil durum yönetimi ve diğer birçok sektör için önemlidir. Büyük enerji tüketicileri ve endüstriyel tesisler, enerji

tüketimlerini planlamak ve optimize etmek için kısa süreli tahminlere başvururlar. Bu, enerji maliyetlerini azaltmanın yanı sıra enerji talebine cevap verme kapasitesini artırmaktadır (Anonim, 2022).

Kısa süreli tahminler, enerji verimliliğini artırmanın yanı sıra enerji sektörünün güvenli ve sürdürülebilir bir şekilde çalışmasına katkı sağlar. Ayrıca, hava durumu tahminleri, güvenlik operasyonları ve acil durum yönetimi gibi alanlarda da hayati bir rol oynar. Bu nedenle, bu tahminlerin doğruluğu ve geliştirilmesi, birçok sektör için stratejik bir öneme sahiptir. Rüzgar hızı, bu tahminlerde günlük hava durumu raporlarının ve hava alanı operasyonlarının planlanmasında önemlidir.

c. Orta süreli tahminler, genellikle 6 saatten başlayıp 1 güne kadar olan zaman aralığını kapsayan kritik tahminlerdir ve özellikle enerji sektörü başta olmak üzere birçok endüstri ve uygulama için vazgeçilmezdirler. Gün sonu piyasası düzenlemeleri ve enerji sistem yönetimi, enerji ticareti için aktif bir rol oynamaktadır. Bu unsurlar, geleneksel elektrik santrallerinin kullanımına dair kararlar almayı (ünite taahhüdü) ve bu santrallerin planlanmasını en iyi şekilde optimize etmeye yardımcı olabilirler. Ayrıca bu tahminler, aşağıdaki alanlarda önemli bir rol oynarlar (Cantürk, 2018).

Enerji üreticileri, enerji üretimini planlamak ve optimize etmek amacıyla orta süreli tahminlere büyük ölçüde güvenmektedirler. Bu tahminler, belirli saatlerde ne kadar enerji üretileceğini ve hangi kaynakların kullanılacağını belirlemeye yardımcı olur. Özellikle geleneksel elektrik santrallerinin (örneğin, termik santraller) işletme planlaması ve üretim programları bu tahminlere dayanmaktadır.

Enerji ticareti, enerji tüccarları ve piyasa katılımcıları için büyük bir önem taşır. Orta süreli tahminler, enerji fiyatlarını tahmin etmek, talep ve arz dengesini sağlamak, piyasa düzenlemelerini planlamak ve enerji tedarikini optimize etmek için kullanılır. Ticari kullanımda, genellikle teklifler d 'inci günün ilk saatlerinde, $(d+1)$ 'inci günü için 00:00–23:59 saatleri aralığına kadar elde edilmelidir. Elde edilen sonuçlar orta süreli tahminler olarak isimlendirilir.

Büyük endüstriyel tesisler ve işletmeler, enerji tüketimlerini planlamak ve enerji maliyetlerini optimize etmek için orta süreli tahminlere başvururlar. Bu tahminler, üretim

programları ve işletme süreçleri için enerji talebini belirlemenin yanı sıra enerji maliyetlerini azaltmaya yardımcı olur.

Sonuç olarak, orta süreli tahminler enerji sektöründe ve enerji piyasasında stratejik bir öneme sahiptir. Ayrıca, enerji tüketimini daha verimli ve sürdürülebilir bir şekilde yönetmek için temel bir araç olarak kabul edilmektedirler. Bu tahminler, daha geniş bir zaman aralığında hava koşullarını da tahmin etmek için kullanılmaktadırlar. Rüzgar hızı, bu tahminlerde hava seyahatleri, enerji üretimi ve denizcilik gibi uzun vadeli planlamalarda önemli bir rol oynamaktadır (Karık ve ark., 2017).

d. Uzun süreli tahminler, genellikle 1 günden başlayıp 1 haftaya veya daha uzun bir süre için yapılan öngörülerdir ve enerji sektörü başta olmak üzere birçok endüstri ve planlama süreci için kritik bir rol oynamaktadırlar. Bu tahminler, gelecekteki enerji talebini, üretimini ve tüketimini tahmin etmek, enerji kaynaklarının etkili bir şekilde yönetilmesini sağlamak ve enerji sistemlerinin verimli bir şekilde işletilmesini planlamak amacıyla kullanılmaktadırlar.

Özellikle rüzgar enerjisi üretimi için uzun süreli tahminler, büyük rüzgar santrallerinin verimli bir şekilde çalışmasını ve enerji şebekesine minimum maliyetle enerji sağlamak için hayati bir öneme sahiptirler (Jung ve Broadwater, 2014). Bu tahminler, rüzgar enerjisi üretimi ile enerji talebi arasındaki dengesizlikleri önceden görmek ve enerji üretimini planlamak için kullanılmaktadırlar.

Ayrıca, geleneksel elektrik üretim santralleri veya iletim hatlarının bakım planlaması da uzun süreli tahminlere dayanmaktadır. Çünkü bu tesislerin plansız bakımları, enerji kesintilerine neden olabilirler ve cezai durumlara yol açabilirler. Bu nedenle, uzun süreli tahminler, bakım programlarını planlamak ve enerji sistemlerinin sürekli ve güvenilir bir şekilde çalışmasını sağlamak için kullanılmaktadırlar (Akmandor ve ark., 2009).

Uzun süreli tahminler enerji endüstrisi ve enerji altyapısının yönetimi açısından stratejik bir öneme sahiptirler. Bu tahminler, enerji üreticilerine, dağıtıcılara ve ticaret şirketlerine enerji kaynaklarını ve sistemlerini etkili bir şekilde planlama ve yönetme yeteneği sunmaktadır. Aynı zamanda, enerji sektörünün sürdürülebilirliği ve karar alma süreçlerinin optimize edilmesine katkı sağlamaktadır. Ayrıca bu tahminler, mevsimsel tahminler ve tarım gibi alanlarda uzun vadeli planlamalar için kullanılmaktadırlar. Rüzgar

hızı, bu tahminlerde özellikle enerji üretimi ve su kaynakları yönetimi gibi uzun vadeli kararlar için kritik öneme sahiptirler.

Sonuç olarak, rüzgar hızı tahminleri, belirli bir zaman aralığına yönelik beklentileri doğru bir şekilde belirlemeye çalışmaktadırlar. Böylece tahminlemeler, farklı zaman aralıklarına sahip çok kısa vadeli, kısa vadeli, orta vadeli ve uzun vadeli tahminler olarak yapılmaktadırlar. Bu tahminler birbirleriyle ilişkilendirildiğinde uzun vadeli tahminler daha spekülasyon olabilir, çünkü atmosferik koşulların uzun vadeli tahminleri daha belirsizdir. Dolayısıyla Tahmin süresi arttıkça tahminin güvenilirliği azalabilir. Yani çok kısa vadeli tahminler, daha yakın gelecekteki rüzgar hızını daha doğru tahmin edebilirken, uzun vadeli tahminler daha belirsiz olabilir. Ayrıca, her bir tahmin süresi için farklı modellemeler, veriler ve analizler kullanılmaktadır.

Rüzgar hızı tahminleri, meteoroloji ve çevre bilimleri alanlarında önemli bir konudur ve çeşitli yöntemlerle sınıflandırılabilir. Bu sınıflandırma, rüzgar hızı tahminlerinin doğruluğu, kullanılan veri kaynakları, matematiksel modeller ve algoritmalara dayalı olarak gerçekleştirilmektedir (Dündar ve ark., 2011). Bu yöntemlerden kısaca bahsedecek olursak; gözlem tabanlı tahminler Meteoroloji istasyonlarından elde edilen rüzgar hızı ölçümlerine dayalıdır. En basit haliyle, gözleme dayalı tahminler, geçmiş verilere dayanarak istatistiksel analizlerle yapılabilir. İleri düzeydeki gözlem tabanlı tahminler, radar, lidar ve diğer uzaktan algılama teknolojilerini kullanarak daha hassas sonuçlar üretebilir. Numerik Hava Modelleri yani bilgisayar tabanlı hava modelleri, atmosferin matematiksel denklemlerini kullanarak rüzgar hızı tahminleri yapmaktadırlar. Hava modelleri, atmosferin özelliklerini çeşitli yüksekliklerde ve zamansal ölçeklerde simüle edebilmektedirler. Bu modeller, çok sayıda girdi verisi gerektirir ve genellikle süper bilgisayarlar üzerinde çalışmaktadırlar.. İstatistiksel ve Veri madenciliği teknikleri, büyük veri kümelerini analiz ederek rüzgar hızı tahminlerini geliştirmektedirler. Bu yaklaşım, özellikle uzun vadeli tahminlerde ve iklim değişikliği çalışmalarında kullanılmaktadırlar.. Makine öğrenimi ve yapay zeka teknikleri, karmaşık ilişkileri tespit etmek için kullanılmaktadırlar. Ampirik tahmin yöntemleri, geçmiş gözlemlere dayalı istatistiksel ilişkileri kullanılmaktadırlar. Bu yöntemler, bölgesel veya yerel özelliklere göre özelleştirilmektedirler.. Hibrid tahmin yöntemleri, birden fazla yöntemin birleşimi

olarak kullanılmaktadırlar. Örneğin, gözlem tabanlı verilerle sayısal model çıktılarını birleştirerek daha doğru tahminler elde edebilmektedirler.

Rüzgar hızı tahminleri için çeşitli yöntemler mevcuttur ve bu yöntemler farklı zaman aralıkları ve uygulama alanları için kullanılmaktadırlar. Fiziksel yöntemler, genellikle uzun vadeli tahminler için uygundur, ancak kısa vadeli ve anlık tahminler için istenilen doğruluk seviyesini sağlamakta zorlanabilmektedirler. Bu nedenle, rüzgar enerjisi üretimi ve şebekeye entegrasyonu gibi hızlı değişen koşullar altında rüzgar hızını daha hassas bir şekilde tahmin etmek için istatistiksel ve hibrit yöntemler tercih edilmektedirler. Böylelikle doğrusal ve doğrusal olmayan istatistiksel yöntemler, özellikle veri madenciliği, makine öğrenimi ve istatistiksel analizler gibi teknikleri kullanarak rüzgar hızı tahminlerini iyileştirmektedirler. Bu yöntemler, geçmiş verilere dayalı istatistiksel ilişkileri ve desenleri kullanarak tahminler yapmaktadırlar. Örneğin, regresyon analizi gibi doğrusal yöntemler veya yapay sinir ağları gibi doğrusal olmayan yöntemler kullanılmaktadırlar (Filik ve Filik, 2017).

Rüzgar enerjisi sektörü, doğru rüzgar hızı tahminlerine büyük önem vermektedirler, çünkü bu tahminler enerji üretimi ve dağıtımını etkilemektedirler. Bu nedenle, farklı yöntemlerin avantajları ve sınırlamaları göz önüne alınarak, uygulamanın ihtiyaçlarına uygun en iyi tahmin yöntemi seçilmelidir. Hibrit yöntemler, genellikle çoklu veri kaynaklarını ve modelleme tekniklerini birleştirdiği için karmaşık koşullar altında daha iyi performans göstermektedirler (Dündar ve ark., 2011)

Rüzgar hızı tahminleri, her bir yöntemin avantajları ve dezavantajlarına sahiptirler. Genellikle tahminin amacına, zamansal ve mekansal çözünürlüğe, veri erişimine ve hesaplama kaynaklarına bağlı olarak farklı yöntemler tercih edilmektedir.. Bu nedenle, rüzgar hızı tahminlerinin yöntemsel sınıflandırması, belirli bir uygulamanın gereksinimlerine ve hedeflerine bağlı olarak yapılmaktadırlar (Soman ve ark., 2010).

3.2.1 Naive ve Fiziksel Tahminleme Yöntemleri

Naive tahminleme yöntemi, sıklıkla "basit tahmin" olarak adlandırılmaktadır ve meteoroloji ve tahmin bilimlerinde yaygın bir uygulama olarak kullanılmaktadır. Bu yaklaşım, bir belirli bir zaman noktasındaki verinin, gelecekteki belirli bir süre sonra aynı

kalacağını varsaymaktadır. Örneğin, "t" anındaki bir rüzgar hızı değeri ile "t+Δt" anındaki rüzgar hızının aynı olacağı tahmin edilmektedir. Bu yöntem, özellikle atmosferdeki değişimlerin yavaş olduğu durumlarda ve kısa vadeli tahminlerde etkili bir yol sunmaktadır (Şenkal, 2014). Naive tahminleme yöntemi, tarih boyunca meteorologlar tarafından Sayısal Hava Tahmini (SHT) sonuçlarını değerlendirmek ve karşılaştırmak için geliştirilen ikincil bir araç olarak kullanılmışlardır. Temelde, bu yaklaşım, rüzgar hızı gibi hava koşullarını tahmin etmek için bir referans model olarak işlev görmektedir. Verinin t zamanında elde edilen bir değeri, gelecekteki zaman dilimleri için de geçerli kabul edilmektedir (Negnevitsky ve Potter, 2006).

Bu basit yöntemin etkili olmasının nedeni, atmosferdeki değişikliklerin genellikle yavaş bir şekilde meydana gelmesidir. Bu yüzden kısa vadeli tahminlerde daha karmaşık fiziksel veya istatistiksel yöntemlere kıyasla başarılı sonuçlar üretmektedir. Bu, özellikle hızlı tahminler gerektiren durumlarda önemli olmaktadır (Cantürk, 2018). Sonuç olarak, naive tahminleme yöntemi, atmosfer koşullarını tahmin etmek için kullanılan basit ancak etkili bir yaklaşımdır. İleriye dönük hava tahminleri yapılırken bu yöntem, verinin sürekli değiştiği ve güncel veri eksikliği olduğu durumlarda önemli bir araç olarak kullanılmaktadır (Özdamar, 2001).

Fiziksel yaklaşımlar, atmosferdeki değişkenleri tahmin etmek için bilimsel bir metod sunmaktadırlar (Soman ve ark., 2010). Bu metodoloji, rüzgar hızını belirlemek için ayrıntılı fiziksel parametrelerin entegrasyonunu gerektirmektedir, bunlar arasında bitki örtüsü, coğrafi yükseklik, sıcaklık, atmosfer basıncı ve çevresel türbin konumları yer almaktadır. Rüzgar hızı tahmini için kullanılan fiziksel yaklaşımlardan biri Sayısal Hava Tahmini (SHT) yöntemidir. Sayısal hava tahmini modelleri, karmaşık matematiksel denklemleri çözme amacı güder ve bu denklemlerin çözümü için giriş verilerini kullanmaktadır. Bu giriş verileri, sıcaklık, atmosfer basıncı, yüzey pürüzlülüğü ve engel konumları gibi hava koşullarını içermektedir (Şenkal, 2014). Bu yaklaşım, atmosferdeki fiziksel süreçleri ayrıntılı bir şekilde modelleyerek rüzgar hızı tahminlerini geliştirmeyi amaçlamaktadır.

Kısa dönem hava tahminleri, rüzgar hızını ve diğer meteorolojik faktörleri birkaç saat ile birkaç gün öncesinden tahmin etmek için kullanılmaktadır. Bu tahminler, özellikle

rüzgarla ilgili gelişmeleri takip etmek ve dönemin hava koşullarını anlamak için hayati öneme sahiptirler. SHT rüzgar tahmin sistemleri, rüzgar hızını tahmin etmek için karmaşık matematiksel ve meteorolojik modeller kullanmakta ve bu tahminler ulusal meteoroloji hizmetleri ile özel hava verisi sağlayıcıları tarafından sağlanan çeşitli verilere dayanmaktadır. Enerji üretimi, denizcilik, havacılık ve tarım gibi sektörler, günlük operasyonlarını etkileyen rüzgar hızını ve yönünü doğru bir şekilde tahmin etmeye ihtiyaç duymaktadırlar ve bu nedenle SHT rüzgar tahminlerine büyük önem vermektedirler (Köse ve ark., 2014).

Matematiksel hesaplamaların yüksek karmaşıklığı nedeniyle sayısal hava tahmin modellerinin süper bilgisayarlar üzerinde işlenmesi gerektiği ve bu işlem sürelerinin oldukça uzun olduğu ifade edilmektedir. Bundan dolayı, 6 saatten daha kısa süreli tahminler için yüksek maliyet ve veri toplama sorunları ortaya çıkabileceği belirtilmiş ve bu nedenle bu yöntemin özellikle orta ve uzun vadeli tahminler için daha uygulanabilir olduğu vurgulanmıştır (Chang, 2013; Wu ve Hong, 2007)

3.2.2 İstatistiksel Yaklaşım Metodları

Hava tahmini için kullanılan istatistiksel yaklaşımlar temel iki tahmin yaklaşımı zamansal yaklaşımlar ve yapay zeka tabanlı modellerdir. İstatistiksel tahmin yöntemleri, özellikle kısa süreli tahminler için yaygın olarak kullanılmaktadırlar. Bu yöntemler, geçmişte ölçülmüş hava verileri üzerinden istatistiksel analizler yaparlar ve gelecekteki hava koşullarını tahmin etmek için bu analizlerden elde edilen modelleri kullanılmaktadırlar (Potter ve Negnevitsky, 2006; Candy ve ark., 2009). Örneğin, zaman serisi analizi, regresyon analizi ve otoregresif entegre hareketli ortalama (ARIMA) gibi istatistiksel yöntemler bu kategoriye dahildir. İstatistiksel yaklaşımlar, özellikle veri toplama maliyetlerinin düşük olduğu durumlarda ve hızlı tahmin sonuçları gerektiğinde tercih edilmektedirler.

Kısa vadeli hava tahminleri, genellikle birkaç saat ila birkaç gün arasındaki zaman dilimlerini kapsamaktadırlar. Bu tahminler, günlük hava koşullarını ve özellikle rüzgar hızını tahmin etmek için önemlidirler. İstatistiksel yaklaşımlar, bu kısa süreli tahminler için özellikle uygun olarak kabul edilmektedirler. Bunun nedenleri istatistiksel modeller, karmaşıklığı daha düşük olduğu için hızlı ve kolay bir şekilde oluşturulabilirler. Veri

toplama ve işleme maliyetleri genellikle daha düşüktür. İstatistiksel modeller, verileri hızlı bir şekilde işleyebilir ve sonuçlar üretebilirler. Ancak, tahmin edilecek sürenin çok kısa olması, özellikle ani hava değişiklikleri için istatistiksel yaklaşımların sınırlamalarını ortaya koyabilmektedir (Wu ve Hong, 2007).

Zaman serisi modelleri, başka bir ifade ile istatistiksel öğrenme yöntemleri olarak da adlandırılırlar ve genellikle rüzgar hızını tahminde lineer olmayan ve yüksek boyutlu denklemler oluştururlar (Liu ve ark., 2014). İstatistiksel yöntemler, rüzgar hızı tahmini için kullanılan modeller arasında önemli bir yer tutarlar. Bu yöntemler, özellikle basit ve hızlı olduklarından dolayı doğrusal ve durağan zaman serileri için önerilmektedirler (Wang ve ark., 2015). İstatistiksel yöntemlerin bazıları şunları içermektedir:

Otoregressive (AR) Modeller: AR modelleri, geçmiş dönemlerdeki rüzgar hızını kullanarak gelecekteki değerleri tahmin etmek için kullanılmaktadır. Bir dönemin rüzgar hızı, önceki dönemlerin rüzgar hızlarına bağlı olarak tahmin edilmektedir.

Otoregressive Hareketli Ortalama (ARMA) Modelleri: ARMA modelleri, hem otoregressive hem de hareketli ortalama terimlerini içermektedir. Bu modeller, geçmiş rüzgar hızı değerlerinin yanı sıra hızlı değişimleri ve dalgalanmaları da dikkate alarak tahminler yapmaktadırlar.

Kuantil Regresyon Modeli (QR): Kuantil regresyon, tahminlerin belirli yüzdelik dilimlere göre yapılmasını sağlamaktadır. Bu, rüzgar hızının farklı quantile (yüzdelik) seviyelerini tahmin etmek için kullanışlıdır.

Kalman-Filtre Modelleri: Kalman filtresi, bir sistemin gelecekteki durumunu tahmin etmek için kullanılan bir modelleme ve tahmin tekniğidir. Rüzgar hızı tahmini için kullanıldığında, sürekli olarak güncellenen tahminler üretebilmektedir.

Bu istatistiksel yöntemler, geçmiş verileri kullanarak rüzgar hızını tahmin etmekte oldukça etkilidirler. Ancak, bu yöntemler bazı karmaşık nonlineer ilişkileri yakalamakta sınırlı olabilmektedirler (Wang ve ark., 2015).

AR (Otoregressive) modeller, zaman serilerinin analizi ve tahmini için yaygın olarak kullanılan istatistiksel modellerdir. Bu modeller, bağımlı değişkenin geçmiş dönemlerdeki değerlerinin bir fonksiyonu olarak ifade edilir ve bu sayede geçmiş verilere

dayalı tahminleryapmaktadır. Bir AR(p) modeli için denklem aşağıdaki gibi ifade edilebilir: (Şenkal, 2014).

$$x^t = a + a^2x^{(t-1)} + a^2x^{(t-2)} + a^2x^{(t-3)} + \dots + \varepsilon \quad (3.20)$$

Burada, a, sabit terimdir, a^1 ve benzer katsayılar da gecikmeli değerlerin şimdiki değerle olan ilişkisini ortaya koymaktadır. Formülde yer alan ε ise hata terimi olarak gösterilmektedir. Elde edilecek olan seri genel olarak AR(p) şeklinde betimlenir. Eğer seride şimdiki hata değerleri, gecikmeli hata değerleri tarafından etkileniyorsa bu süreç hareketli ortalama süreci olarak nitelendirilir. Hareketli ortalama sürecinde hata tahmin değeri, değişkenin tahmin değeri ile ilişkilidir. Hareketli ortalama süreci,

$$2x_t = e_t - (a_1e_{(t-1)}) - \dots, t = 1, 2, \dots, n \quad (3.21)$$

şeklinde formülize edilebilir. Ve bu seri, yaygın şekilde hareketli ortalama, MA(q) olarak tanımlanır. Geciken her hata terimi hareketli ortalama sürecinde, onun şimdiki değerini etkilemektedir. Ayrıca, eğer hata terimleri arasında da bir AR ilişkisi bulunuyorsa, bu durumda ARIMA (Otoressive Integrated Moving Average) modeli kullanılır. ARIMA modelleri, zaman serisi verilerini durağan hale getirmek için fark alma işlemi ile başlar ve ardından ARMA modeli uygulanır. Bu, zaman serilerindeki trend ve durağanlık sorunlarını ele almak için kullanılmaktadır. Yani ARIMA modeller, rüzgar hızı veya gücünün gelecekteki değerlerini tahmin etmek için zaman serilerine dayalı olarak kullanılan yaygın yöntemlerdir Candy ve ark., 2009) İşte bu modellerin bazı önemli varyasyonları şunlardı:

Mevsimsel-ARIMA (Seasonal-ARIMA) Modelleri: Mevsimsel etkilere sahip zaman serilerini modellemek için kullanılır. Bu modeller, mevsimsel dönemlerin etkilerini dikkate alır. Parçalı-ARIMA (Fractional-ARIMA) Modelleri: Bu modeller, zaman serisindeki uzun vadeli bağımlılıkları yakalamak için kullanılır ve Fraktal teorilere dayanmaktadır. ARMAX veya ARX Modelleri: Bu modeller, dışsal değişkenlerin (örneğin, rüzgar türbinlerinin hız kontrolü gibi) rüzgar hızı tahminlerine olan etkilerini değerlendirmek için kullanılmaktadır. Gri Tahminleyiciler: Gri tahminleyiciler, belirli bir

veri kümesi üzerinde tahminler yapmak için kullanılan heuristik yöntemlerdir ve daha az veriye sahip olduğunuzda kullanışlı olabilirler. Doğrusal Tahminleyiciler: Basit doğrusal regresyon modelleri, rüzgar hızı tahminleri yapmak için kullanılabilirler. Üstel Düzeltme Modelleri: Bu modeller, zaman serisindeki üstel büyüme veya azalma trendlerini modellemek için kullanılır.

Bu modeller, farklı durumlar ve veri türleri için uyarlanabilir ve rüzgar enerjisi tahminleri gibi uygulamalarda yaygın olarak kullanılırlar. Hangi modelin kullanılacağı, veri setinin özelliklerine ve tahmin gereksinimlerine bağlı olarak değişebilir (Şenkal, 2014).

Yapay Zeka Tabanlı Modeller: Yapay zeka (YZ) temelli tahmin modelleri, makine öğrenimi ve derin öğrenme tekniklerini içerir. Bu modeller, büyük miktarda veriyi analiz edebilir ve karmaşık ilişkileri tanımlamak için öğrenme yeteneklerine sahiptir. Rüzgar hızı tahminlerinde, sinir ağı tabanlı modelleme ve özellikle derin öğrenme yöntemleri kullanılarak oldukça başarılı sonuçlar elde edilebilir. Bu yaklaşım, büyük veri kaynaklarına ve hesaplama kapasitesine erişim sağlandığında yaygın olarak kullanılır. Bu nedenle, çok kısa vadeli tahminler için daha karmaşık yapay zeka tabanlı modeller daha iyi sonuçlar verebilir.

3.2.3 Ayırıştırma Tabanlı Metodlar

Ayırıştırma yöntemleri, bir zaman serisini farklı bileşenlere ayırmak ve bu bileşenleri daha iyi anlamak için kullanılan analitik tekniklerdir. Bu yöntemler, zaman serisi verilerinin içerdiği farklı örüntüleri ve yapılarıdaki değişiklikleri ortaya çıkarmak için önemlidirler. Dalga analizi ve Ampirik Mod Ayırıştırma tabanlı yöntemler, çoğunlukla kullanılan ayırıştırma yöntemleridir. Bunların yanı sıra, Mevsimsel Ayarlama Yöntemi (SAM), Değişken Mod Ayırıştırma (VMD) ve İçsel Zaman Ölçeği Ayırıştırması (ITD) şeklinde literatüründe ayırıştırma yaklaşımlarına da değinilmiştir (Zhang ve ark., 2016).

Dalga analizi, bir zaman serisini farklı frekansta ve genlikteki dalgalara ayırmak için kullanılmaktadır. Dalga Analizi, Fourier Dönüşümü veya Dalgacık Dönüşümü gibi matematiksel dönüşüm tekniklerini kullanmaktadır. Ayrıca bu yöntem, zaman serisinin içerdiği farklı periyodik örüntüleri tanımlamak için de kullanılmaktadır. Örneğin, bir deniz

seviyesi zaman serisi, günlük, mevsimsel ve yıllık dalgalara ayrıştırılabilir (Şentürk, 2013).

Dalga analizi temel bileşenler açısından incelendiğinde, frekansta ayrıştırma, bir zaman serisini farklı frekansta dalgalara ayrıştırmaktadır. Bu, zaman serisinin içindeki periyodik örüntüleri belirlemek için önemlidir. Örneğin, günlük, haftalık ve yıllık periyodik örüntüleri tanımlamak için farklı frekansta dalgalara ihtiyaç olmaktadır. Genlikte ayrıştırma, her frekansta dalga bileşeninin genliğini ve katkısını incelemeye olanak tanımaktadır. Her bileşenin zaman serisinin toplamında ne kadar etkili olduğunu anlamamıza yardımcı olmaktadır. Zaman-frekans analizi, zaman serisinin frekansta ve zamanla nasıl değiştiğini incelememizi sağlamaktadır. Bu, belirli bir frekansta ne zaman ve ne kadar süreyle önemli dalgalanmaların meydana geldiğini belirlenmesinde yardımcı olmaktadır (Deniz, 2007)..

Dalga analizinin teknik bileşenleri ve türevleri incelendiğinde fourier ve dalgacık dönüşümler olarak ele alınabilmektedir. Fourier dönüşümü, dalga analizinin en temel türevlerinden biri olan Fourier Dönüşümü, bir zaman serisini farklı frekansta sinüs ve kosinüs dalgalara ayrıştırır. Her frekans bileşeni için genlik ve faz bilgilerini sağlamaktadır. Short-Time Fourier Dönüşümü (STFT), zaman serisini küçük zaman aralıklarında Fourier Dönüşümü uygulayarak zaman-frekans analizi yapmaktadır. Zaman içinde frekans bileşenlerinin nasıl değiştiğini göstermektedir (Liu ve ark., 2013).

Dalgacık dönüşümü, hem zaman hem de frekans alanındaki zaman serilerinin çoklu çözünürlük analizi için etkili ve yaygın olarak kullanılan bir yaklaşımdır. Dalgacık yöntemleri, zaman geçişini düşük geçişli ve yüksek geçişli bir filtre kullanarak ayrıştırır. Düşük geçişli filtrenin ayrışma sonucu yaklaşık seridir, yüksek geçişli filtrenin sonucu ise detaylı seridir (Aghajan ve ark., 2016). Dalgacık Ayrıştırma (WD), Dalgacık Paket Ayrıştırma (WPD), sürekli dalgacık dönüşümü ve ayrık dalgacık dönüşümü dalgacık tabanlı ayrıştırma yöntemlerine ait ayrıştırma stratejilerindendir. WD düşük frekans bileşenini her seviyede ayrıştırır ve son olarak bir düşük frekans yaklaşık alt sınıfı ve birkaç yüksek frekans ayrıntı alt grubunu elde ederken, WPD her düşük seviyede hem düşük frekans hem de yüksek frekans bileşenini ayrıştırır ve düşük bir grup elde eder. Sürekli dalgacık dönüşümü (CWT), sürekli bir formudur ve zaman serisini sürekli zaman

ölçekleri üzerinde incelemeye olanak tanımaktadır. Ayırık dalgacık dönüşümü (DWT), dalga analizini belirli ölçeklerde ve seviyelerde gerçekleştirir. Daha düşük ve daha yüksek frekanstaki bileşenleri farklı seviyelerde ayırıştırılmaktadır (Meng ve ark., 2016).

Rüzgar zamanı serilerinin tümü ayrı seriler olduğundan, rüzgar enerjisi tahmin modellerinde kesikli dalgacıklar uyarlanmıştır. Rüzgar tahmin uygulamalarında WD veya WPD kullanma standartları yoktur. Bununla birlikte, bildirilen yayınlardan WPD genellikle öngörme modellerini WP'den daha fazla geliştirebilirken, WPD her seviyede hem düşük frekanslı hem de yüksek frekanslı serileri parçaladığı için daha fazla hesaplama kaynağına ihtiyaç duyar (Liu ve ark., 2018). Ayrıca, rüzgar tahmini araştırmalarında da yüksek ve düşük frekans standart tanımları yoktur. Mevcut rüzgar tahmin yayınlarında, yüksek ve düşük frekanslar yazarların kendileri tarafından belirlenmektedir. 10 dakikalık zaman aralığı veya 1 saatlik zaman aralığı rüzgar tahmini çalışmalarındaki örnekleme sorunu zaman aralığında belirli bir sorunun uygulanmasına bağlıdır. Her bir dalga analizi türü, belirli veri türleri ve analiz gereksinimlerine göre seçilmektedir. Özellikle zaman serisinin içerdiği periyodik örüntüleri ve değişiklikleri anlamak için güçlü araçlar sunmaktadırlar (Chen ve ark., 2011).

Her ne kadar dalgacık analizi, durağan olmayan verilerin analizinde birçok avantaja sahip olsa da, adaptif olmayan doğa gibi bazı sınırlamaları vardır ve temel dalgacık ve ayrışma seviyesinin uygulamada dikkatlice seçilmesi gerekmektedir. Adaptif EMD yöntemi Huang ve diğerleri tarafından 1990'lı yıllarda doğrusal ve durağan olmayan süreçlerin analizi için geliştirmişlerdir (Huang ve ark., 1998). Bir zaman serisinde EMD yöntemleri, farklı frekans bantlarına sahip durağan İçsel Mod Fonksiyonları (IMF) ve zaman serisinin yerel özelliklerine göre uyarlanabilir ve verimli bir şekilde ayrılmaktadır. EMD'nin etkinliği, durağan ve doğrusal olmayan zaman serileri incelemek için geniş bir uygulama yelpazesinde kanıtlanmıştır. Hala hazırda EMD'nin uygulamasında bazı sınırlamaları vardır. En önemli sorunlardan biri IMF'de benzer bir ölçek sinyalinin farklı IMF'lerde bulunduğu ya da farklı ölçeklerde bir sinyalinin olduğu anlamına gelen mod karıştırma problemidir. Ensemble Empirical Mode Decomposition (EEMD) (Wu ve ark., 2011), Complementary Ensemble Empirical Mode Decomposition (CEEMD) (Yeh ve ark., 2011) ve Complete Ensemble Empirical Mode Decomposition with Adaptive Noise (CEEMDAN) (Torres, 2011) ve benzeri yöntemler yukarıda bahsedilen mod karıştırma

problemleri çözümünde farklı EMD yöntemleri ortaya konulmuştur. EMD'nin avantajları ve dezavantajları ve üç yaygın kullanılan varyantı Çizelge 3.1'de gösterilmektedir /Ren ve ark., 2015). Son on yılda, EMD ve geliştirilmiş sürümleri, rüzgar tahminlerinde kullanılmıştır. Tipik olarak, rüzgar hızı/güç zaman serilerini düzleştirmek ve istikrarlı bir IMF bileşeni ve bir artık bileşen grubu ekleyerek rüzgar tahmin performansını artırmak için adapte edilirler. Daha sonra, her bir bileşen tahmin modeli kullanılarak ayrı ayrı tahmin edilmektedirler.

Çizelge 3. 1. Ampirik modların karşılaştırılması

METOT	AVANTAJLARI	DEZAVANTAJLARI
EMD	Uyarlanabilir	Mod karıştırma
EEMD	Uyarlanabilir, Mod karıştırma problemini çözme yeteneği, Yeniden yapılandırılmış sinyalde fazladan gürültü yok	Yeniden yapılanmış sinyalde ekstra gürültü var, Çok fazla hesaplama kaynağına ihtiyacımız var.
CEEMD	Uyarlanabilir, Mod karıştırma problemini çözme yeteneği, Yeniden yapılandırılmış sinyalde fazladan gürültü yok	Çok fazla hesaplama kaynağına ihtiyacımız var.
CEEMDAN	Uyarlanabilir, Mod karıştırma problemini çözme yeteneği, Yeniden yapılandırılmış sinyalde fazladan gürültü yok	Sıralı prosedür, paralel hesaplama ile gerçekleştirilemez.

Ayrışma bazlı hibrid modellerin farkı, hızların rüzgar hızı / güç zaman serilerinde bir arada olduğu varsayımından kaynaklanmaktadır. Her bir deseni ayrı ayrı tahmin etmek, rüzgar tahmini performansını iyileştirmenin daha basit ve uygulanabilir bir yoludur. Dalgacık tabanlı ayrıştırma yöntemlerine ve EMD tabanlı ayrıştırma yöntemlerine ek olarak, rüzgar zamanı serilerini farklı kalıplara ayırmak için başka bazı ayrıştırma algoritmaları da benimsenmiştir.

Mevsimsel Ayarlama Yöntemi (SAM), zaman serisindeki mevsimsel örüntüleri çıkarmak için kullanılır. Bu yöntem, verinin mevsimsel etkilerini analiz eder ve mevsimsel bileşenleri ortadan kaldırarak trendi ve hata bileşenini ayırır. Verinin belirli bir mevsimsel periyodu (örneğin, yıllık) aşan kısmı çıkarılır ve geride kalan bileşen trend ve hata bileşenini temsil eder. Orijinal rüzgar hızı serisi SAM kullanarak mevsimsel bileşen ve

trend bileşenine ayrıştırılabilir, ardından trend bileşen tahmin modelleri ile tahmin edilir. Nihai sonuçlar, trend bileşeninin sonuçları, mevsimsel bileşen değeri kullanılarak düzeltilerek elde edilebilir (Zhang ve ark., 2013). SAM'da, orijinal rüzgar hızı serisini mevsimsel ve trend bileşenlere ayırmanın iki yolu vardır, bunlar ekleme yöntemi ve çarpma yöntemidir. Bununla birlikte, rapor edilen literatürlerde hangi yöntemin kullanılması gerektiğine nasıl karar verileceği konusunda kanıtlanmış bir teorik yöntem yoktur (Wang ve ark., 2015; Prema ve ark., 2015).

Değişken Mod Ayrıştırma (VMD) orijinal zaman serisini ortaya koyarken tanımlı aralıklarda özelliklere sahip birkaç moda parçalayan yeni bir ayrıştırma algoritmasıdır. Zaman serisini farklı frekansta ve genlikteki modlara ayırmak için kullanılmakta olup bunun içinse ayrıştırma işleminde bir optimizasyon problemini çözmeye dayalı bir matematiksel yöntemler içermektedir. VMD, özellikle non-stationary (durağan olmayan) zaman serilerini analiz etmek için uygundur. Özelleştirilmiş bir Euler-Lagrange denkleminin çözülmesi ile uygulanmaktadır. Bazı yayınlarda rüzgâr hızı/güç tahminine yönelik VMD algoritmasını dahil edildiği bildirilmiştir. Ulaşılan sonuçlara göre, tahmin modellerinde VMD'nin WD ve EMD yöntemleriyle kıyasla herhangi biriyle birleştirilirken daha iyi performans sunduğunu göstermiştir (Abdoos ve ark., 2016; Naik ve ark., 2017).

İşsel Zaman Ölçeği Ayrıştırması (ITD).bir zaman serisini birkaç Uygun Döndürme Bileşenine (PRC'ler) ve monoton bir temel sinyale ayırtıran, hesaplamalı olarak verimli bir ayrıştırma yöntemidir. Bu yöntem, veriyi farklı hızlarda değişen bileşenlere bölmektedir. ITD, zaman serisini farklı zaman ölçeklerine göre ayırtırmak için bir matematiksel işlem kullanmaktadır. Verinin farklı ölçeklerdeki dalgalarının zaman-ölçek yüzeyini analiz ederek bileşenleri belirlemektedir (Zhang ve ark., 2016).

Bu ayrıştırma yöntemleri, zaman serisi analizinde verilerin daha iyi anlaşılmasına ve örüntülerin tanımlanmasına yardımcı olmaktadır. Her biri farklı türde veri yapılarına ve analiz gereksinimlerine uygun olan bu yöntemler, özellikle öngörülebilirlik, trend analizi ve mevsimsel etkilerin çıkarılması gibi uygulamalarda kullanılmaktadır (Gou ve ark., 2011; Zhang ve ark., 2013),

3.2.4 Hibrit Modeller

Hibrit tahminleme (Hybrid forecasting), tahminlerin yapılmasında farklı yaklaşımların veya modellerin birleştirilerek kullanılması anlamına gelir. Bu, tahminlerin daha doğru, güvenilir ve genellikle daha performanslı hale getirilmesini amaçlar. Hibrit tahminleme, literatürde çeşitli yapılar ve yöntemlerle incelenmiştir (Eldering ve ark., 2017). Literatürde bildirilmiş bazı farklı yapılar şunlardır;

- **Model Birleştirme (Model Averaging):** Bu yaklaşım, farklı tahmin modellerinin sonuçlarını ağırlıklı olarak birleştirir. Örneğin, zaman serisi analizi, makine öğrenimi algoritmaları ve istatistiksel modeller gibi çeşitli tahmin yöntemleri bir araya getirilir. Her modelin tahminleri belirli bir ağırlıkla toplanır veya ortalaması alınır.
- **Model Sıralama (Model Ranking):** Bu yöntemde, farklı tahmin modelleri oluşturulur ve ardından bu modellerin her birinin performansı karşılaştırılır. En iyi performans gösteren model veya modeller daha fazla vurgulanır veya kullanılır.
- **Çıkarım ve Karar Ağaçları (Inference and Decision Trees):** Hibrit tahminleme için çıkarım ve karar ağaçları kullanılabilir. Bu yapılar, farklı tahmin modellerini veya kurallarını birleştirerek tahminlerdeki karmaşıklığı azaltır ve daha iyi sonuçlar elde eder.
- **Zaman Serisi ve Makine Öğrenimi Birleşimi:** Zaman serisi analizi, rüzgar hızı gibi sürekli değişkenlerin tahmininde yaygın olarak kullanılırken, makine öğrenimi algoritmaları da genellikle büyük veri setlerinde kullanılır. Hibrit tahminleme, bu iki yaklaşımı birleştirerek daha iyi tahminler elde etmeyi amaçlar.
- **Entegrasyon Tabanlı Yaklaşımlar:** Bu tür yaklaşımlar, farklı modelleri entegre etmek için özel tasarlanmış matematiksel veya istatistiksel yöntemleri kullanır. Örneğin, rüzgar enerjisi tahminlerinde fiziksel modellemelerle istatistiksel modellerin birleştirilmesi gibi.
- **Özelleştirilmiş Hibrit Yöntemler:** Bazı çalışmalar, belirli bir uygulama veya veri seti için özel hibrit tahminleme yöntemleri geliştirmiştir. Bu yöntemler, belirli gereksinimlere veya veri yapısına uyacak şekilde tasarlanır.

Hibrit tahminleme, farklı uygulamalarda ve veri setlerinde kullanılabilir ve tahminleme performansını artırmak için oldukça etkili bir yöntemdir. Literatürde bu konuyla ilgili birçok çalışma bulunmaktadır ve yeni hibrit tahminleme yöntemleri sürekli olarak geliştirilmektedir (Dai ve Trenberth, 2012). Bu nedenle, spesifik bir uygulama veya veri seti için en iyi hibrit tahminleme yaklaşımını seçmek için literatürü incelemek ve uygun yöntemi belirlemek önemlidir.

Hibrit modeller, tahminlerde en iyi sonuçları elde etmek için yukarıda da bahsedildiği gibi birden fazla yöntemi birleştirme prensibine dayanmaktadır. Rüzgar enerjisi tahminlerinde sıkça kullanılan bu hibrit modeller, çeşitli yaklaşımların bir araya getirilmesiyle oluşturulmaktadır. Bu modeller genellikle fiziksel ve istatistiksel yaklaşımların bir kombinasyonunu, kısa ve orta vadeli tahmin modellerinin bir araya gelmesini ve alternatif istatistiksel modellerin bir araya getirilmesini içermektedir (Wu ve Hongi 2007). İstatistiksel ve fiziksel kuramın bir araya geldiği bu modellerde, zaman serisi modelleri kısa vadeli tahminlerde yüksek başarı sağlarken, fiziksel yöntemler uzun vadeli tahminler için modelin avantajını artırmaktadır (Cantürk, 2018).

Rüzgar hızı tahminlemede kullanılan hibrit modeller, enerji sektörü için büyük öneme sahiptirler. Bu modeller, rüzgar enerjisi tesislerinin verimli bir şekilde çalışabilmesi ve enerji üretimini optimize etmek için çok değerlidirler (Cantürk, 2018). Rüzgar hızı tahminlemede kullanılan hibrit modellerin önemini anlatan bazı anahtar noktalar şunlardır;

- **Enerji Üretimini Optimizasyonu:** Rüzgar enerjisi tesisleri, rüzgar hızının doğru bir şekilde tahmin edilmesine bağlı olarak enerji üretimini planlarlar. Hibrit modeller, farklı yöntemleri birleştirerek daha doğru tahminler yapabilmektedirler. Bu, enerji üretimini en üst düzeye çıkarırken aynı zamanda enerji kaynaklarının daha verimli bir şekilde kullanılmasını sağlamaktadır.
- **Maliyet Azaltma:** Rüzgar enerjisi projeleri büyük yatırımlar gerektirmektedir. Hibrit modeller sayesinde daha iyi tahminler elde edilebilmektedir ve bu da işletme maliyetlerini azaltabilir. Daha iyi tahminler, bakım ve onarım faaliyetlerinin daha etkili bir şekilde planlanmasına yardımcı olabilmektedir.

- **Güvenilirlik:** Enerji tesisleri, enerji dağıtım ağları için güvenilir enerji üretimi sağlamak zorundadırlar. Hibrit modeller, farklı yaklaşımları bir araya getirerek daha güvenilir tahminler sunmaktadır. Bu da enerji talebini karşılamak için daha iyi bir hazırlık sağlamaktadır.
- **Rüzgar Enerjisinin Entegrasyonu:** Rüzgar enerjisi, enerji karışımının önemli bir parçası haline gelmektedir. Hibrit modeller, rüzgar enerjisi üretimini daha iyi tahmin ederek enerji ağlarına entegrasyonunu kolaylaştırmaktadır. Bu, daha fazla yenilenebilir enerji kaynağının kullanılmasını teşvik edebilir.
- **İklim Değişikliği ve Sürdürülebilirlik:** Rüzgar enerjisi, iklim değişikliği ile mücadelede ve sürdürülebilir enerji kaynaklarının kullanımında kritik bir rol oynamaktadır. Hibrit modeller, rüzgar enerjisinin daha etkili bir şekilde kullanılmasına yardımcı olarak çevresel sürdürülebilirliği desteklemektedirler.

Rüzgar hızının mütemadiyen değişken bir özelliği içermesi, tekli modellerin rüzgar hızı tahminlerinde istenilen doğruluk seviyelerine ulaşmasını zorlaştırmaktadır. Bu nedenle, bugünlerde rüzgar hızı tahminlerinde tercih edilebilir hale gelen hibrit modeller geliştirilmektedir. Bu çalışma, hibrit modele yönelmenin önemini vurgulamaktadır.

Rüzgar hızı tahmininde hibrit modeller genellikle iki temel kullanım şekli dizayn edilebilmektedirler. İlk kullanım şekli, sezgisel optimizasyon algoritmalarını içermektedir. Örnek olarak yerçekimi arama algoritması (GSA), genetik algoritma (GA), Çapraz optimizasyon algoritması (COA), parçacık sürüsü optimizasyonu (PSO) benzeri sezgisel optimizasyon algoritmaları tercih edilmektedirler. İkinci kullanım şekli ise orijinal zaman serisine geliştirilen ayrıştırma teknikleri uygulanmasıdır. Zaman serisine ait eğitim ve test veri setleri ayrı ayrı olarak ayrıştırma teknikleri kullanılarak ayrıştırılırlar. Yapılan işlemler sonucunda ana veri alt fonksiyonlarına ayrılır ve her bir alt fonksiyon ana verinin özelliklerini yansıtmaktadırlar. Ayrıca tahminlemede bu fonksiyonlar performansı üzerinde etkili olmaktadır.

Genel olarak, ayrıştırma tabanlı hibrit modeller literatürde üç farklı yapıyla bildirilmiştir. Rüzgar hızı tahminini geliştirmek için ayrıştırma tabanlı hibrit modeller, rüzgar hızı veya güç zaman serisini daha durağan özelliklere sahip alt gruplara bölmek amacıyla kullanılmaktadır. Yaygın olarak kullanılan ilk yapı, değişik modelleri kullanarak her bir

alt kümeyi tahminler. İkinci yapıda, ayrıştırılmış alt kümelerden bir taneis üzerinde tekrar ikincil bir ayrıştırma yöntemi uygulanarak bir grup daha sabit alt fonksiyona ayrıştırılmaktadır. Devamında her alt fonksiyon, ilk yapıya benzer şekilde tahmin edilmektedir (Hui-Liu ve ark., 2015; Liu ve ark., 2010). Her iki yapının son işlem basamağında her bir alt kümelerden yapılan tahminler birleştirilerek elde edilir. Bu iki yapıdan farklı olarak ayrıştırma sonucu elde edilen alt fonksiyonlardan seçilen tek bir fonksiyon ile tahmin modelinin oluşturulması üçüncü yapıyı meydana getirmektedir (Ramesh ve Arulmozhivarman, 2013; Wei ve ark., 2016).

Her ayrıştırılmış alt fonksiyon için kullanılan tahminleme yöntemleri ekseriyetle YSA SVM ve ARMA gibi farklı metotlardır. Bazı durumlarda ise her alt grubun niteliklerine göre bu metodlar arasından seçim yapılır (Tasçıkaraoğlu ve Uzunoğlu, 2014).

Qian ve ekibi (2019), yaptıkları çalışmada, literatürde 101 rüzgar tahmini ile ilgili yayını incelemiş ve bunların çoğunun ayrıştırma tabanlı hibrit yöntemlerle ilişkisini bildirmişlerdir. Bu 101 yayının 88'i, en popüler yöntemin ayrıştırma tabanlı olduğunu gösterdiğini bildirmişlerdir ancak diğer yöntemlerin de önemli olduğunu belirtmişlerdir. Ayriyeten, bazı akademik çalışmalarda bu farklı yöntemlerin karşılaştırıldığını vurgulamışlardır. Hui-Liu ve arkadaşları (2015) ise birinci ve ikinci yöntemler için bir dizi kıyaslamalı vaka çalışması yapmışlardır. Vaka çalışmalarının sonuçları, hem birinci yöntemin hem de ikinci yöntemin tekli modellere göre çok aşamalı rüzgar hızı tahminlerinde daha iyi performans sergilediğini göstermişlerdir. Ren ve ekibi (2016), Singapur'da yer alan bir sahada 10 dakika aralıklı rüzgar hızı verileri kullanarak birinci ve üçüncü yapıların performansını karşılaştırmıştır. Sonuçlar, her iki yapı türünün tekli tahmin modellerine göre daha iyi performans gösterdiğini bildirmişlerdir. Kısa vadeli tahminlerde üçüncü yapı biraz daha etkiliyken, uzun vadeli tahminlerde birinci yapıya göre daha az hesaplama kaynağı kullanıldığını göstermişlerdir.

Sonuç olarak, rüzgar hızı tahminlemesinde kullanılan hibrit modeller, enerji sektöründe verimliliği artırır, maliyetleri azaltır, güvenilirlik sağlar, rüzgar enerjisinin entegrasyonunu kolaylaştırır ve sürdürülebilir enerji üretimine katkıda bulunur. Bu nedenle, rüzgar enerjisi tesisleri için vazgeçilmez bir araçtır ve enerji endüstrisindeki rolü giderek artmaktadır.

3.3 Dünya’da ve Türkiye’de Rüzgar Enerjisi


Yenilenebilir enerji kaynaklarının, 2023 – 2025 döneminde dünya geneli elektrik üretimindeki payının önemli bir kısmını karşılaması öngörülmektedir. Bu süreçte Çin'in bu büyümedeki payının %45'i aşması, ardından da AB ülkelerinin payının %15 ile gelmesi öngörülmektedir. Doğalgaz ve kömür kaynaklı elektrik üretiminin 2022 ile 2025 yılları arasında genel olarak sabit kalması da beklenmektedir. Çin'in dünya elektrik tüketimindeki payının 2025'e kadar %33'e çıkması öngörülmektedir. Gelecek üç yıl boyunca küresel elektrik talebinin %70'ten fazlasının Çin, Hindistan ve Güneydoğu Asya tarafından kaynaklanması beklenmektedir. Gelişmekte olan ekonomilerin büyümesi, elektrik taleplerinin artmasıyla birlikte gelişirken, gelişmiş ekonomiler, ulaşım, ısınma ve endüstri sektörlerini karbonsuzlaştırmak için elektrifikasyonu teşvik etme politikalarını artırması beklenmektedir (Anonim, 2023c).

2022, Avrupa'da tarihi kuraklık koşulları nedeniyle hidroelektrik enerji üretiminin düşük olduğu bir yıl olmuştur. İtalya, 2017 – 2021 yılına göre hidroelektrik üretimi %30'dan fazla bir düşüş yaşadı, İspanya ise benzer bir durumla karşı karşıya kalmıştır. Fransa'da önceki beş sezona göre hidroelektrikte %20'lik bir düşüş kaydedilmiştir. Avrupa Birliği'nde nükleer enerji üretimi, kapasite kapanmaları ve kullanılamaması nedeniyle 2022'de 2021'e göre %17 düşüş göstermiştir. Almanya ve Belçika'daki santral kapanmaları, 2022'de kullanılabilir nükleer kapasiteyi azalttı. Aynı zamanda Fransa'da, sürekli bakım çalışmaları ve nükleer çatışmalardaki diğer zorluklar nedeniyle rekor düşük nükleer enerji üretimi yaşanmıştır. Sınırlı nükleer enerji çıkışı ve düşük hidro enerji tedariki, Avrupa'da talebi karşılamak için kapasiteler üzerinde ek baskı oluşturmıştır. Soğuk hava ve düşük hidro ve nükleer enerji üretimi döneminde bazı Avrupa ülkelerinde elektrik kesintisi riski olduğu bildirilmiştir (Anonim, 2023c).

Sıcak hava dalgaları, kuraklık ve kış fırtınaları gibi aşırı hava olayları, çeşitli bölgelerdeki güç sistemleri için zorluklar yaratmaktadır. Bu olaylar, hava durumuyla ilgili beklenmedik durumlarla daha iyi başa çıkabilmek için güç sistemlerinin esnekliğinin artırılmasının ve elektrik arz güvenliğinin arttırılmasının önemini vurgulamaktadır. Rüzgar ve güneş enerjisi de dahil olmak üzere yenilenebilir kaynaklar, 2022'de yıllık

bazda %5,7 oranında önemli bir artış göstererek küresel üretim karışımının yaklaşık %30'unu oluşturmuşlardır. Yenilenebilir enerji üretimindeki artışa Asya Pasifik bölgesi öncülük ederken, onu Amerika kıtası takip etmiştir. Yenilenebilir enerjinin küresel elektrik üretimindeki payının 2022'de %29 iken 2025'te %35'e yükselmesi öngörülmektedir. Bu artışla birlikte, kömür ve doğalgazla çalışan enerji üretiminin payı azalacak ve buna bağlı olarak da elektrik üretiminden kaynaklı emisyon oranları 2025'e kadar kademeli azalacağı öngörülmektedir. Düşük karbonlu kaynaklara yönelme, daha temiz enerji ve sürdürülebilirliğe olan bağlılığın yanı sıra ekonomik toparlanma planlarının bir parçası olarak ülkelerin yenilenebilir enerjiye yaptığı yatırımları da yansıtmaktadır. Aynı zamanda değişen hava koşullarına ve tedarik zorluklarına uyum sağlamak için güç sistemlerinde daha fazla esneklik ve dayanıklılık ihtiyacının altını çizilmektedir (Anonim, 2023c).

Şekil 3.3'te dünyada kurulu rüzgar enerjisi kapasitesinin yıllara göre değişimi verilmiştir. Şekilde görüleceği üzere son 3 yılda gerçekleşen kapasite artırımları önceki 10 yıl ile neredeyse aynıdır. Dolayısıyla rüzgar enerji kapasite kurulumları yüksek bir ivme yakalamıştır.




Şekil 3.3 Yıllara göre küresel rüzgar enerji toplam kapasite kurulumları (Anonim, 2023e)

2022 yılında yaklaşık 78 GW'lık rüzgar enerjisi kapasitesi eklenmiştir, bu son üç yıl içindeki en düşük seviye olmasına rağmen hala tarihteki en yüksek üçüncü yıl olmuştur. Zorlu bir ekonomik ortam ve kesintiye uğramış küresel tedarik zinciri ile birleşen, küresel sağlık ve enerji krizleri tarafından karmaşık hale getirilen bir ortamda başarılmıştır. Küresel olarak, 2022'de güç şebekelerine bağlanan yeni rüzgar enerjisi kapasitesi 77.6 GW olarak gerçekleşmiştir ve toplam kurulu rüzgar kapasitesini 906 GW'a çıkarmıştır. Böylece yıllık bazda %9'luk bir büyümeyi temsil etmektedir (Anonim, 2023d).

Karasal rüzgar pazarı 2022 yılında dünya genelinde 68.8 GW eklemiştir, bu eklemelerin %52'sini Çin gerçekleştirmiştir. Dünya geneli eklemeler, önceki yıla göre %5 daha düşüktür. Latin Amerika, Afrika ve Orta Doğu'daki yavaşlama bu düşüşün bir kısmından sorumlu olsa da, asıl nedenin Amerika Birleşik Devletleri'nde kurulumların azalması olmuştur. ABD rüzgar endüstrisi, yıl sonunda güçlü bir dördüncü çeyrekle tamamlanmasına rağmen, 2022'de sadece 8.6 GW'lık karasal rüzgar kapasitesi devreye alabilmişti. Bu durum tedarik zinciri kısıtlamaları ve şebeke bağlantı sorunlarından kaynaklandığı bildirilmiştir. İsveç, Finlandiya ve Polonya'da rekor kurulumlar sayesinde ve Almanya'da toparlanan kurulumlar sayesinde, Avrupa dalgalı bir 2022'de iyi bir performans sergilemiştir ve karasal rüzgar kapasitesine rekabetçi bir pazar payı olan %24 eklenmiştir. 2022 yılında Kuzey Amerika'daki karasal rüzgar eklemeleri %28 düşmüştür, Asya Pasifik ülkelerindeki yeni eklemeler sabit kalmıştır, ancak bu üç bölge toplamda 2022'de dünya genelindeki karasal rüzgar kurulumlarının %92'sini oluşturmaktadırlar (Anonim, 2023d).


Yeni eklenen 8.8 GW'lık deniz üstü rüzgar enerji kapasitesi, 2022 yılın sonunda toplam küresel deniz üstü rüzgar kapasitesini 64.3 GW'a çıkarmıştır. Yeni eklemeler, 2021'deki rekor yılından %58 daha düşük olsa da, 2022'yi deniz üstü rüzgar kurulumları için tarihteki ikinci en yüksek yıl haline getirmiştir. Çin, küresel deniz üstü rüzgar kapasitesini geliştirmeye liderlik etmeye devam etmiştir, ancak yeni kurulumları 21 GW rekor yılın ardından 5 GW'a düşüş yaşayarak yavaşlamıştır. Diğer iki pazardan APAC ülkeleri (Tayvan:1,175 MW ve Japonya:84 MW) 2022 yılında deniz üstü rüzgar kurulumları rapor ettiği görülmüştür. Avrupa ise 2022'de 2.5 GW kapasiteyi bağlamıştır. Fransa ve İtalya her biri ilk ticari deniz üstü rüzgar projelerini devreye almışlardır. 2022 yılındaki kurulum

hızının 2016'dan bu yana en düşük olmasına rağmen, Avrupa'nın toplam deniz üstü rüzgar kapasitesi 30 GW'a ulaşmıştır, bunun %46'sı Birleşik Krallık tarafından gerçekleştirilmiştir. APAC bölgesinde toplam deniz üstü rüzgar kapasitesi 2022'de 34 GW'a ulaşarak, Avrupa'nın dünyanın en büyük deniz üstü rüzgar pazarı unvanını kaybetmesine neden olmuştur (Anonim, 2023d). Şekil 3.4'te yıllara göre küresel rüzgar enerjisinin hem karada hem de denizdeki kurulum kapasitelerinin değişimleri gösterilmiştir (Anonim, 2023e).



Şekil 3.4 rüzgar enerjisinin karada ve denizde kurulumlarının yıllara göre değişimi
(Anonim, 2023e)

Rüzgar enerjisi, hem karada hem de deniz üstünde farklı coğrafi bölgelerde kullanılmaktadır ve bu tür tesislerin dağılımı, rüzgar potansiyeli, altyapı, maliyet ve çevresel faktörler gibi birçok etkene bağlı olarak değişebilmektedir. Kara üstünde rüzgar santrali imalatı için kurulan yeni tesisler 68,8 GW'a (Şekil 3.5.a) yakalamışken, global deniz üstü rüzgar santrali imalatı da 8,8 GW'ı (Şekil 3.5.b) yakalamıştır.



Şekil 3.5. a) 2022 yılı Karasal kapasiteler

b) 2022 yılı Deniz üstünde kapasiteler


Bildirilen istatistiklere göre, özellikle rüzgar enerjisi önderliğinde, yenilenebilir enerji kaynakları elektrik üretiminde daha fazla tercih edilmektedir. Dünya genelinde, hidroelektrik enerji yerine rüzgar enerjisi sistemlerinin kullanımına yönelik adımlar atılmaktadır. Bu nedenle, gelecek dönemde yapılacak çalışmalarla maliyetler hızlı bir şekilde azaltılacak ve modern yenilenebilir kaynak olarak kabul edilen rüzgar enerjisiyle elektrik üretimi daha da popüler olacaktır (Karagöl ve Kavaz, 2017).

Arzının güvenli ve ekonomik olmasını sağlama ve iklim hedeflerini karşılama gibi eşsiz iki zorluğun etkisiyle, rüzgar enerjisi geliştirilmesi her zamankinden daha hızlı bir büyümenin sıradışı bir yeni aşamasına itilmiştir. Zorlu bir yılın ardından, küresel rüzgar pazarı 2025'te geri dönmeye ve 100 GW'ı aşmayı hedeflemektedir

Rüzgar enerjisi, dünya genelinde enerji ihtiyacını karşılamamanın sürdürülebilir ve çevre dostu bir yolunu temsil ederken, Türkiye gibi enerji talebinin hızla arttığı ülkelerde de önemli bir rol oynamaktadır. Rüzgar enerjisi, doğal rüzgar hareketlerini elektrik enerjisine dönüştürme yeteneği sayesinde, temiz ve yenilenebilir bir kaynak olarak dikkat çekmektedir. Bu kaynağın dünya çapında ve özellikle Türkiye'de kullanımı, enerji sektörünün dönüşümünde kritik bir etken haline gelmektedir.

Türkiye elektrik enerjisi tüketimi 2022 yılında bir önceki yıla göre %0,5 oranında azalarak 331,1 TWh, elektrik üretimi ise bir önceki yıla göre %1,9 azalarak 328,3 TWh


olarak gerekleşmiştir. Şekil 3.5’da elektrik üretimi 2022 yılı kaynak bazlı dağılımı gösterilmiştir (Anonim, 2023a). Türkiye Ulusal Enerji Planı çalışmasının sonuçlarına göre elektrik tüketiminin 2025 yılında 380,2 TWh, 2030 yılında 455,3 TWh, 2035 yılında ise 510,5 TWh seviyesine ulaşması beklenmektedir (Anonim, 2023a).



Şekil 3.6. 2022 yılı kaynak bazlı elektrik üretimi (Anonim, 2023a)

2022 yılında elektrik üretimimizin, %34,6’sı kömürden, %22,9’u doğal gazdan, %20,3’ü hidrolik enerjiden, %10,6’sı rüzgardan, %5,1’i güneşten, %3,4’ü jeotermal enerjiden ve %3’ü diğer kaynaklardan elde edilmiştir. 2023 yılı Ağustos ayı sonu itibarıyla ülkemiz kurulu gücü 105.417 MW’a ulaşmıştır (Anonim, 2023a).

2023 yılı Ağustos ayı sonu itibarıyla kurulu gücümüzün kaynaklara göre dağılımı şekil 3.7’de gösterildiği gibi %30’u hidrolik enerji, %24,1’i doğal gaz, %20,7’si kömür, %11’i rüzgâr, %10,1’i güneş, %1,6’sı jeotermal ve %2,6’sı ise diğer kaynaklar şeklindedir.



Şekil 3.7. 2023 yılı Ağustos ayı itibarıyla kurulu gücümüz (Anonim, 2023a)

Ayrıca Ülkemizde elektrik enerjisi üretim santrali sayısı, 2023 yılı Ağustos ayı sonu itibarıyla 12.426'ya (Lisanssız santraller dâhil) yükselmiştir. Mevcut santrallerin 752 adedi hidroelektrik, 68 adedi kömür, 363 adedi rüzgâr, 63 adedi jeotermal, 344 adedi doğal gaz, 10.344 adedi güneş, 492 adedi ise diğer kaynaklı santrallerdir (Anonim, 2023b).

Türkiye'de yenilenebilir enerji kaynaklarının kullanımını ve enerjide dışa bağımlılığın azaltılmasını teşvik etmek amacıyla önemli adımlar atılmıştır. Bu adımlar Türkiye'nin enerji sektöründe yenilenebilir kaynaklardan elektrik üretimini artırmayı hedeflemektedir. İlgili adımlar kanında yer alan yasaları içermekte olup bu yasalara ilişkin bazı temel bilgiler şöyledir:

- 4628 sayılı Elektrik Piyasası Kanunu: Bu kanun, Türkiye'deki elektrik piyasasını düzenlemek ve rekabeti teşvik etmek amacıyla kabul edilmiştir. Kanun, yenilenebilir enerji kaynaklarına dayalı elektrik üretimini teşvik eder ve yenilenebilir enerji kaynaklarına öncelik tanır. Ayrıca, bu kanun, elektrik üretiminde yenilenebilir enerji kaynaklarının kullanımını artırmayı hedefleyen bir dizi destek mekanizması ve düzenlemeler içermektedir.
- 5346 sayılı Yenilenebilir Enerji Kaynaklarının (YEK) Elektrik Enerjisi Üretimi Amaçlı Kullanımına İlişkin Kanun: Bu kanun, özellikle rüzgar, güneş, hidroelektrik, biyokütle ve jeotermal gibi yenilenebilir enerji kaynaklarına dayalı elektrik üretimini teşvik etmek amacıyla kabul edilmiştir. Yenilenebilir enerji üretimini teşvik etmek için özel destek mekanizmaları sunar ve yenilenebilir enerji kaynaklarına dayalı projelerin geliştirilmesini kolaylaştırır.

Bu yasalar, Türkiye'nin enerji üretimini çevre dostu ve sürdürülebilir bir şekilde artırmayı, enerji dışa bağımlılığını azaltmayı ve enerji sektöründe yenilenebilir enerji kaynaklarını daha fazla kullanmayı amaçlayan önemli adımlardır. Bu politikalar, hem enerji güvenliğini artırmak hem de çevresel sürdürülebilirliği desteklemek amacıyla uygulanmaktadır (Anonim,2023b)..


4. MATERYAL VE YÖNTEM

Bu tez çalışmasında rüzgar hızını doğru ve güvenilir bir şekilde tahmin etmek için bünyesinde 3 temel bölümü barındıran yenilikçi adaptif bir tahminleme modeli (NAEM) (ICEEMDAN-CWT-CLAHE-PSO-CNN) geliştirilmiştir (Ek-1). Bu modelin bölümlerinden ilki veri çıkarma bölümüdür. Bu bölümde 4 yıllık gerçek zamanlı ölçüm yapılan rüzgar hızı verileri her hafta için ayrı ayrı gruplandırılır. Ve her haftaya karşılık gelen bu verilerin ortalaması alınarak ilgili hafta için bir veri seti oluşturulur. Örneğin; ilk olarak 2017-2020 yıllarının Ocak ayının ilk haftalarına ait veriler gruplandırılır. Gruplandırılan bu verilerin de kendi içerisinde ortalamaları alınarak Ocak ayının ilk haftası için bir veri seti oluşturulmuş olur. Bu tüm ayların tüm haftaları için ayrı ayrı uygulanır. Modelin 2. bölümü veri ön işleme bölümüdür. Burası tezimin en çok odaklanıldığı bölümüdür. Özellikle rüzgar tahminlemesi işleminde kullanılan veriler gerçek zamanlı izleme verileri, geçmiş veriler, SHT verileri ve coğrafi veriler olmak üzere kategorize edilebilirler. Bu durum yapılan tahminleme işleminin doğruluğunu büyük ölçüde etkiler ve değiştirir. Bu nedenle tez çalışmasının bu bölümünde tahminleme işlemindeki tutarlılığın ve doğruluğun artırılması için Uyarlanabilir gürültü ile geliştirilmiş tam topluluk ampirik mod ayrışımı (Improved complete ensemble empirical mode decomposition with adaptive noise, ICEEMDAN), sürekli dalgacık dönüşümü (continuous wavelet transform, CWT) ve kontrast sınırlı uyarlanabilir histogram eşitleme (contrast limited adaptive histogram equalization, CLAHE) birlikte kullanıldığı yeni bir veri ön işleme yaklaşımı sunulmuştur. CNN yapısında tek boyutlu veriler girdi olarak kullanılabildiği gibi 2 veya 3 boyutlu video ve görüntü verileri de kullanılmaktadır (Huang ve Kuo, 2019). Bu çalışmada 3 boyutlu görüntü verileri oluşturulurdu ve bu veriler oluşturulurken non-lineer zaman serilerinin görüntülerinin oluşturulmasında geleneksel ve yaygın olarak kullanılan data matris dönüşümündeki klasik örnekleme yöntemine alternatif bir yaklaşım sunulmuştur. ICEEMDAN ile ayrıklaştırılan non-lineer zaman serisine ait içsel mod fonksiyonları (IMFs) birleştirilerek yeni bir matris formu elde edildi. Daha sonra bu matris dizisi CWT yöntemi ile görüntü verisine dönüştürülmüştür. Modelin son bölümü olan tahminleme bölümünde ise diğer iki bölümü birleştiren ve parçacık sürü optimizasyonu (PSO) ile optimize edilen bir CNN yapısı sunulmuştur. Önerilen NAEM ile yaygın olarak kullanılan diğer derin öğrenme yöntemleri ile (CNN-

RNN, GRU, LSTM) karşılaştırıldığında elde edilen sonuçların daha doğru ve tutarlı olduğu görülmüştür. Tez çalışmasında sunulan yenilikçi adaptif tahminleme yönteminin içerdiği konular ve buralarda kullanılan bazı metod ve yaklaşımlar aşağıda detaylı bir şekilde okuyucunun bilgi ve istifadesine sunulmaktadır.

4.1 Veri Çıkarma Bölümü

Tez çalışmamızda gerçek zamanlı rüzgar hızı ölçüm verileri kullanılmıştır. Bunun için Tokat Gaziosmanpaşa Üniversitesi kampüsünde latitude (enlem) (N 40°19'58.73") and longitude (boylam) (E 36°29'0.28") üzerinde konumlandırılmış olan ölçüm istasyonu kullanılmıştır. Ölçüm istasyonunu oluşturan iki temel bileşen olan ölçüm direği ve güç kutusu (power box) Şekil 4.1'de gösterilmektedir. Ölçüm direği üzerine sabitlemiş 2 adet rüzgar hızının ölçüldüğü anemometre ilaveten 1 adet rüzgar yönünü ölçen rüzgar yönünü ölçen sensör bulunmaktadır. Ölçüm direğinin toplam yüksekliği 12 metre olup anemometrelerden biri 12. metreye diğeri ise 10. metreye yerleştirilmiştir. Ölçümlerde Thies Clima'nın birinci sınıf rüzgar yön vericisi ve birinci sınıf gelişmiş çanak anemometresi kullanılmıştır (Şekil 4.2.a ve b). Ölçüm sisteminde kullanılan sensörler hem yüksek çözünürlüğe hem de yüksek ölçüm doğruluğuna sahiptirler.



Şekil 4.1. Ölçüm direği ve güç kutusu



Şekil 4.2. a) Birinci sınıf rüzgar yönü vericisi b) Birinci sınıf gelişmiş çanak anemometre

Bununla birlikte sistem için gerekli olan güç kaynakları, basınç, sıcaklık ve nem sensörleri, veri toplamak için bir veri kaydedici olan Windcom Messtechnik güç kutusunun içerisine yerleştirilmiştir. Sistemdeki sensörlerden elde edilen veriler veri kaydedicide kullanılan yazılım ile 10 dk aralıklarla kayıt altına alınmaktadır. Ayrıca önümüzdeki dönem çalışmalarda kullanılmak üzere the top of the measurement mast AIR-X 400 W rüzgar türbininde yerleştirilmiştir.

Tez çalışmasında 2017-2020 yılları arasındaki rüzgar hızı verileri kullanıldı. Veriler öncelikle her yılın ayları içerisinde haftalık gruplara ayrıldı. Gruplandırılan haftalık veriler birleştirilerek ilgili ayın her haftası için ayrı ayrı ortalama rüzgar hızı serisi oluşturuldu. En son olarak bu serisinde ortalaması alınarak haftalar için oluşturulan görüntü verileri etiketlendi. Bu işlem her yılın her ayının tüm haftaları için ayrı ayrı gerçekleştirilmiştir.

Bu aşamaların neticesinde her ayın haftalarına ait ortalama veriler birleştirilerek (her ayın 4 haftası x 12 ay = 48 data) 48 datadan oluşan ve tahminleme işleminin gerçekleştirileceği zaman serisi elde edildi.

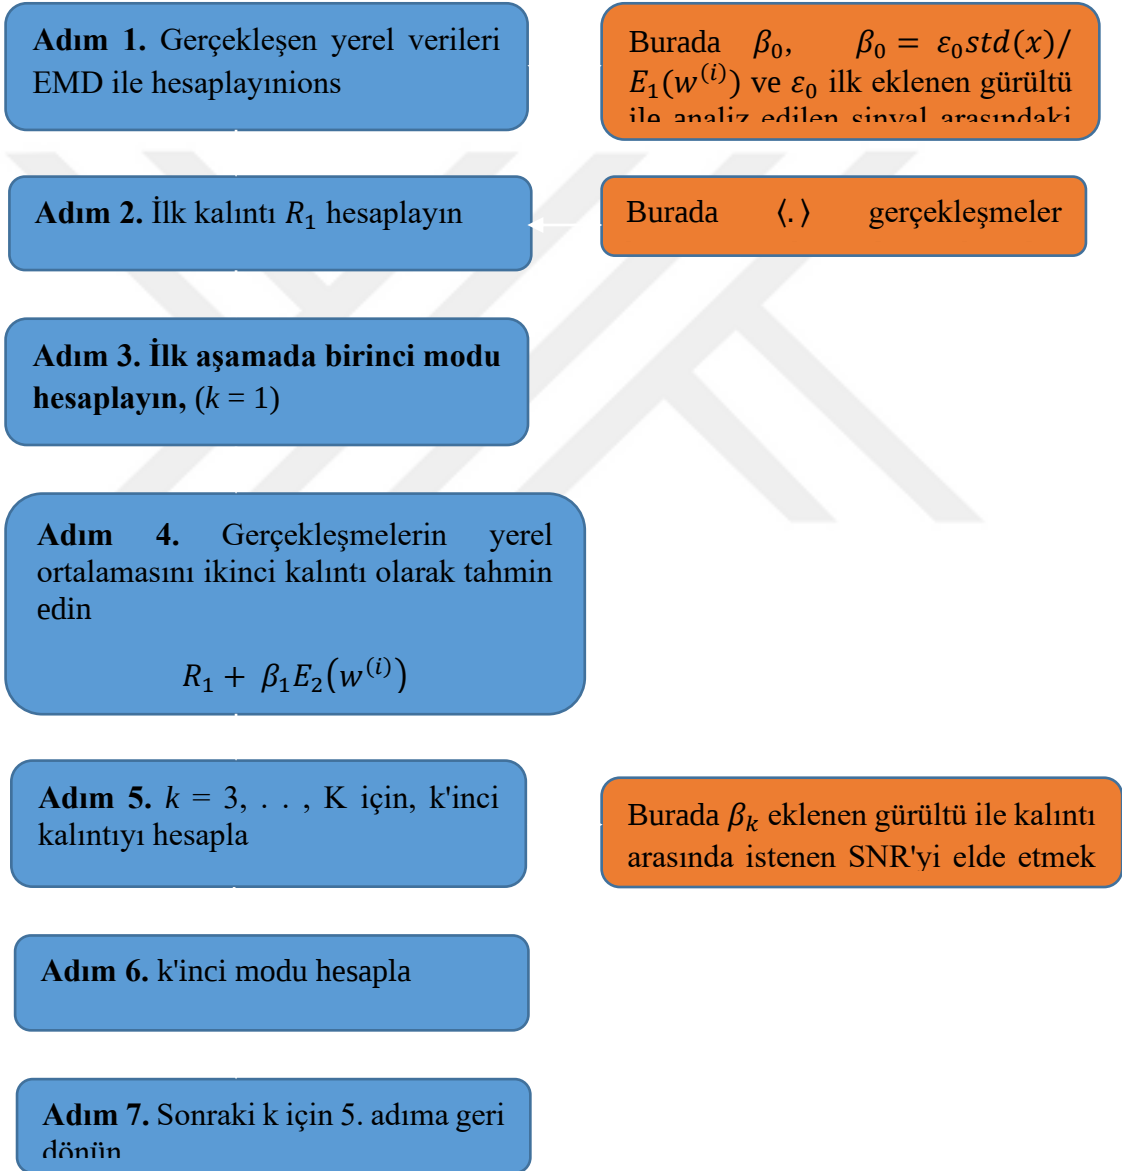
4.2 Veri Önileme Bölümü

Bu bölümde kullanılan yöntemlerin (ICEEMDAN-CWT-CLAHE) organizasyonu önerilen NAEM'in hem temelini hem de inovatif yönünü oluşturmaktadır. Kullanılan bu yöntemlere ait temel özellikler ve sağladığı faydalar aşağıda sunulan alt bölümlerde detaylandırılmıştır.

4.2.1 Uyarlanabilir Gürültüyle Tamamlanan Topluluk Ampirik Mod Ayırıştırma (ICEEMDAN)

ICEEMDAN (Improved complete ensemble empirical mode decomposition with adaptive noise), Colominas ve ark. (2014), tarafından geliştirilmiş EMD tabanlı bir ayırıştırma tekniğidir. EMD tabanlı ayırıştırma yöntemlerinde zaman serisi sinyalleri temel olarak sonlu sayıda IMF'lere ayırıştırılır. Ayırıştırma işlemi en son elde edilen

kalıntı sinyali ile tamamlanır. Her IMF farklı ölçeklerde orijinal sinyalin sahip olduğu birtakım karakteristiklere sahip sinyallerdir. ICEEMDAN diğer ayrıklaştırma teknikleri ile karşılaştırıldığında örtüşmeleri ve IMF’lerde bulunan gürültü kalıntısını minimize ettiği görülmüştür. Bu da ICEEMDAN yöntemin daha iyi bir ayrıştırma yeteneğine sahip olduğunun bir göstergesidir (Du ve ark., 2020). ICEEMDAN tekniğinin uygulama adımları Şekil 4.3’te gösterilmektedir.



Şekil 4.3. ICEEMDAN’nın uygulama aşamaları

4.2.2 Sürekli dalgacık dönüşümü (CWT)

Son yıllarda sinyal işleme alanında yapılan birçok çalışmada sinyallere ait frekans domenindeki özellikler, temelini fourier dönüşümün oluşturduğu tekniklerle incelenmektedir. Bu tekniklerden en yaygın olarak kullanılanları kayan pencere yöntemi kullanan Short-Time Fourier Transform (STFT) ve sinyallere ait frekans bileşenlerini belirleyen Fast Fourier transforms (FFT) dur. Fakat STFT de kullanılan sabit pencere uzunluğu zaman-frekans analizlerinde birtakım problemlere neden olmaktadır (Nguyen ve ark., 2013). Bu durum geçici bileşenlerin analizlerinde farklı zaman destekli bir pencere yönteminin kullanılmasını zorunlu kılmaktadır. Bu nedenle wavelet dönüşümünün sürekli versiyonu olan continuous wavelet transform (CWT) geliştirilmiştir. Böylece CWT ile bir sinyalin yüksek frekans bileşenleri için daha iyi zaman çözünürlüğüne ve düşük frekans bileşenleri için daha iyi bir frekans çözünürlüğüne sahip frekans-zaman temsili sağlanmaktadır (Mallat ve Wavelet, 1999.).

Bu çalışmada ICEEMDAN kullanılarak ayrıklaştırılan zaman serisi sinyalleri CWT kullanılarak 3D birleşik formatlı CWT resimlerine dönüştürülmüştür ve CNN için giriş veri seti oluşturulmuştur. CWT ve CNN'nin sahip olduğu avantajlar birleştirilerek elde edilen bu RGB görüntüleri ile rüzgar hızı tahmini gerçekleştirilmiştir. CWT özellikle görselleştirme noktasında oldukça etkilidir (Zheng ve ark., 2019). Zaman serilerinde CWT kullanarak analiz gerçekleştirmek için ana dalgacıktan elde edilen ve Ψ ile gösterilen bir dizi fonksiyona ihtiyaç vardır. Bu fonksiyon (Erkaymaz ve ark., 2021):

$$\Psi_{s,\tau}(t) = \frac{1}{\sqrt{|s|}} \Psi\left(\frac{t-\tau}{s}\right) \Rightarrow \sqrt{|s|} \Psi(s\omega)e^{-i\omega t} \quad (4.1)$$

Burada τ çeviri parametresi ve s ölçek parametresidir. Bununla birlikte denklemden $\frac{1}{\sqrt{|s|}}$ oranı normalizasyon faktörüdür. Ana dalgacık belirlendikten sonra $x(t)$ sinyali CWT işlemi Denklem 4.2'deki gibi uygulanır. Denklem 4.2 incelendiğinde $\Psi_{s,\tau}(t)$ 'nin kompleks eşleniği ile $x(t)$ 'nin konvolüsyon işlemine tabi tutulduğu görülmektedir.

$$X_{\Psi}(s, \tau) = \langle X(t), \Psi_{s,\tau}(t) \rangle = \int_{-\infty}^{\infty} X(t) \Psi_{s,\tau}^*(t) dt \quad (4.2)$$

Buradaı “ Ψ ” sembolü kompleks eşlenik operatörü olarak tanımlanmaktadır. Denklem 4.2’nin Fourier domainine karşılık gelen ifadesi aşağıdaki gibi düzenlenir.

$$\Psi_{s,\tau}(t) = \frac{\sqrt{|s|}}{2\pi} \int_{-\infty}^{\infty} X(\omega) \Psi^*(s\omega) e^{-i\omega t} d\omega \quad (4.3)$$

CWT için sunulan denklemler incelendiğinde en önemli faktörün ana dalgacık tipi olduğunu söyleyebiliriz. Ana dalgacık tipi ailesinde Morlet wavelet, Shannon Mexican hat and Gaussian etc. dönüşümleri yaygın olarak kullanılmaktadır. Bu çalışmada ana dalgacık olarak Morlet wavelet transformu kullanıldı. Bu transformun tercih edilmesindeki en önemli etken ise hem zaman hem de frekans alanında eşit varyansla öznelilikler çıkarabilmesidir. Böylece her iki alanda da aynı anda optimum çözünürlüğe sahip olabilmektedir. Morlet wavelet transformun matematiksel ifadesi Denklem 4’te sunulmaktadır.

$$\Psi_{s,\tau}(t) = \frac{\sqrt{|s|}}{2\pi} \int_{-\infty}^{\infty} X(\omega) \Psi^*(s\omega) e^{-i\omega t} d\omega \quad (4.4)$$

4.2.3 Kontrast sınırlı uyarlanabilir histogram eşitleme (CLAHE)

Görsel veri tabanlı derin öğrenme çalışmalarında veri artırma işlemi, görüntülerin niteliğini, çeşitliliğini ve boyutunu yapay olarak yükseltmede önemli bir role sahiptir. Bu sayede düşük performans riski azaltılarak derin öğrenme modellerine daha uygun bir şekilde adapte olunur. Ayrıca, diğer düzenleme tekniklerine kıyasla veri artırmanın, örneklerin dayanıklılığını artırarak genelleme yeteneğini iyileştirdiği ve sağladığı avantajların daha fazla olduğu gözlemlenmektedir (Buslaev ve ark., 2020; Hernandez ve König, 2018). Bu nedenle bu çalışmada CWT kullanılarak elde edilen 3D birleşik formatlı CWT resimlerine contrast limited adaptive histogram equalization tekniği kullanılarak veri artırma işlemi gerçekleştirilmiştir. Görüntü verilerinin kontrastlarında yapılan değişiklikler ile eğitim veri seti 4 kat artırılarak (36x4=144) 144 veriye çıkartılmıştır. Böylece CNN yapısı ile yapılan tahminleme işleminde veri artırımının tahminleme performansında yükselttiği gözlenmiştir.

CLAHE kontrast sınırlaması açısından değerlendirildiğinde uyarlanabilir bir histogram eşitlemesine göre birtakım farklılıklar göstermektedir. Özellikle kullanıcı tarafından tanımlanabilen bir değer noktasında kırpma işlemi gerçekleştirerek amplifikasyonu sınırlar. Kullanıcı tarafından tanımlanan bu değer klip limiti olarak adlandırılır. Bu durum ne kadar kontrast artırılması gerekliliğini de belirler (Hitam ve ark., 2013). Ayrıca piksel dağılımları genellikle Rayleigh dağılımının özellikleri sergileyecek şekilde eşlenir.

Örnek bir görüntü çok sayıda birbiri ile kesişmeyen bölgelere ayrılır. Yani görüntü $M \times N$ şeklinde bölümlendirilir. Her bölgeye ait histogram örnek olarak değerlendirilen görüntünün gri seviyelerine göre hesaplanır. Ortalama pixel sayısı (Kaur ve ark., 2021):

$$N_{avg} = \frac{(N_x \times N_y)}{N_{gr}} \quad (4.5)$$

Denklem 4.5’re gösterilen N_x ve N_y sırasıyla bölgenin x ve y boyutlarındaki piksel sayısıdır. N_{gr} ise Gri seviyelerin miktarını temsil etmektedir. Daha sonra CLAHE Denklem 4.6 kullanılarak hesaplanır.

$$N_{CL} = N_{clip} \times N_{avg} \quad (4.6)$$

Burada N_{CL} kontrast limiti ve N_{clip} ise kontrast limitin $[0,1]$ aralığında normalizasyonu ifade eder. Ayrıca N_{CL} da sınır değerdir ve bu değerin aşılması durumunda rsa pikseller kırpılır. Bu durumda eğer toplam piksel sayısı $N_{\Sigma clip}$ ile ifade edilirse her bir gri seviyeye dağıtılacak kalan ortalama pikseller Denklem 4.7 olarak sunulur.

$$N_{avggr} = \frac{N_{\Sigma clip}}{N_{gr}} \quad (4.7)$$

Histogram kırpma işleminde aşağıda verilen kural kullanılır:

$$\begin{aligned}
& \text{Else if } (H(j) + N_{avggr}) \gg N_{CL} \text{ then } H_{clip}(j) = N_{CL} \\
& \text{Else if } (H(j) + N_{avggr}) \gg N_{CL} \text{ then } H_{clip}(j) = N_{CL} \\
& \text{Else if } (H(j) + N_{avggr}) \gg N_{CL} \text{ then } H_{clip}(j) = N_{CL}
\end{aligned} \tag{4.8}$$

j^{th} gri seviyede yer alan kırpılmış ve orijinal histogram $H_{clip}(j)$ ve $H(j)$ ile ifade edilir. Kalan piksellerin dağılımı ise tüm piksellerin dağıtımı bitene kadar devam eder. Kırpılmış histogram olarak tanımlanan $P_{input}(j)$ hem transferin gerçekleştirilmesinde hem de kümülatif olasılık hesaplamasında kullanılır. Buna göre çıkış olasılık yoğunluğu Denklem 4.9 kullanılarak aşağıdaki gibi hesaplanır:

$$\text{Else if } (H(j) + N_{avggr}) \gg N_{CL} \text{ then } H_{clip}(j) = N_{CL} \tag{4.9}$$

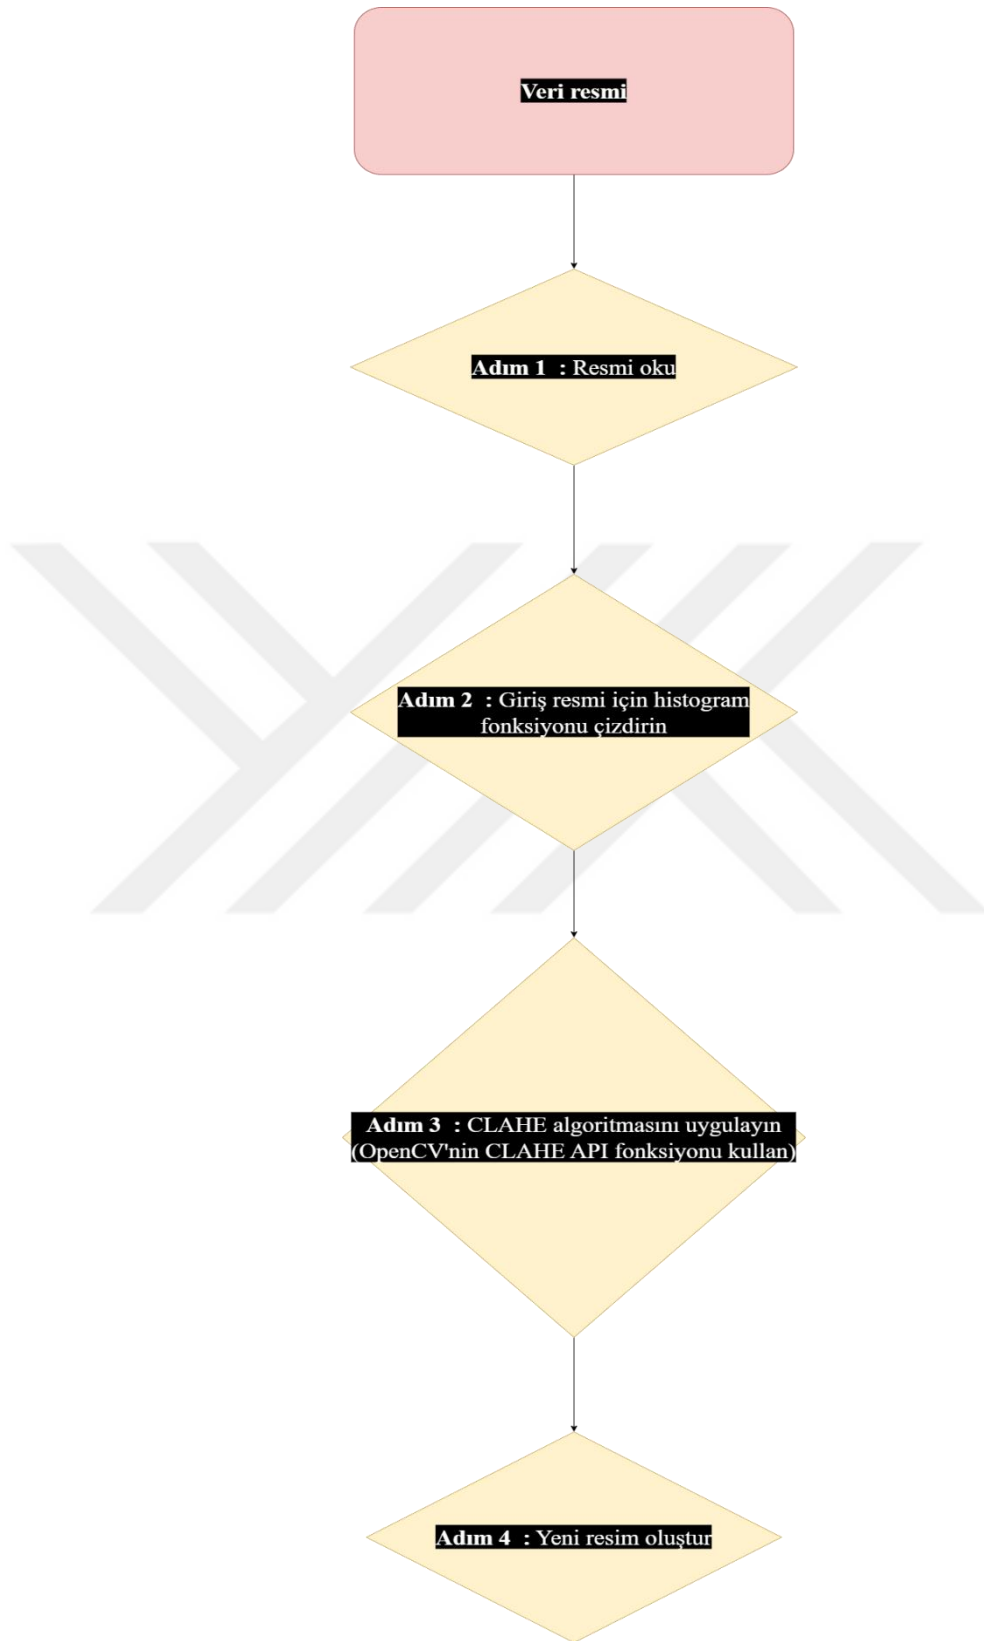
α Rayleigh dağılımının ölçek parametresini ifade ederken, y_{min} piksel değeri için belirlenen alt sınırı ifade eder. $y(j)$ ifadesi Rayleigh ileri dönüşümü olarak tanımlanır ve aşağıdaki gibi hesaplanır:

$$\text{Else if } (H(j) + N_{avggr}) \gg N_{CL} \text{ then } H_{clip}(j) = N_{CL} \tag{4.10}$$

Denklem 4.10 doğrusal kontrast kullanılarak aşağıdaki gibi yeniden şekillendirilirebilir.

$$y(j) = \frac{x(j) - x_{min}}{x_{max} - x_{min}} \tag{4.11}$$

Transfer fonksiyonunun maksimum ve minimum değerleri x_{max} and x_{min} ile tanımlanır. $x(j)$ ise transfer fonksiyonundan girdi değeri olarak değerlendirilir. Çalışmada kullanılan CLAHE için uygulanan adımlar aşağıda akış diyagramı verilen algorithmada sunulmuştur (Şekil 4.4).




Şekil 4.4. CLAHE algoritması

4.3 Tahminleme Bölümü

Tahminleme bölümü, önerilen yenilikçi adaptif modelde veri çıkarma ve ön işleme bölümlerinin birleştirilerek tahminleme işleminin gerçekleştirildiği kısımdır. Bu bölümde tahminleme işleminde kullanılan ve PSO ile optimize edilen CNN yapısı aşağıda detaylı bir şekilde açıklanmaktadır.

4.3.1 Evrişimsel sinir ağıları (CNN)

Evrişimsel sinir ağı (Convolutional neural network, CNN), görüntü analizlerinde yaygın olarak kullanılan ve güçlü veri işleme yeteneğine sahip ileri beslemeli bir sinir ağıdır. Derin öğrenme algoritmalarının bir üyesi olan CNN ilk olarak Le Cun tarafından sunulmuştur (Lecun ve ark., 1998). CNN'nin genel mimari yapısı Şekil 4.5'te gösterilmektedir. Yapı incelendiğinde 3 temel katmandan oluştuğu görülmektedir. Bu katmanlar sırasıyla Evrişim katmanı, havuzlama katmanı ve tam bağlantı katmanıdır (Ju ve ark., 2019). Evrişim ve havuzlama katmanlarında giriş bilgilerine özellik çıkarma ve dönüştürme işlemleri uygulanır. Özellikle özellik çıkarma işlemlerinde çoklu filtreler kullanılır. Evrişim ve havuzlama katmanlarında işlenen veriler tam bağlantı katmanında bütünleştirilerek çıkış katmanı üzerinden çıktı sinyalleri ile eşleştirilir (Yan ve ark., 2021). Burada özellikle regresyon ve sınıflandırma problemlerinin çözülmesinde aktivasyon fonksiyonu kullanılır. Ayrıca CNN sahip olduğu etkili çözüm yaklaşımları nedeniyle de karmaşık veri formatlarında başarıyla kullanılabilmektedir



Şekil 4.5. CNN mimarisi (Emeksiz ve Tan, 2022)

Evrişim katmanı, CNN'nin filtreler olarak bilinen birden çok evrişim çekirdeğine sahip en önemli modülüdür (Zhang ve ark., 2018). Bu katman çapraz korelasyon ve matematiksel bir evrişim operatörü kullanır. Girdi verileri üzerinde bir filtre kaydırarak girdi verilerine ait özellikler çıkartılır ve çıktı özellik haritaları bir aktivasyon fonksiyonu ile oluşturulur. Bu işlemin gerçekleştirilmesinde aşağıdaki ifade kullanılır (Sengupta ve ark., 2018):

$$x_j^l = f \left(\sum_{i \in M_j} x_i^{l-1} * k_{ij}^l + b_j^l \right) \quad (4.12)$$

Burada, aktivasyon fonksiyonu, bias, evrişim operatörü, ağırlıklar, giriş haritalarının seçimi, $(l - 1)$ 'inci katmandaki i 'inci çıkış özellik haritası ve l 'inci katmandaki j 'imci çıkış özellik haritası sunulmaktadır.

Havuzlama katmanı, evrişim işleminden sonra ağdaki parametre ve veri boyutunu azaltmak için kullanılan katmandır. Havuzlama işlemi sonucunda veri boyutunun azaltılması sinir ağının daha hızlı olmasını sağlayarak, sinir ağının hesaplama miktarını ve kullanılan bellek miktarını azaltmaktadır. Veri boyutunun azaltılması belli bir filtreleme işlemi ile gerçekleştirilmektedir. Bu filtreleme, en büyük değerlerini (maximum pooling), en küçük değerlerini (minimum pooling) veya değerlerin ortalamasını (average pooling) alarak havuzlama işlemini yapmaktadır. Bu tez çalışmasında genellikle daha başarılı sonuçlar veren maximum pooling yöntemi kullanılmıştır (Castelluccio ve ark., 2015; Hinton, 2012). Havuzlama katmanının çalışması Denklem 4.13'te gösterilmektedir.


$$x_j^l = f(\beta_j^l \text{down}(x_j^{l-1}) + b_j^l) \quad (4.13)$$

Burada “down(.)” maxpooling altörnekleme fonksiyonudur.

Son katman olan tam bağlamı katmanının girdilerini evrişim ve havuzlama katmanlarında hesaplanan özellik haritaları oluşturmaktadır. Tüm hesaplamaların tamamlanmasından sonra çıkış vektörü aşağıdaki gibi elde edilir:

$$x^l = f(K^l x^{l-1} + b^l) \quad (4.14)$$

Burada, K^l , x^{l-1} ve x^l ($l-1$)'inci katman ve l 'inci katman arasındaki ağırlıkları, giriş vektörü ve çıkış vektörünü sunulmaktadır. Bu çalışmada kullanılan CNN model parametreleri Şekil 4.6'da gösterilmektedir. Özellikle CNN'nin verimliliğinin artırılması için oluşturulan yapıda bazı öğrenme becerilerine yer verilmiştir. Bunlar; Batch normalization, ReLU ve DropOut tur.




Şekil 4.6. CNN model parametreleri (Emeksiz ve Tan, 2022)

Batch normalizasyon özellikle derin öğrenmede çok yaygın kullanılan eğitim tekniklerinden birisidir (Wang ve ark., 2018). Özellikle bu teknik ile katmanlar arasında ortaya çıkan dağılım boşluğu önlenabilir ve aynı katman içerisinde yer alan numunelerin dağılım özellikleri korunabilir. Batch normalizasyon fonksiyonu Denklem 4.15'te gösterilmektedir:

$$x'_i = (x_i - \bar{x}) / x_{var} = \frac{x_i - \frac{1}{n} \sum_{j=1}^n x_j}{\sqrt{\frac{1}{n} \sum_{j=1}^n (x_j - \bar{x})^2}} \quad (4.15)$$

CNN yapısında yaygın olarak kullanılan aktivasyon fonksiyonları Şekil 4.8'de detaylı olarak sunulmaktadır. Bu fonksiyonlar sırasıyla Sigmoid, hyperbolic tangent ve rectified linear unit (ReLU) dır. Çalışmada son yıllarda yaygın olarak tercih edilen ve hesaplama verimliliğini büyük ölçüde artıran bir uyum yeteneğine sahip olan ReLU aktivasyon fonksiyonu kullanılmıştır. Ayrıca Şekil 4.7'de yer alan aktivasyon fonksiyonlarının dışında sırasıyla identity, softsign, sinc, softplus step, linear, exponential linear unit functions etc. aktivasyon fonksiyonlarında literatürde kullanılmaktadır (Shao ve ark., 2018).



Şekil 4.7. CNN yapısında yaygın olarak kullanılan aktivasyon fonksiyonları

Birçok mühendislik uygulamalarında kullanılan veri setleri incelendiğinde içerisinde bazı anormal veriler bulunduğu görülmektedir ve bu anormal verilerin sayısı normal verilerden çok azdır. Dolayısıyla anormal verilerin aynı durumdaki normal verilere göre gerçekleşme olasılıkları daha düşüktür. Fakat anormal verilerin hem model üzerindeki etkisinin hemde oluşma olasılığının azaltılması gerekir (Goodfellow ve ark., 2016). Bu nedenle çalışmada çok basit ve etkili bir yöntem olan the dropout technology' si kullanılmıştır. Bu teknolojiye ağ yapısındaki nöronlar rastgele ve geçici olarak atılır ve each mini-batch farklı bir ağda eğitilir. Böylece toplam eğitim parametresi miktarında değişme olmaz (Goodfellow ve ark., 2016). Ayrıca dropout teknolojisinin kullanılmasının diğer bir sebebidir şudur: CNN farklı kategoride yer alan verileri ayırmada zorluk yaşar ve anormal verileri normal veriler gibi öğrenir. Bu durum modelin bozulmasına ve aşırı uyuma sebep olur. Yani eğitim setinde yüksek bir doğruluğa ulaşılır fakat test setinde ve diğer uygulamalarda doğruluk oranı düşer (Flach, 2012). Bu nedenle doğruluğun artırılması noktasında özellikle eğitim aşamasında bu yöntemden faydalanılmıştır.

4.3.2 Parçacık sürü Optimizasyonu (PSO)

1995 yılında J. Kennedy ve R.C. Eberhart tarafından geliştirilen Parçacık Sürüsü Optimizasyonu (PSO), bir popülasyon tabanlı stokastik optimizasyon tekniğidir. Bu algoritma, kuş sürülerinin davranış modellerinden ortaya çıkmıştır, nihayetinde sürü zekâsına dayanmaktadır. Sürüdeki hayvanların güvenlik ve yiyecek arayışlarında rasgele sergiledikleri hareketlerin, amaçlarına basit şekilde ulaşmalarına olanak tanıdığı gözlemlenmiştir. PSO, sürü içindeki sosyal davranış bigisinin paylaşımını temel alır. Her bir kuş parçacık olarak adlandırılır ve bu parçacıkların bir araya gelerek oluşturduğu topluluğa da sürü denir. Her parçacık, kendi pozisyonunu, sürü içindeki en iyi pozisyona doğru ayarlarını yaparken bir önceki tecrübesinden yararlanır. PSO'nun temel amacı, sürüdeki bireylerin pozisyonlarını sürünün en iyi pozisyona sahip olan bireyine yaklaştırmaktır. Bu yaklaşma süreci, rasgele gelişen bir hızla gerçekleşir ve genellikle sürü içindeki bireyler, yeni hareketlerinde bir önceki konumlarından daha iyi bir konuma gelirler. Bu süreç, belirlenen hedefe ulaşılan kadar devam eder, ve PSO'nun etkili bir optimizasyon yöntemi olarak kullanılmasını sağlar.

PSO'nun en çok bilinen optimizasyon tekniklerinden ayıran önemli fark, türev bilgisinin olmasıdır. Bu durum, birçok problemde gerekli olan kompleks işlem yükünü azaltmada etkilidir. Bunun yanı sıra, PSO'nun uygulanması, algoritmasında daha az parametre içermesi nedeniyle kullanımı oldukça basittir (Juang ve Lu, 2006).. PSO, klasik olarak bir dizi birbirinden bağımsız çözümle (parçacık sürüsü) başlatılır ve her bir iterasyonda en iyi çözümü bulunmaya çalışılır. Bütün iterasyon boyunca en iyi iki duruma göre çözümler güncellenir. Bu iki durum *pBest* ve *gBest* olarak adlandırılır. *pBest* o ana kadar aynı parçacığın ulaştığı en iyi durumu gösterir. *gBest* ise tüm parçacıklar arasında o ana kadarki en iyi durumu gösterir. Yani *pBest* bireysel, *gBest* ise global en iyi çözümdür (Cavuslu ve ark., 2010). PSO temel adımlarını içeren akış şeması Şekil 4.8'de sunulmaktadır.

Adım 1. Parçacıkları başlatın, maksimum üretim sayısını max_t , önceden tanımlayın ve bir $t=0$ sayacını başlatın;

Adım 2. Parçacıkların uygunluğunu değerlendirin;

Adım 3. Her bir parçacık için hafızasındaki en iyi $pBest_i$ seçiniz.

Adım 4. Geçmiş tüm parçacıklardan en iyi parçacığı $gBest$ seçiniz

Adım 5. Denklem 17'ye göre her bir parçacığın $\{x_1, \dots, x_i, \dots\}$ hızı $\{v_1, \dots, v_i, \dots\}$ hesaplayın.

Adım 6. Denklem 18'e göre her parçacığa $\{x_1, \dots, x_i, \dots\}$ ait pozisyonu $\{p_1, \dots, p_i, \dots\}$. Güncelleyiniz.

Adım 7. 2-6 arasındaki adımları tekrarlamak için $t < max_t$ ise t 'yi 1 artırın, aksi takdirde Adım 8'e gidin

Adım 8. $gBest$ ait pozisyonları raporlayınız.

Şekil 4.8. PSO Algoritması Akış Diyagramı

$$v_i \leftarrow \overbrace{w \cdot v_i}^{inertia} + \underbrace{c_1 \cdot r_1 \cdot (p_g - p_i)}_{global\ search} + \underbrace{c_2 \cdot r_2 \cdot (p_p - p_i)}_{local\ search} \quad (4.16)$$

$$p_i \leftarrow p_i + v_i \quad (4.17)$$

Burada, v_i , p_i , p_g , p_p , (r_1, r_2) , (c_1, c_2) , sırasıyla i 'inci parçacığın hızı, i 'inci parçacığın pozisyonu, $gBest$ pozisyonu, $pBest_i$ pozisyonu, 0 ve 1 arası rastgele sayılar, ivme sabitleri ve atalet ağırlığıdır.

Bu tez çalışmasında PSO kullanılarak CNN'deki optimize edilen hiperparametreler, filtre sayıları, mini-batch genişliği, havuzlama metodu, adım genişliği, nöron sayısı ve dropout genişliğidir. Parametrelerin ve değerlerinin belirlenmesinde Referanslardan faydalanılmıştır (Saranyaraj ve ark., 2020; Wang ve ark., 2018; Da Silva ve ark., 2018). Parametrelere ait değerler Çizelge 4.1'de gösterilmektedir. Ayrıca PSO için seçilen parametreler de Çizelge 4.2'de gösterilmektedir.

Çizelge 4.1. Optimize edilen hiperparametreler

Katmanlar	Parametre
Evrişim1 Katmanı +	Filtre sayısı:128
	Mini-batch genişliği: 14
Havuzlama Katmanı	Havuzlama metodu: Max-pooling
	Adım genişliği: 2
	Havuzlama metodu: Max-pooling
	Adım genişliği: 3
Evrişim2 Katmanı +	Filtre sayısı:128
	Mini-batch genişliği: 12
Havuzlama Katmanı	Havuzlama metodu: Max-pooling
	Adım genişliği: 2
	Havuzlama metodu: Max-pooling
	Adım genişliği: 3
Evrişim3 Katmanı	Filtre sayısı:128
	Mini-batch genişliği: 10
	Havuzlama metodu: Max-pooling
	Adım genişliği: 2
Evrişim4 Katmanı	Filtre sayısı:128
	Mini-batch genişliği: 12
	Havuzlama metodu: Max-pooling
	Adım genişliği: 2
Düzenleme	Dropout genişliği: 0.3

Çizelge 4.2. PSO parametreleri

PSO Parametreleri	Değer
Atalet ağırlığı	0.723
İvme sabitleri (c_1, c_2)	1.473
Sosyal parametre	2.0
Bilişsel parametre	2.0
İterasyon sayısı	30
Sürü genişliği	10

4.4 Çalışma Performansını Ölçme ve Değerlendirme

Çalışmada önerilen NAEM'in performansının doğru bir şekilde değerlendirilmesi için rüzgar hızı tahminlemesi alanında yapılan literatür çalışmalarında yaygın olarak kullanılan 3 temel performans metrikler (RMSE, MAPE, R^2) seçilmiştir (Jiang, 2018). Ortalama mutlak hata yüzdesi (MAPE, Mean Absolute Percent Error), ve Ortalama Karesel Hatanın Karekökü (RMSE, Root Mean Square Error) ve determinasyon katsayısı (R^2 , Determination Coefficient), seçilen bu performans metriklerinin tanımlaması ve formülleri Çizelge 4.3'te özetlenmektedir (Sun ve ark., 2018):

Çizelge 4.3. Performans metrikleri

Metrik	Tanım	Formülü
Belirleme katsayısı (R^2)	Belirleme katsayısı, X ve Y arasındaki Pearson korelasyon katsayısının karesidir.	$R^2 = \left(\frac{\sum(xy) - \frac{(\sum x)(\sum y)}{n}}{\sqrt{\left[\sum x^2 - \frac{(\sum x)^2}{n}\right] \left[\sum y^2 - \frac{(\sum y)^2}{n}\right]}} \right)^2$
Ortalama mutlak yüzde hatası (MAPE)	İstatistikte uygun bir seri değerindeki doğruluk ölçüsü.	$MAPE = \frac{1}{N} \sum_{i=1}^N \left \frac{(y_i - \hat{x}_i)}{y_i} \right $
Kök ortalama kare hatası (RMSE)	Tahmini değerlerin ortalama karesel sapmasının bir ölçüsü.	$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{x}_i)^2}$


Denklemlerdeki y_i ve $\hat{x}_i$ benzer şekilde gözlenen ve tahmin edilen rüzgar hızını, N, toplam örnek sayısını temsil etmektedir.

5. ARAŞTIRMA BULGULARI VE TARTIŞMA


Tez çalışmasında 3 vaka çalışması gerçekleştirilmiştir. İlk vaka çalışmasında önerilen NAEM kullanılarak haftalık ortalama rüzgar hızı tahminlemesi yapılmıştır. Yapılan tahminlemeler neticesinde elde edilen performans metrikleri değerlendirilmiştir. İkinci vaka çalışmasında tahminlemede kullanılacak olan verilerin data matris dönüşümünde geleneksel örnekleme yöntemi kullanıldı ve elde edilen sonuçlar NAEM ile karşılaştırıldı. Üçüncü vaka çalışmasında ise yaygın olarak kullanılan derin öğrenme modelleri (CNN-RNN, GRU, LSTM) ile tahminleme işlemi gerçekleştirilerek bir performans karşılaştırılması sunulmaktadır.

5.1 Vaka 1: NAEM kullanılarak haftalık ortalama rüzgar hızı tahmini


Verilerin toplanması ve gruplandırması ile ilgili bilgiler Bölüm 4.1’de detaylı olarak sunulmuştu. Bu nedenle elde edilen sonuçların görselleştirilmesinde Ocak ayının ilk haftası referans alınmıştır. Böylece NAEM’in uygulama aşamaları detaylı bir şekilde sunulup tüm haftalar için genel olarak değerlendirme yapılmıştır. Buradan yola çıkarak 2017-2020 yıllarındaki Ocak aylarının ilk haftalarına ait rüzgar hızı değişimleri Şekil 5.1 ile Şekil 5.4’te sunulmaktadır.




Şekil 5.1. 2017 Ocak ayının ilk haftasına ait rüzgar hızları



Şekil 5.2. 2018 Ocak ayının ilk haftasına ait rüzgar hızları




Şekil 5.3 2019 Ocak ayının ilk haftasına ait rüzgar hızları




Şekil 5.4. 2020 Ocak ayının ilk haftasına ait rüzgar hızları

Dört yılın Ocak ayının ilk haftasına ait bu veriler birleştirilerek Ocak ayı'nın ilk haftasına ait ortalama rüzgar hızlarının değişimini gösteren bir seri oluşturuldu. Oluşturulan bu rüzgar hızlarının değişimi Şekil 5.5'te gösterilmektedir. Ayrıca ilk hafta için elde edilen rüzgar hızı serisinin bu haftaya ait ortalama rüzgar hızı değerinde ($V_{\text{mean}} = 6.048$)

hesaplandı. Böylece hem tahminleme işleminin gerçekleştirileceği rüzgar hızı verileri oluşturulmuş oldu hemde her hafta için oluşturulan ortalama rüzgar hızı serileri etiketlendi (Şekil 5.6).



Şekil 5.5. Ocak aylarının ilk haftalarının ortalaması (2017-2020)



Şekil 5.6. Her bir haftaya ait ortalama rüzgar hızları


Yukarıda belirtilen işlemler yılların her ayının her haftası için gerçekleştirildi ve Şekil 5.5'te gösterilen ortalama değerlerin nümerik karşılıkları Çizelge 5.1'de ayrıca sunulmuştur.

Çizelge 5.1 Haftalık rüzgar hızı serilerinin ortalama rüzgar hızı değerleri

Aylar	Haftalar			
	1. Hafta	2. Hafta	3. Hafta	4. Hafta
Ocak	6.048	6.636	5.133	4.805
Şubat	4.581	5.321	5.487	6.748
Mart	6.693	6.532	6.041	7.081
Nisan	8.346	6.204	6.085	8.121
Mayıs	5.846	8.007	6.665	6.401
Haziran	6.344	6.081	7.082	7.121
Temmuz	7.478	8.008	8.311	5.701
Ağustos	5.878	7.979	7.532	8.021
Eylül	7.357	6.912	6.696	5.529
Ekim	6.423	5.704	4.604	4.624
Kasım	4.847	5.741	4.855	5.965
Aralık	3.932	4.686	3.843	6.022


Böylece elde edilen ortalama değerlerden yola çıkarak tahminleme işlemi için kullanılacak 48 veriden oluşan veri seti tamamlanmış oldu. Oluşturulan bu veri setinin ilk 36'sı eğitim verisi kalan 12'si test verisi olarak seçildi. Bunun yanı sıra kurgulanan ağ yapısının 2. girdisi ortalama rüzgar hızı serilerini kullanarak oluşturulan 3 boyutlu görüntü verileridir. Herbir haftaya ait elde edilen görüntüler ortalama değerler ile etiketlendi. Görüntü verilerinin oluşturulmasında kullanılan işlem basamaklarında elde edilen sonuçlar aşağıda sunulmaktadır.

Şekil 5.5'te gösterildiği gibi yılların ilk haftaları kullanılarak oluşturulan ortalama rüzgar hızı serisi önce ICEEMDAN tekniği kullanılarak ayrıştırıldı. Ayrıklaştırma işlemi neticesinde elde edilen IMFs'lerin değişimi Şekil 5.7'de gösterilmektedir.




Şekil 5.7 ICEEMDAN aracılığıyla ayrıştırılan haftalık ortalama rüzgar hızı verilerinin IMF serisi


Ocak ayının ilk haftasının ayrıklaştırılmış işarete ait verileri (IMFs+R) 9x1008'lik matrise dönüştürüldü. Bu işlem çalışmada yer alan her hafta için elde edilen farklı sayıdaki IMFs ler kullanılarak ayrı ayrı gerçekleştirildi. Her hafta için ayrıklaştırılıp matris formuna dönüştürülen verilerden CWT tekniği kullanılarak 3 boyutlu toplam 48 adet görüntü verisi elde edildi. Elde edilen bu görüntülerden rastgele seçilen haftalara ait olanlar Şekil 5.8'de gösterilmektedir.




1. Hafta



6. Hafta




25. Hafta




39. Hafta

Şekil 5.8. Rastgele seçilen haftalara ait 3 boyutlu görüntü verileri


CNN yapısının performansının artırılması için eğitim verileri setinde kullanılan görüntü verileri CLAHE tekniği ile 4 kat artırılmıştır ($36 \times 4 = 144$). Veri artırımını gerçekleştirmeden önce yapılan ve Model 1 olarak isimlendirilen tahminleme sonuçları ile veri artırımı yaptıktan sonra gerçekleştirilen tahminleme sonuçlarındaki hesaplanan hata oranlarında belirgin farklılıkların olduğu görülmektedir (Çizelge 5.2). Ocak ayının 1. haftasına ait artırılmış verilere ait görüntüler Şekil 5.9’da gösterilmektedir.




Orjinal 1. Hafta



1. Haftanın artırılmış 1. örnek görseli



1. haftanın artırılmış 2. örnek görseli




1. haftanın artırılmış 3. örnek görseli

Şekil 5.9. Ocak ayının 1. haftasına ait artırılmış verilere ait görüntüler

Tüm haftalar için veri artırma işlemleride tamamlandıktan sonra CNN yapısı için gerekli girdiler oluşturuldu ve tahminleme işlemi gerçekleştirildi. Yapılan tahminlemeler neticesinde hesaplanan performans metrikleri ve gerçek değere olan hata uzaklıklarının değişimleri Çizelge 5.2 ve Şekil 5.10’da sunulmaktadır. NAEM’de kullanılan veri artırma işlemi ile hata oranlarından RMSE ve MAPE değerlerinin sırasıyla 3% ve 5% oranında azaltmıştır.


Çizelge 5.2. NAEM ve Model 1'in performans metrikleri

Tahminlenen Modeller	RMSE	MAPE	R ²
NAEM	0.9618	0.1693	0.9654
Model 1	0.9916	0.1784	0.9632



Şekil 5.10. NAEM ve Model 1'e ait hata uzaklık değişimleri


Gerçek veriler ile NAEM ve Model1 kullanılarak yapılan tahminleme işlemi sonucu elde edilen verilerin değişimi Şekil 5.11'de gösterilmektedir.




Şekil 5.11. NAEM ve Model1 kullanılarak yapılan tahminleme sonuçlarının değişimi

5.2 Vaka 2: Veri matrisi dönüşümü kullanılarak haftalık ortalama rüzgar hızı tahmini

İkinci vaka çalışmasında non-lineer zaman serilerinin 3 boyutlu görüntülerinin oluşturulmasında geleneksel ve yaygın olarak kullanılan data matris dönüşümündeki klasik örnekleme yöntemi kullanılmıştır. Şekil 5.12 incelendiğinde 1008 data uzunluğuna sahip olan seri 168 datadan oluşan altı pencereye ayrılmıştır. Elde edilen bu pencereler gruplandırılarak 6x168'lik matrise dönüştürülmüştür. Bu işlem çalışmada yer alan her hafta için ayrı ayrı gerçekleştirildi. Her hafta için pencerelere ayrılan verilerden data matris formuna dönüştürülenler CWT tekniği kullanılarak 1. vaka çalışmasındaki gibi 3 boyutlu görüntü verilerine dönüştürüldü. Elde edilen bu görüntülerden rastgele seçilen haftalara ait olanlar Şekil 5.13'te gösterilmektedir.



Şekil 5.12. Sinyalin pencereleme yöntemi ile bölünmesi




Şekil 5.13. Rastgele seçilen haftalara ait data matris dönüşümü kullanılarak elde edilen 3 boyutlu görüntü verileri

Model 2 olarak adlandırılan data matris dönüşümü ile tüm haftalar için CNN yapısında kullanılacak girdiler oluşturulduktan sonra tahminleme işlemi gerçekleştirildi. Yapılan tahminlemeler neticesinde hesaplanan performans metrikleri ve gerçek değere olan hata uzaklıklarının değişimleri Çizelge 5.3 ve Şekil 5.14’da sunulmaktadır. NAEM ile elde edilen tahminleme sonuçlarının Model 2’ye göre daha doğru ve tutarlı olduğu görülmektedir. Bu durum önerilen modelin veri matris dönüşüm yaklaşımına iyi bir alternatif olduğunda ortaya koymaktadır.


Çizelge 5.3 NAEM ve Model 2’nin performans metrikleri

Tahminlenen Modeller	RMSE	MAPE	R ²
NAEM	0.9618	0.1693	0.9654
Model 2	1.3557	0.2411	0.9303



Şekil 5.14. NAEM ve Model 2'ye ait hata uzaklık değişimleri

Gerçek veriler ile NAEM ve Model2 kullanılarak yapılan tahminleme işlemi sonucu elde edilen verilerin değişimi Şekil 5.15'te gösterilmektedir.



Şekil 5.15. NAEM ve Model2 kullanılarak yapılan tahminleme sonuçlarının değişimi

5.3 Vaka 3: NAEM'in diğer derin öğrenme modelleriyle karşılaştırılması


Üçüncü vaka çalışmasında; karşılaştırmalı bir çalışma gerçekleştirmek ve geliştirilen NAEM'i değerlendirmek amaçlanmıştır. Bunun için tahminleme işlemleri literatürde sıklıkla kullanılan CNN-RNN, GRU ve LSTM derin öğrenme modelleri ile de gerçekleştirilmiştir. NAEM kullanılarak yapılan tahminlemelerde elde edilen RMSE ve MAPE değerlerinin karşılaştırılan derin öğrenme modellerine kıyasla daha doğru sonuçlar ve düşük hata oranları gösterdiği belirlenmiştir. Bu durum önerilen modelin

tahmin üstünlüğünü açıkça ortaya çıkarmaktadır. Elde edilen karşılaştırmalı hata oranları Çizelge 5.4'te gösterilmektedir.

Çizelge 5.4 NAEM ve CNN-RNN, GRU ve LSTM'nin performans metrikleri

Tahminlenen Modeller	RMSE	MAPE	R ²
NAEM	0.9618	0.1693	0.9654
CNN-RNN	1.2964	0.2103	0.9213
GRU	2.4773	0.4891	0.7553
LSTM	2.6427	0.5157	0.7214

Gerçek veriler ile NAEM, CNN-RNN, GRU ve LSTM kullanılarak yapılan tahminleme işlemi sonucu elde edilen verilerin değişimi Şekil 5.16'da gösterilmektedir.



Şekil 5.16. NAEM, CNN-RNN, GRU ve LSTM kullanılarak yapılan tahminleme sonuçlarının değişimi

Çizelge 5.5'te hem gerçek rüzgar hızları hem de tahmini rüzgar hızları için ölçek ve şekil parametreleri belirlenmiş ve her adım için güç yoğunlukları hesaplanmıştır. Çizelge 5.5 incelendiğinde önerilen NAEM ile gerçek rüzgar hızlarının güç yoğunluğu değerine %95,1 oranında yaklaşılmıştır. Diğer güç yoğunlukları ile karşılaştırıldığında en yakın değer NAEM'de, en uzak değer ise LSTM'de elde edilmiştir.

Çizelge 5.5. Güç yoğunluklarının karşılaştırılması


	Ölçek Parametresi	Şekil parametresi	Güç yoğunluğu (W/m ²)
P _{gerçek}	5.452	7.166	87.984
P _{NAEM}	5.498	12.081	92.301
P _{Model 1}	5.165	8.888	75.322
P _{Model 2}	6.259	8.126	133.569
P _{CNN-RNN}	6.191	10.0177	130.451
P _{GRU}	7.405	13.281	226.744
P _{LSTM}	7.613	14.08	247.230

6. SONUÇLAR

Yenilenebilir enerji kaynaklarının birçoğu doğası gereği kesintili olma özelliğine sahiptir. Bu durum birçok araştırmacıyı enerji tahmini ile ilgili araştırmalar yapmaya sevk etmiştir. Özellikle rüzgar enerjisi açısından değerlendirildiğinde doğru ve erken tahmin enerji planlaması ve güç dağıtımı açısından büyük bir öneme sahiptir. Ayrıca doğru bir tahminleme süreci rüzgar çiftliklerinin planlanmasında oluşabilecek hem teknik hemde ekonomik kayıpları da en düşük seviyeye indirecektir. Bu nedenle bu çalışmada rüzgar enerjisi rüzgar santralleri en önemli parametresi olan rüzgar hızını güvenilir ve doğru tahmin edebilmek için yenilikçi adaptif tahminleme modeli (NAEM) geliştirilmiştir. Ayırıştırma ve birleştirme teknolojilerini barındıran bu modelin veri ön işleme sürecinde ICEEMDAN-CWT-CLAHE kullanılmıştır. Özellikle veri ön işleme sürecindeki görüntü verilerinin elde edilmesinde kullanılan geleneksel veri matris dönüşümündeki örnekleme yöntemine alternatif bir yaklaşım sunmak çalışmanın en önemli yenilikçi yanını oluşturmaktadır. Çünkü ICEEMDAN kullanılarak ayırıştırılan non-linear zaman serisi sinyaline ait IMFs ile görüntü verilerinin elde edilmesi ilk defa bu çalışma gerçekleştirilmiştir. Derin öğrenme modellerinde veri artırma işleminin faydaları ve gerekliliği bir kez daha ön plana çıkmıştır. Ayrıca tahminleme sürecinde doğruluğun ve performansın artırılması için CNN parametreleri PSO ile optimize edilmiştir. Çalışmada rüzgar hızı tahminlemesinde kullanılan NAEM'in performansı yaygın olarak kullanılan diğer derin öğrenme modelleri ile karşılaştırıldı ve RMSE, MAPE ve R^2 gibi performans metrikleri kullanılarak değerlendirildi. Bununla birlikte analizlerde kurulan ölçüm istasyonunda toplanan gerçek zamanlı rüzgar hızı verileri kullanılmıştır.

Önerilen modelde elde edilen RMSE ve MAPE değerleri göreceli olarak 0,9618 ve 0,1693 olarak hesaplanmıştır. RMSE ve MAPE değerleri CNN-RNN modeliyle karşılaştırıldığında göreceli olarak %25,8 ve %19,49, GRU modeliyle %61,17, %65,38, LSTM modeliyle %63,60 ve %67,17 azalmaktadır. . Tüm modellerin karşılaştırıldığı hata kaybı değişim grafiği (Şekil 6.1) incelendiğinde NAEM'in kullanıldığı uygulamada gerçek değer ile tahmin edilen değer arasındaki fark daha azdır. Ayrıca NAEM'in kullanıldığı uygulamadaki tüm değişim eğilimi diğer uygulamalara göre 0'a yakın bir davranış göstermektedir. İyi bir modelden beklenen kayıp değerlerinin 0'a yakın

olmasıdır. Elde edilen sonuçlar değerlendirildiğinde önerilen NAEM'in dikkate alınan diğer derin öğrenme modellerine göre daha üstün olduğunu göstermektedir.



Şekil 6.1. İncelenen tüm modellerin hata kaybı grafikleri

Çalışmanın ana özellikleri ve mevcut literatüre sağladığı katkıları şu şekilde özetlenmektedir:

- (1) Rüzgar hızı tahminlemede doğruluğu ve tutarlılığı artırmak için adaptif bir derin öğrenme modeli geliştirilmiştir,
- (2) Veri ön işleme sürecinde görüntü verilerinin elde edilmesi için ayrıklaştırma tekniği kullanarak yeni bir yaklaşım sunulmuştur. Böylece orijinal rüzgar hızı serilerinde saklı olan farklı salınım karakteristikleri de ayrılabilir, ayrılabilir, ayrılabilir,
- (3) Kurulan ölçüm istasyonundan elde edilen gerçek zamanlı veriler kullanılmış ve pratik açıdan sonuçların değerlendirilmesi istatistiksel olarak gerçekleştirilmiştir,
- (4) Tahmin modelinin parametreleri optimizasyon işlemi ile sistematik olarak ayarlanmıştır
- (5) Özellikle görüntü verileri üzerinden yapılan tahminleme yöntemlerinin geliştirilmesi açısından bu çalışmanın öncü olması beklenmektedir,

(6) Ayrıca derin öğrenme modellerinde görüntü verileri ile çalışırken veri artırma işleminin gerekliliği birkez daha vurgulanmıştır,

(7) Gelecekteki bilgileri kullanarak pratik olmayan önceki ayrıştırma ve topluluk modellerinin aksine bu çalışmada eğitim ve test verileri ayrıklaştırma işlemi öncesinde bölünmüştür. Böylece modelin pratikliği sağlanmış olur.

Bununla birlikte modelin hala birtakım sınırlamaları olduğu görülmektedir. Özellikle daha büyük bir veri seti ile çalışılması ve model parametrelerinin nasıl daha fazla optimize edileceği en önemlileridir. Bu yüzden gelecekteki yapılacak çalışmalarda daha büyük veri setleri kullanarak geliştirilmiş optimizasyon algoritmaları ile rüzgar hızı ve rüzgar enerjisi tahminlemesi planlanmaktadır.

7. KAYNAKLAR

- Abdullah, M.A., Yatim, A.H., Tan, C.W., Saidur, R. 2012. A review of maximum power point tracking algo(r)thms for wind energy systems. *Renew Sustain Energy Rev.* Vol. 16(5); 3220-3237.
- Abedinia, O., Bagheri, M., Naderi, M.S., Ghadimi, N., 2020. A new combinatory approach for wind power forecasting, *2020 IEEE Systems Journal* PP(99):1-12.
- Abdoos AA. A new intelligent method based on combination of VMD and ELM for short term wind power forecasting. *Neurocomputing* 2016:111–20.
- Aggarwal, S.K., 2013. Wind power forecasting: a review of statistical models, *International Journal of Energy Science.* Vol. 3 (1); 1-10.
- Aghajani A, Kazemzadeh R, Ebrahimi A. A novel hybrid approach for predicting wind farm power production based on wavelet transform, hybrid neural networks and imperialist competitive algorithm. *Energy Convers Manage* 2016;121:232–40
- Akmandor, İ.S., Akgün, N., Altuntaşoğlu, Z.T., Malkoç, Y. ve Ayaz, F., 2009. Kısa Süreli Rüzgâr Enerjisi Tahminleri ve Tahmin Sistemleri-Rüzgâr Enerjisi Tahminleri, Tahmin Sistemleri ve Değişkenliği, Dünya Enerji Konseyi-Türk Milli Komitesi.
- Allen, D.J., Tomlin, A.S., Bale, C., Skea, A., Vosper, S. ve Gallani, M.L.2017, . A boundary layer scaling technique for estimating near-surface wind energy using numerical weather prediction and wind map data. *Appl Energy*, Volume 208, Pages 1246-1257.
- An, X., Jiang, D., Zhao, M. ve Liu, C., 2012. Short-term prediction of wind power using EMD and chaotic theory. *Communications Nonlinear Science and Numerical Simulation*, Vol. 17, 1036–1042.
- Anonim 2022 NOAA (National Oceanic and Atmospheric Administration) ve WMO (World Meteorological Organization) Rüzgar Tahminleri Kılavuzu, 2022.
- Anonim, 2023a. Enerji ve Tabii Kaynaklar Bakanlığı. <https://enerji.gov.tr/bilgi-merkezi-enerji-elektrik> (11.08.2023).
- Anonim, 2023b. Türkiye Rüzgar Enerjisi Potansiyeli. Enerji İşleri Genel Müd., <https://repa.enerji.gov.tr/REPA/>
- Anonim, 2023c. BP, Statistical Review of World Energy 2023 | 68th edition British Petroleum (BP), London, UK
- Anonim, 2023d. Küresel Rüzgar Enerji Konseyi 2023 Raporu. Küresel Rüzgar Enerji Konseyi (GWEC), https://gwec.net/wp-content/uploads/2023/03/GWR-2023_interactive.pdf (18.08.2023).
- Anonim, 2023e. Dünya Enerji Konseyi, Türk Milli Komitesi. <https://dunyaenerji.org.tr/2021-kuresel-ruzgar-raporu/> (12.08.2023)
- Aoife, M. F., Leahy, P. G., Marvuglia A. ve McKeogh E. J., 2012. Current methods and advances in forecasting of wind power generation. *Renew Energy*, Volume 37(1), 1–8.
- Bayraç, H. N., 2011. Küresel Rüzgar Enerjisi Politikaları ve Uygulamaları. *Uludağ Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, Cilt/Vol. XXX (1), 37-57.
- Bedi, J. ve Toshniwal, D., 2019. Deep learning framework to forecast electricity demand, *Appl. Energy* 238 (2019) 1312–1326.

- Bosch, J.L., Lopez, G. ve Batlles, F.J., 2007. Daily solar irradiation estimation over a mountainous area using artificial neural networks. *Renew Energy* 2008;33(7): 1622–8. <https://doi.org/10.1016/j.renene.2007.09.012>
- Buslaev, A., Iglovikov, V.I., Khvedchenya, E., Parinov A, Druzhinin, M., Kalinin, A.A., 2020 Albumentations: fast and flexible image augmentations. *Information* 11(2):125. <https://doi.org/10.3390/info11020125>.
- Cadenas, E. ve Rivera, W., 2010. Wind speed forecasting in three different regions of Mexico, using a hybrid ARIMA-ANN model. *Renew Energy*, vol. 35: 2732–2748. <https://doi.org/10.1016/j.renene.2010.04.022>.
- Candy, B., English, S. J. and Keogh, S. J., 2009. A Comparison of the impact of QuikScat and WindSat wind vector products on met office analyses and forecasts. *IEEE Transactions on Geoscience and Remote Sensing*, Vol. 47 (6), 1632-1640.
- Cantürk, S., 2018. Bir Rüzgar Çiftliğinden Yapay Sinir Ağlarıyla Kısa Süreli Elektrik Enerjisi Yönetimi. *Yüksek Lisans Tezi* 2019;185:783-99.
- Carolin, M.M. ve Fernandez, E., 2008. Analysis of wind power generation and prediction using ANN: a case study. *Renew Energy*. Vol. 33(5), p:986–992. <https://doi.org/10.1016/j.renene.2007.06.013>.
- Castelluccio, M., Poggi, G., Sansone, C., ve Verdoliva, L., 2015. Land Use Classification in Remote Sensing Images by Convolutional Neural Networks. 1–11. *EKLER Chatfield, C., 2002. Confessions of a pragmatic statistician. The Statistician, Volume 51, 1–20.*
- Chang, W., 2013. A literature review of wind forecasting methods, *Power and Energy Engineering*, Volume 2, 161-168.
- Chandra, D.R., Kumari, M.S. ve Sydulu, M., 2013. A detailed literature review on wind forecasting, in: *International Conference on Power, Energy and Control*, 2013, pp. 630-634
- Chen P, Chen H, Ye R. IPEC, 2011. Porcine milk-derived exosomes promote proliferation of intestinal epithelial cells. *Conference proceedings*. 2011.
- Chen, Y., Zhang, S., Zhang, W., 2019. Multifactor spatio-temporal correlation model based on a combination of convolutional neural network and long short-term memory neural network for wind speed forecasting. *Energy Conversion and Management* 2019;185:783-99.
- Cheng, L.L., Zang, H.X., Ding, T., Sun, R., Wang, M.M., Wei, Z.N., Sun, G.Q., 2018. Ensemble recurrent neural network based probabilistic wind speed forecasting approach. *Energies* 11 (8), 1958.
- Colominas, M.A., Schlotthauer, G., Torres, M.E., 2014. Improved complete ensemble EMD: a suitable tool for biomedical signal processing. *Biomed. Signal Process. Control* 14, 19–29.
- Çetin, N.S., 2001. Küçük güçlü bir rüzgar türbini tasarımı ve elektrik enerjisi eldesi, VI. Türk-Alman Sempozyumu, Ege Üniversitesi Güneş Enerjisi Enstitüsü, İzmir.
- Da Silva, G.L.F., Valente, T.L.A., Silva, A.C., Paiva, A.C., Gattass, M., 2018. Convolutional neural network-based PSO for lung nodule false positive reduction on CT images, *Computer Methods and Programs in Biomedicine* 162. 109–118.
- Dai, A. ve Trenberth, K. E., 2002. Estimates of freshwater discharge from continents: Latitudinal and seasonal variations. *Journal of Hydrometeorology*, 3(6), 660-687.
- Deniz, O.T. 2007. Elektrik güç sistemlerindeki geçici olayların dalgacık analizi ve olasılıksal sinir ağları yöntemiyle sınıflandırılması. Y.T.U., yüksek lisans tezi.

- Ding, M., Zhou, H., Xie, H., Wu, M., Liu, K.Z., Nakanishi, Y. ve Yokoyama, R., 2021. A time series model based on hybrid-kernel least-squares support vector machine for short-term wind power forecasting, *ISA (Instrum. Soc. Am.) Trans.* 108 (2021) 58-68.
- Dong, Y., Wang, J., Xiao, L., 2021. Short-term wind speed time series forecasting based on a hybrid method with multiple objective optimization for nonconvex target. *Energy* 2021;215:119180.
- Dündar, C., Oğuz, K., Dokuyucu, K. ve Bacanlı, H., 2011. Kısa Süreli Rüzgar Enerjisi Tahmini, VI. Yeni ve Yenilenebilir Enerji Kaynakları Sempozyumu, 21-22 Ekim 2011, Hilton
- Du, P., Wang, J., Hao, Y., Niu, T., Yang, W., 2020. A novel hybrid model based on multi-objective Harris hawks optimization algorithm for daily PM2.5 and PM10 forecasting. *Appl. Soft. Comput.* 96, 106620.
- Eldering, A., Wennberg, P. O., Crisp, D., Schimel, D. S., Gunson, M. R., Chatterjee, A. ve Mahieu, E., 2017. The Orbiting Carbon Observatory-2 early science investigations of regional carbon dioxide fluxes. *Science*, 358(6360).
- Emeksiz, C., 2014. Şekil Hafızalı Alaşımlar Kullanarak Sonlu Elemanlar Yöntemi İle Değişken Devirli Rüzgar Türbini Modellemesi. (Doktora Tezi), Ege Üniversitesi Fen Bilimleri Enstitüsü, İzmir.
- Emeksiz, C. ve Tan, M., 2022. Wind speed estimation using novelty hybrid adaptive estimation model based on decomposition and deep learning methods (ICEEMDAN-CNN). *Energy*, Cilt:249, S:123785
- Erdem, E. ve Shi, J., 2011. ARMA based approaches for forecasting the tuple of wind speed and direction, *Appl. Energy*, vol. 88 (4), p:1405-1414.
- Erkaymaz, O., Yapici, I.S. ve Arslan, R.U., 2021. Effects of obesity on time-frequency components of electroretinogram signal using continuous wavelet transform, *Biomedical Signal Processing and Control* 66 (2021) 102398.
- Flach, P., 2012. *Machine Learning*; Cambridge University Press: Cambridge, UK, 2012.
- Giorgi, M.G.D., Ficarella, A. Ve Tarantino, M., 2011. Error analysis of short term wind power prediction models, *Appl. Energy*, vol. 88 (4); 1298-1311.
- Goodfellow, I., Bengio, Y. ve Courville, A., 2016. *Deep Learning*; MIT Press: Cambridge, MA, USA, 2016.
- Guo Z., Jie W., Hai-yan L., Wang J.. A case study on a hybrid wind speed forecasting method using BP neural network. *Knowl-Based Systems* 2011;24(7):1048–56.
- Guo, Z., Zhao, W., Lu, H. ve Wang, J., 2012. Multi-step forecasting for wind speed using a modified EMD-based artificial neural network model. *Renew Energy*, vol. 37(1): 241–249. <https://doi.org/10.1016/j.renene.2011.06.023>.
- Guo, Z.H., Wu, J., Lu, H.Y., Wang, J.Z., 2011. A case study on a hybrid wind speed forecasting method using BP neural network, *Knowl. Base Syst.* Vol. 24 (7), p:1048-1056.
- He, X., Chu, L., Qiu, R.C., Ai, Q., Ling, Z.N., Zhang, J., 2020. Invisible units detection and estimation based on random matrix theory. *IEEE Trans. Power Syst.* 35 (3), 1846-1855.
- Hernandez, G.A. ve König, P., 2018. Further advantages of data augmentation on convolutional neural networks. In: *International conference on artificial neural networks*. Springer, pp 95–103. <https://doi.org/10.1007/978-3-030-01418-6-10>.

- Hitam, M.S., Yussof, W.N.J.H. ve Awalludin, E.A., 2013. Mixture Contrast Limited Adaptive Histogram Equalization for Underwater Image Enhancement 2013: Sousse. 1–5.
- Hu, Q., Zhang, R. ve Zhou, Y., 2016. Transfer learning for short-term wind speed prediction with deep neural networks. *Renew. Energy*, vol. 85, p:83-95.
- Huang, C-J. ve Kuo, P-H., 2019. Multiple-input deep convolutional neural network model for short-term photovoltaic power forecasting. *IEEE Access*. Vol.7, p:74822–74834.
- Hui-Liu, H.T., Liang, X. ve Li, Y., 2015. Wind speed forecasting approach using secondary decomposition algorithm and Elman neural networks. *Application Energy*, Vol. 157, 183–194.
- İlkiliç, C., 2012. Wind energy and assessment of wind energy potential in Turkey, *Renewable and Sustainable Energy Reviews*, Volç 16 (2), 1165-1173.
- Jiang, H., 2018. Model forecasting based on two-stage feature selection procedure using orthogonal greedy algorithm. *Appl. Soft Comput. J.* <https://doi.org/10.1016/j.asoc.2017.11.047>.
- Ju, Y., Sun, G.Y., Chen, Q.H., Zhang, M., Zhu, H.X.i Rehman, M.U.i 2019. A model combining convolutional neural network and LightGBM algorithm for ultrashort-term wind power forecasting, *IEEE Access* 7 (2019) 28309-28318.
- Juang, C.F. ve Lu, C.F., 2006. Load-frequency control by hybrid evolutionary fuzzy PI controller. *IEE Proc.Gener. Transm. Distrib*, Vol. 153, No:2.
- Jung, J. ve Broadwater, R., 2014. Current status and future advances for wind speed and wind power forecasting. *Renewable and Sustainable Energy Reviews*, 31, 762-777.
- Kalogirou, S.A., 2000. Artificial neural networks in renewable energy systems applications: a review. *Renew Sustain Energy Rev*. Vol.5(4), p:373–401. [https://doi.org/10.1016/S1364-0321\(01\)00006-5](https://doi.org/10.1016/S1364-0321(01)00006-5).
- Karagöl, E. T. ve Kavaz, İ., 2017. Dünyada ve Türkiye’de Yenilenebilir Enerji. *Analiz Dergisi*, Sayı: 197.
- Karık, F., Sözen, A. ve İzgeç, M. M., 2017. Rüzgâr gücü tahminlerinin önemi: Türkiye elektrik piyasasında bir uygulama. *Politeknik Dergisi*, 20(4), 851-861.
- Kaur, M., Sarkar, K.K. ve Dutta, M.K., 2021. Investigation on quality enhancement of old and fragile artworks using non-linear filter and histogram equalization techniques, *Optik - International Journal for Light and Electron Optics* 244 (2021) 167564.
- Kavasseri, R.G. ve Seetharaman, K., 2009. Day-ahead wind speed forecasting using f-ARIMA models, *Renew. Energy*. Vol. 34 (5), p:1388-1393.
- Kennedy, J. ve Eberhart, R.C., 1995. Particle Swarm Optimization. *Proc. of the IEEE Int. Conference on Neural Networks*, 4, 1942-1948, 1995. Filik, Ü.B. ve Filik, T., 2017.
- Kim, M., Choi, W., Jeon, Y. ve Liu, L., 2019. A hybrid neural network model for power demand forecasting, *Energies* 12 (5) (2019) 931.
- Köse, B., Recebli, Z. ve Özkaymak, M., 2014. Stokastik Modellerle Rüzgar Hızı Tahmini; Karabük Örneği, *ISITES2014*, Karabük.
- Lalarukh, K. ve Yasmin, Z.J., 1997. Time series models to simulate and forecast hourly averaged wind speed in Quetta, Pakistan. *Solar Energy*, vol.61 (1), p:23-32.
- Lecun, Y.; Bottou, L.; Bengio, Y.; Haffner, P. 1998. Gradient-based learning applied to document recognition. *Proc. IEEE* 1998, 86, 2278–2324.

- Li, H.M., Wang, J.Z., Lu, H.Y., Guo, Z.H., 2018. Research and application of a combined model based on variable weight for short term wind speed forecasting. *Renew. Energy* 116, 669-684.
- Liu, D., Niu, D., Wang, H. ve Fan L., 2014. Short-term wind speed forecasting using wavelet transform and support vector machines optimized by genetic algorithm. *Renewable Energy*, Volume 62, 592–597.
- Liu, D., Li, H., Ma, Z., 2010. One hour ahead prediction of wind speed based on data mining. 2nd International conference on advanced computer control, China.
- Liu, H., Tian, H., Liang, X. ve Li, Y., 2015. Wind speed forecasting approach using secondary decomposition algorithm and Elman neural networks. *Appl Energy* 2015;157: 183–94. <https://doi.org/10.1016/j.apenergy.2015.08.014>.
- Liu, H., Wu, H. ve Li, Y. 2018. Smart wind speed forecasting using EWT decomposition, GWO evolutionary optimization (Liu et al., 2018)n, RELM learning and IEWT reconstruction. *Energy Conversion and Management*, 161, 266-283.
- Liu H., Duan Z., Han F., Li Y., Big multi-step wind speed forecasting model based on secondary decomposition, ensemble method and error correction algorithm. *Energy Convers Manage* 2018:525–41.
- Liu H., Tian H., Chen C., Li Y. An experimental investigation of two Wavelet-MLP hybrid frameworks for wind speed prediction using GA and PSO optimization. *Int J Electr Power Energy Syst* 2013;52(1):161–73.
- Mallat, S., Wavelet, A., 1999. *Tour of Signal Processing*, Academic Press, 1999.
- Mardani, A., Jusoh, A., Zavadskas, E.K. ve Cavallaro, F., 2015. Sustainable and renewable energy: an overview of the application of multiple criteria decision making techniques and approaches. *Sustainability* 2015;7(10):13947-84.
- Meng A., Ge J., Yin H., Chen S.. Wind speed forecasting based on wavelet packet decomposition and artificial neural networks trained by crisscross optimization algorithm. *Energy Convers Manage* 2016:75–88
- Mi, X.W. ve Zhao, S., 2020. Wind speed prediction based on singular spectrum analysis and neural network structural learning. *Energy Convers. Manag.* Vol. 216.
- Moghaddamnia, A., Remesan, R., Kashani, M.H., Mohammadi, M., Han, D. ve Piri, J., 2009. Comparison of LLR, MLP, Elman, NNARX and ANFIS Models-with a case study in solar radiation estimation. *J Atmos Solar-Terrestrial Phys* 2009;71(8–9):975–82. <https://doi.org/10.1016/j.jastp.2009.04.009>.
- Moreno, S.R. ve dos Santos, C.L., 2018. Wind speed forecasting approach based on singular spectrum analysis and adaptive neuro fuzzy inference system. *Renew Energy*. Vol.126, p:736–54. <https://doi.org/10.1016/j.renene.2017.11.089>.
- Monteiro, C., Bessa, R., Miranda, V., Botterud, A., Wang, J. ve Conzelmann, G., 2009. *Wind Power Forecasting: State-of-the-Art 2009*. Argonne National Laboratory Report, Illinois
- Mostafaeipour, A., Dehshiri, S.J., Dehshiri, S.S., 2020. Ranking locations for producing hydrogen using geothermal energy in Afghanistan. *International Journal of Hydrogen Energy*. Vol. 45 (32); 15924-15940.
- Naik J., Sujit D. PK, Dash R. B.. Short term wind power forecasting using hybrid variational mode decomposition and multi-kernel regularized pseudo inverse neural network. *Renew Energy* 2017.
- Niu, Z., Yu, Z., Tang, W., Wu, Q., Reformat, M., 2020. Wind power forecasting using attention-based gated recurrent unit network. *Energy* 196, 117081.

- Nguyen, D.T., Park, Y.H., Shin, K.Y., Kwon, S.Y., Lee, H.C. ve Park, K.R., 2013. Fake finger-vein image detection based on Fourier and wavelet transforms, *Digital Signal Process.* 23 (5) (2013) 1401–1413, <https://doi.org/10.1016/j.dsp.2013.04.001>.
- Negnevitsky, M. ve Potter, C., 2006. Innovative Short-Term Wind Generation Prediction Techniques, 2006 IEEE PES Power Systems Conference And Exposition.
- Ouyang, T., Zha, X. ve Qin, L., 2017. A combined multivariate model for wind power prediction. *Energy Convers Manage.* Vol. 144:361–373. <https://doi.org/10.1016/j.enconman.2017.04.077>.
- Özdamar, A., 2001. Rüzgar enerjisi ve rüzgar türbinlerine genel bakış. Yenilenebilir enerji kaynakları sempozyumu kitapçığı, İzmir.
- Ozturk, M., Dincer, I., 2021. An integrated system for ammonia production from renewable hydrogen: a case study. *Int J Hydrogen Energy.* Vol. 46 (8); 5918-59125.
- Qin, Q., Lai, X., Zou, J., 2019. Direct multistep wind speed forecasting using lstm neural network combining eemd and fuzzy entropy. *Appl. Sci.* 9 (1), 126.
- Qian, Z., Pei, Y., Zareipour, H. ve Chen, N., 2019. A review and discussion of decomposition-based hybrid models for wind energy forecasting applications. *Applied Energy*, Volume 235, 939-953.
- Qu, Z., Mao, W., Zhang, K., Zhang, W. ve Li, Z., 2019. Multi-step wind speed forecasting based on a hybrid decomposition technique and an improved back-propagation neural network. *Renewable Energy*, Vol. 133, 919-929.
- Patel, M.R., 2006. *Wind and Solar Power Systems*. CRC Press, Boca Raton, Second Edition, 448, London.
- Potter C.W. ve Negnevitsky M., 2006. Very short-term wind forecasting for Tasmanian power generation. *IEEE Transactions on Power Systems*, Volume 21(2), 965-972.
- Prema V, Rao KU. Time series decomposition model for accurate wind speed forecast. *Renew Wind Water Solar* 2015;2(1):1–11.
- Ramesh, B.N. ve Jagan, M.B., 2015. Fault classification in power systems using EMD and SVM. *Ain Shams Eng J.* p:1–9. <https://doi.org/10.1016/j.asej.2015.08.005>.
- Ramasamy, P., Chandel, S.S. ve Yadav, A.K., 2015. Wind speed prediction in the mountainous region of India using an artificial neural network model. *Renewable Energy*, Volume 80, 338–347.
- Ren Y, Suganthan PN, Srikanth N., 2015. Ensemble methods for wind and solar power forecasting—a state-of-the-art review. *Renew Sustain Energy Rev*;50:82–91.
- Salem, H., Pharma, H., Abdelhafez, E., Hamdan, M.A., Abdelhafez, E. ve Ghnaimat, O., 2017. Prediction of Hourly Solar Radiation in AmmanJordan by using artificial neural networks. *Int J Therm Environ Eng* 2017;14(2):103–8. <https://doi.org/10.5383/ijtee.14.02.003>.
- Saranyaraj, D., Manikandan, M. ve Maheswari, S., 2020. A deep convolutional neural network for the early detection of breast carcinoma with respect to hyperparameter tuning, *Multimedia Tools and Applications* (2020) 79:11013–11038.
- Sengupta, M., Xie, Y., Lopez, A., Habte, A., Maclaurin, G. ve Shelby, J., 2018. The national solar radiation data Base (NSRDB), *Renew. Sustain. Energy Rev.* 89 (2018) 51-60.


- Sfestos, A., 2000. A comparison of various forecasting techniques applied to mean hourly wind speed time series. *Renewable Energy*, Volume 21, 23–35.
- Shao, H., Jiang, H., Ying, L. ve Li, X., 2018. A novel method for intelligent fault diagnosis of rolling bearings using ensemble deep auto-encoders. *Mech. Syst. Signal Process.* 2018, 102, 278–297.
- Shukur, O.B. ve Lee, M.H., 2015. Daily wind speed forecasting through hybrid KF-ANN model based on ARIMA. *Renew Energy* 2015;76:637–47. <https://doi.org/10.1016/j.renene.2014.11.084>.
- Sideratos, G. ve Hatzigargyriou, N.D., 2007. An advanced statistical method for wind power forecasting. *IEEE Trans Power Syst.* Vol. 22(1), p:258–265. <https://doi.org/10.1109/TPWRS.2006.889078>.
- Smith, J.C., Ahlstrom, M.L., Zavadil, R.M., Sadjadpour, A. ve Philbrick R.C., 2009. The Role of Wind Forecasting in Utility System Operations. *IEEE Power and Energy Society General Meeting*, Volume 2009, 1-5.
- Soğukpınar, H. ve Bozkurt, İ., 2014. Türkiye, Avrupa ve dünyada rüzgar enerjisi kullanımı, potansiyeli ve 2013 sonrası hedefler. *Adıyaman Üniversitesi Mühendislik Bilimleri Dergisi*, cilt 1(1), 23-30.
- Soman, S.S., Zareipour, H., Malik, O.P. ve Mandal, P., 2010. A Review of Wind Power and Wind Speed Forecasting Methods With Different Time Horizons. *North American Power Symposium (NAPS)*.
- Song, J., Wang, J. ve Lu, H., 2018. A novel combined model based on advanced optimization algorithm for short-term wind speed forecasting. *Appl Energy*. Vol. 215, p:643–658. <https://doi.org/10.1016/j.apenergy.2018.02.070>.
- Sözen, A., Menlik, T. ve Ünvar, S., 2008. Determination of efficiency of flat-plate solar collectors using neural network approach. *Expert Syst Appl* 2008;35(4):1533–9. <https://doi.org/10.1016/j.eswa.2007.08.080>.
- Şahin, A.D., 2001. Türkiye Rüzgarlarının Alan-Zaman Modellemesi. (Doktora Tezi), İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Şenkal, S., 2014. Rüzgar Hızı Tahmin Yöntemleri - Örnek Bir Uygulama. (Yüksek Lisans Tezi), Ondokuz Mayıs Üniversitesi Fen Bilimleri Enstitüsü, Samsun.
- Şentürk, ü. 2013. EKG Sinyallerinin Bilgisayarda görüntülenmesi, ayrıştırılması Ve Analizi. *Marmara üniversitesi, yüksek lisans tezi*.
- Taşçıkaraoğlu, A. ve Uzunoğlu, M., 2011. Dalgacık Dönüşümü ve Yapay Sinir Ağları ile Rüzgar Hızı Tahmini. *Elektrik-Elektronik ve Bilgisayar Sempozyumu FEED 2011*, Fırat Üniversitesi-Elazığ, 5-7 Ekim 2011.
- Tom, H. ve Peter, C.. 2010. Correction and downscaling of NWP wind speed forecasts. *Meteorol Appl.* Vol. 14; 105–116.
- Torres, J.L., García, A., De Blas, M., De Francisco, A., 2005. Forecast of hourly average wind speed with ARMA models in Navarre. *Solar Energy*;79 (1):65-77.
- Türkyılmaz, F., 1997. Saatlik ve Aylık Rüzgar Verisiyle Rüzgar Enerjisi Modellenmesi. (Doktora Tezi), İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Uygun, C. ve Eker, K., 2009. Rüzgar Enerji Santrallerinin Şebekeye Bağlanması Durumunda Enerji Kalitesi Üzerindeki Etkilerinin İncelenmesi, *Türkiye 11. Enerji Kongresi*, 21-23 Ekim İzmir.
- Wang, B., Sun, Y., Xue, B. ve Zhang, M., 2018. Evolving Deep Convolutional Neural Networks by Variable-length Particle Swarm Optimization for Image Classification, *arXiv: 1803.06492v1 [cs.NE]* 17 Mar 2018.

- Wang, D., Ji, C., Wang, S., Yang, J. ve Wang, Z., 2021. Numerical study of the premixed ammonia-hydrogen combustion under engine-relevant conditions. *Int J Hydrogen Energy*. Vol. 46(2); 2667-2683.
- Wang, J. ve Hu, J.. 2015. A robust combination approach for short-term wind speed forecasting and analysis - Combination of the ARIMA (Autoregressive Integrated Moving Average), ELM (Extreme Learning Machine), SVM (Support Vector Machine) and LSSVM (Least Square SVM) forecasts using a GPR (Gaussian Process Regression) model. *Energy*. Vol. 93: 41–56. <https://doi.org/10.1016/j.energy.2015.08.045>.
- Wang, J., Shanshan, Q., Zhou, Q. Ve Jiang, H., 2015. Medium-term wind speeds forecasting utilizing hybrid models for three different sites in Xinjiang, China, *Renew. Energy*, 76, 91-101.
- Wang, J.J. ve Li, Y.N., 2019. An innovative hybrid approach for multi-step ahead wind speed prediction, *Appl. Soft Comput.* 78 (2019) 296-309.
- Wang, L., Wang, Z., Qu, H. ve Liu, S., 2018. Optimal forecast combination based on neural networks for time series forecasting. *Appl Soft Comput* 2018; 66:1–17. <https://doi.org/10.1016/j.asoc.2018.02.004>.
- Wang J, Wang Y, Jiang P. The study and application of a novel hybrid forecasting model – a case study of wind speed forecasting in China. *Appl Energy* 2015;472–88.
- Wang, S., Muhammad, K., Hong, J., Sangaiah, A., Zhang, Y., 2018. Alcoholism identification via convolutional neural network based on parametric ReLU, dropout, and batch normalization. *Neural Comput. Appl.* 2018, 6, 1–16.
- Wei, S. ve Liu, M., 2016. Wind speed forecasting using FEEMD echo state networks with RELM in Hebei, China. *Energy Conversion Management*. Vol. 114, 197–208.
- Wu Y.K. ve Hong J.S., 2007. A literature review of wind forecasting technology in the World. *IEEE Lausanne PowerTech Proceedings*, Lausanne, Switzerland.
- Yan, R., Liao, J., Yang, J., Sun, W., Nong, M. ve Li, F., 2021. Multi-hour and multi-site air quality index forecasting in Beijing using CNN, LSTM, CNN-LSTM, and spatiotemporal clustering, *Expert Systems With Applications* 169 (2021) 114513.
- Yang, B., Yu, T., Shu, H.C., Dong, J. ve Jiang, L., 2018b. Robust sliding-mode control of wind energy conversion systems for optimal power extraction via nonlinear perturbation observers. *Appl. Energy* 210, 711-723.
- Yang, B., Zhong, L., Wang, J., Shu, H., Zhang, X., Yu, T. ve Sun, L., 2021. State-of-the-art one-stop handbook on wind forecasting technologies: An overview of classifications, methodologies, and analysis, *Journal of Cleaner Production*, vol. 283.
- Yang, B., Zhang, X.S., Yu, T., Shu, H.C. ve Fang, Z.H., 2017. Grouped grey wolf optimizer for maximum power point tracking of doubly-fed induction generator based wind turbine. *Energy Convers. Manag.* 133, 427-443.(Yang et al., 2017)
- Yang, Z. ve Wang, J., 2018. A combination forecasting approach applied in multistep wind speed forecasting based on a data processing strategy and an optimized artificial intelligence algorithm. *Appl Energy*, vol. 230:1108–1125. <https://doi.org/10.1016/j.apenergy.2018.09.037>.
- Yaniktepe B., Savrun M. ve Koroglu T., 2013. Current status of wind energy and wind energy policy in Turkey, *Energy Conversion and Management*, 72, 103-110.

- Yayla, S. ve Harmanci, E., 2021. Estimation of target station data using satellite data and deep learning algorithms. *Int J Energy Res.* Vol.45(1), p:961–974. <https://doi.org/10.1002/er.6055>.
- Zafar, M.W., Shahbaz, M., Sinha, A., Sengupta, T. ve Qin, Q., 2020. How renewable energy consumption contribute to envi(Zafar et al., 2020)ronmental quality? The role of education in OECD countries. *J. Clean. Prod.* 268, 122149.
- Zhang, C., Wei, H. ve Zhao, J., 2016. Short-term wind speed forecasting using empirical mode decomposition and feature selection. *Renew Energy* 2016;96:727–37. <https://doi.org/10.1016/j.renene.2016.05.023>.
- Zhang, K., Qu, Z., Wang, J., Zhang, W. ve Yang, F., 2017. A novel hybrid approach based on cuckoo search optimization algorithm for short-term wind speed forecasting. *Environ Prog Sustain Energy* 2017;36. <https://doi.org/10.1002/ep.12533>.
- Zhang LL, Li MS, Ji TY, Wu QH. Short-term wind power prediction based on intrinsic time-scale decomposition and LS-SVM. *Innovative Smart Grid Technologies. Asia-2016*.
- Zhang W., Wang J., Wang J., Zhao Z., Tian M.. Short-term wind speed forecasting based on a hybrid model. *Appl Soft Computer* 2013;13(7):3225–33.
- Zhang, W., Li, C., Peng, G., Chen, Y. ve Zhang, Z., 2018. A deep convolutional neural network with new training methods for bearing fault diagnosis under noisy environment and different working load. *Mech. Syst. Signal Process.* 2018, 100, 439–453.
- Zhao, X.Y., Jiang, N., Liu, J.F., Yu, D.R., Chang, J.T., 2020. Short-term average wind speed and turbulent standard deviation forecasts based on one-dimensional convolutional neural network and the integrate method for probabilistic framework. *Energy Convers. Manag.* 203, 1122
- Zhuoyi, L., Ryoichi, H. ve Hiroyuki, K., 2021. Hybrid forecasting system based on data area division and deep learning neural network for short-term wind speed forecasting, *Energy Conversion and Management* 238 (2021) 114136.
- Zheng, K, Li Z, Ma Z, Chen J, Zhou J, Su X. 2019. Damage detection method based on Lamb waves for stiffened composite panels. *Compos Struct* 2019;225.



8. EKLER



EK-1. Genel akış diyagramı