

**DERİN ÖĞRENME VE İSTATİSTİKSEL MODELLERLE
OPERASYONEL RÜZGAR ENERJİSİ TAHMİNİ:
BATMAN İÇİN LSTM, ANN VE ARIMA UYGULAMASI**

YÜKSEK LİSANS TEZİ

İlayda KELKİTLİ BAŞARAN

Enerji Bilim ve Teknoloji Anabilim Dalı

Enerji Bilim ve Teknoloji Programı

OCAK 2026

**DERİN ÖĞRENME VE İSTATİSTİKSEL MODELLERLE
OPERASYONEL RÜZGAR ENERJİSİ TAHMİNİ:
BATMAN İÇİN LSTM, ANN VE ARIMA UYGULAMASI**

YÜKSEK LİSANS TEZİ

**İlayda KELKİTLİ BAŞARAN
(301211059)**

Enerji Bilim ve Teknoloji Anabilim Dalı

Enerji Bilim ve Teknoloji Programı

Tez Danışmanı: Dr. Öğr. Üyesi Mustafa Kemal KAYMAK

OCAK 2026

ISTANBUL TECHNICAL UNIVERSITY ★ GRADUATE SCHOOL

**OPERATIONAL WIND ENERGY FORECASTING USING
DEEP LEARNING AND STATISTICAL MODELS:
AN APPLICATION OF LSTM, ANN AND ARIMA FOR BATMAN**

M.Sc. THESIS

**İlayda KELKİTLİ BAŞARAN
(301211059)**

Department of Energy Science and Technology

Energy Science and Technology Program

Thesis Advisor: Assist. Prof. Dr. Mustafa Kemal KAYMAK

JANUARY 2026

İTÜ, Lisansüstü Eğitim Enstitüsü'nün 301211059 numaralı Yüksek Lisans Öğrencisi İlayda KELKİTLİ BAŞARAN, ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı “DERİN ÖĞRENME VE İSTATİSTİKSEL MODELLERLE OPERASYONEL RÜZGAR ENERJİSİ TAHMİNİ: BATMAN İÇİN LSTM, ANN VE ARIMA UYGULAMASI” başlıklı tezini aşağıda imzaları olan jüri önünde başarı ile sunmuştur.

Tez Danışmanı : **Dr. Öğr. Üyesi Mustafa Kemal KAYMAK**
İstanbul Teknik Üniversitesi

Jüri Üyeleri : **Prof. Dr. Ahmet Duran ŞAHİN**
İstanbul Teknik Üniversitesi

Doç. Dr. Ercan İZGİ
Yıldız Teknik Üniversitesi

Teslim Tarihi : 2 Ocak 2026
Savunma Tarihi : 20 Ocak 2026





Eşime ve Aileme



ÖNSÖZ

Bu çalışmanın yürütülmesi sürecindeki akademik desteği ve değerli yönlendirmeleri için tez danışmanım saygıdeğer hocam Dr. Öğr. Üyesi Mustafa Kemal KAYMAK'a, her aşamada gösterdiği sabır, destek ve motivasyonu için sevgili eşim Hasan BAŞARAN'a, her zaman en iyi eğitimi almamı sağlayan ve bugünlerin kapısını açan babacığım Mehmet KELKİTLİ'ye, her kararımda, her anımda en büyük destekçim olan anneciğim Sibel KELKİTLİ'ye, zorlandığım anlarda yanımda olduğunu her şekilde hissettiren canım kardeşim Buğra Turan KELKİTLİ'ye içtenlikle teşekkür ederim.

Ocak 2026

İlayda KELKİTLİ BAŞARAN
(Mühendis)

İÇİNDEKİLER

	Sayfa
ÖNSÖZ	ix
İÇİNDEKİLER	xi
KISALTMALAR	xiii
SEMBOLLER	xv
ÇİZELGE LİSTESİ	xvii
ŞEKİL LİSTESİ	xxi
ÖZET	xxix
SUMMARY	xxxi
1. GİRİŞ	1
1.1 Rüzgârın Fiziksel Temelleri	1
1.2 Atmosferik Dinamikler ve Navier–Stokes Denklemi	2
1.2.1 Basınç gradyanı kuvveti :	3
1.2.2 Coriolis kuvveti :	3
1.2.3 Viskoz/türbülanslı sürtünme :	3
1.2.4 Yerçekimi kuvveti :	3
1.3 Atmosferik Sınır Tabakası, Türbülans ve Modelleme Zorlukları	4
1.4 Topografya, Yüzey–Atmosfer Etkileşimi ve Rüzgârın Dikey Profili	5
1.5 NWP Modelleri ve Türbülansın Çok Ölçekli Yapısı	7
1.6 Rüzgârın Enerji Sistemleri ve Havacılık Operasyonları Açısından Önemi..	9
1.7 Kısa Vadeli Rüzgâr Tahmin Yöntemleri: ARIMA, ANN ve LSTM	11
1.8 Tezin Amacı, Kapsamı ve Yapısı	15
2. LİTERATÜR	21
2.1 Kısa Vadeli Rüzgâr Tahminine Genel Bakış	21
2.2 Rüzgâr Enerjisi Tahmininin Sistemsel Önemi	22
2.3 Doğrusal Yöntemler: AR, ARMA ve ARIMA Model Ailesi	26
2.4 Yapay Sinir Ağları ile Rüzgâr Tahmini Çalışmaları	27
2.5 LSTM Tabanlı Derin Öğrenme Yaklaşımları	28
2.6 Hibrit Modeller: CNN–LSTM, GRU, GAN–LSTM ve Modern Yaklaşımlar	30
2.7 Kompleks Topografya ve ABL Üzerindeki Etkileri: Dağ–Vadi Sistemle-	32
rinde Literatür	32
2.8 Sayısal Hava Tahmini Modelleri ve Sınırları	33
2.9 Literatürdeki Boşluklar ve Bu Tezin Konumlandırılması	35
3. UYGULAMA	39
3.1 Amaç	39
3.2 Veri Hazırlama ve Ön İşleme	44
3.2.1 Veri kaynağı, topoğrafik etki ve zaman çözünürlükleri	44
3.2.2 Kalite kontrol ve veri dönüşümleri	45
3.2.2.1 Uç değer temizleme:	45
3.2.2.2 Eksik veri işlemleri:	45
3.2.2.3 Zamanı yeniden örnekleme:	45

3.2.2.4 Normalizasyon :	45
3.3 Model Formülasyonları ve Kod Parametre Seçimlerinin Bilimsel Gerekçesi	46
3.3.1 ARIMA modeli parametreleri	46
3.3.2 ANN modeli parametreleri	48
3.3.3 LSTM modeli parametreleri	49
4. SONUÇLAR VE DEĞERLENDİRMELER	53
4.1 Meteorolojik Değişkenlerin İncelenmesi	53
4.2 Belirlenen Tarihler için Model Sonuçları	55
4.2.1 1 Şubat-12 Nisan 2023 tarihine ait sonuçlar	56
4.2.1.1 1 Dakikalık zaman çözünürlüğü sonuçları	56
4.2.1.2 5 Dakikalık zaman çözünürlüğü sonuçları	58
4.2.1.3 10 Dakikalık zaman çözünürlüğü sonuçları	60
4.2.1.4 30 Dakikalık zaman çözünürlüğü sonuçları	61
4.2.1.5 60 Dakikalık zaman çözünürlüğü sonuçları	63
4.2.2 1 Eylül-20 Kasım 2023 tarihine ait sonuçlar	65
4.2.2.1 1 Dakikalık zaman çözünürlüğü sonuçları	65
4.2.2.2 5 Dakikalık zaman çözünürlüğü sonuçları	66
4.2.2.3 10 Dakikalık zaman çözünürlüğü sonuçları	68
4.2.2.4 30 Dakikalık zaman çözünürlüğü sonuçları	70
4.2.2.5 60 Dakikalık zaman çözünürlüğü sonuçları	71
4.2.3 1 Mart-25 Mayıs 2024 tarihine ait sonuçlar	73
4.2.3.1 1 Dakikalık zaman çözünürlüğü sonuçları	73
4.2.3.2 5 Dakikalık zaman çözünürlüğü sonuçları	75
4.2.3.3 10 Dakikalık zaman çözünürlüğü sonuçları	77
4.2.3.4 30 Dakikalık zaman çözünürlüğü sonuçları	79
4.2.3.5 60 Dakikalık zaman çözünürlüğü sonuçları	80
4.2.4 1 Eylül-15 Aralık 2024 tarihine ait sonuçlar	82
4.2.4.1 1 Dakikalık zaman çözünürlüğü sonuçları	82
4.2.4.2 5 Dakikalık zaman çözünürlüğü sonuçları	84
4.2.4.3 10 Dakikalık zaman çözünürlüğü sonuçları	85
4.2.4.4 30 Dakikalık zaman çözünürlüğü sonuçları	87
4.2.4.5 60 Dakikalık zaman çözünürlüğü sonuçları	88
4.2.5 1 Mart-3 Mayıs 2025 tarihine ait sonuçlar	90
4.2.5.1 1 Dakikalık zaman çözünürlüğü sonuçları	90
4.2.5.2 5 Dakikalık zaman çözünürlüğü sonuçları	92
4.2.5.3 10 Dakikalık zaman çözünürlüğü sonuçları	94
4.2.5.4 30 Dakikalık zaman çözünürlüğü sonuçları	95
4.2.5.5 60 Dakikalık zaman çözünürlüğü sonuçları	97
5. ÖNERİLER	101
KAYNAKLAR	103
EKLER	107
ÖZGEÇMİŞ	205

KISALTMALAR

ABL	: Atmospheric Boundary Layer
ACF	: Autocorrelation Function
AR	: Autoregressive Model
ARMA	: Autoregressive Moving Average Model
ARIMA	: Autoregressive Integrated Moving Average
ANN	: Artificial Neural Network
CNN	: Convolutional Neural Network
FAA	: Federal Aviation Administration
GAN	: Generative Adversarial Network
GNN	: Graph Neural Network
GRU	: Gated Recurrent Unit
HRRR	: High Resolution Rapid Refresh
I	: Integrated
LSTM	: Long Short-Term Memory
MA	: Moving Average
MAE	: Mean Absolute Error
METAR	: Meteorological Terminal Aviation Routine Report
MLP	: Multi-Layer Perceptron
MSE	: Mean Squared Error
NWP	: Numerical Weather Prediction
PACF	: Partial Autocorrelation Function
RMSE	: Root Mean Squared Error
RNN	: Recurrent Neural Network
R²	: Coefficient of Determination
SHT	: Sayısal Hava Tahmini
TAF	: Terminal Aerodrome Forecast
TÜREB	: Türkiye Rüzgar Enerjisi Birliği
TWEA	: Turkish Wind Energy Atlas



SEMBOLLER

p	: Basınç (Pa)
Δp	: Basınç gradyanı (Pa/m)
WS_{2m}	: 2 m rüzgâr şiddeti (m/s)
WD_{2m}	: 2 m rüzgâr yönü (derece)
T	: Sıcaklık (°C)
RH	: Bağıl nem (%)
QNH	: Deniz seviyesine indirgenmiş basınç (hPa)
ρ	: Havanın yoğunluğu (kg m^{-3})
t	: Zaman indeksi
Δt	: Zaman adımı büyüklüğü
y_t	: t anındaki gözlenen zaman serisi
$\hat{y}_t$	: Model tahmini
ε_t	: Hata (residual) terimi
p, d, q	: ARIMA model parametreleri
ϕ_i	: i 'inci AR katsayısı
θ_j	: j 'inci MA katsayısı
L	: Gecikme (lag) operatörü
∇^d	: d dereceli fark operatörü
AIC	: Akaike bilgi kriteri
BIC	: Bayes bilgi kriteri
X	: Girdi matrisi
x	: Giriş vektörü
w	: Ağırlık matrisi
b	: Bias terimi
z	: Nöron net girdisi
a	: Nöron çıkışı
$f(\cdot)$	: Aktivasyon fonksiyonu

ReLU	: ReLU aktivasyon fonksiyonu
Dense	: Tam bağı katman (fully-connected)
E	: Kayıp fonksiyonu (MSE)
f_t	: Unutma (forget) kapısı
i_t	: Giriş kapısı
o_t	: Çıkış kapısı
C_t	: Hücre durumu
$\tilde{C}_t$	: Aday hücre durumu
h_t	: Gizli durum (hidden state)
x_t	: LSTM girdi vektörü
W_f, W_i, W_o	: Ağırlık matrisleri
U_f, U_i, U_o	: Önceki gizli durum matrisleri
b_f, b_i, b_o	: Bias terimleri
$\sigma(\cdot)$	: Sigmoid fonksiyonu
$\tanh(\cdot)$	: Tanh fonksiyonu
$WS_{2m,lag1}$	: 1 adım gecikmeli rüzgâr şiddeti
$TEMP_{lag1}$	: 1 adım gecikmeli sıcaklık
$HUMID_{lag1}$	: 1 adım gecikmeli bağıl nem
QNH_{lag1}	: 1 adım gecikmeli QNH
$INSTRAIN_{lag1}$	: 1 adım gecikmeli yağış şiddeti
$WD2M_{sin}$	: Rüzgâr yönü sinüs bileşeni
$WD2M_{cos}$	: Rüzgâr yönü kosinüs bileşeni
$WD2M_{sin,lag1}$	: Gecikmeli sinüs bileşeni
$WD2M_{cos,lag1}$	: Gecikmeli kosinüs bileşeni

ÇİZELGE LİSTESİ

Sayfa

Çizelge 4.1: Yalnızca rüzgar verileri ile modellere ait hata metriklerinin karşılaştırılması (1 dk).	53
Çizelge 4.2: Rüzgâr ve sıcaklık girdileri kullanılarak elde edilen modellere ait hata metriklerinin karşılaştırılması (1 dk).	53
Çizelge 4.3: Rüzgâr, sıcaklık ve basınç verileri kullanılarak elde edilen modellere ait hata metriklerinin karşılaştırılması (1 dk).	54
Çizelge 4.4: 10–12 Nisan 2023 (1 dakika) – model karşılaştırması.	57
Çizelge 4.5: 10–12 Nisan 2023 (5 dakika) – model karşılaştırması.	59
Çizelge 4.6: 10–12 Nisan 2023 (10 dakika) – model karşılaştırması.	61
Çizelge 4.7: 10–12 Nisan 2023 (30 dakika) – model karşılaştırması.	62
Çizelge 4.8: 10–12 Nisan 2023 (60 dakika) – model karşılaştırması.	64
Çizelge 4.9: 18–20 Kasım 2023 (1 dakika) – model karşılaştırması.	66
Çizelge 4.10: 18–20 Kasım 2023 (5 dakika) – model karşılaştırması.	67
Çizelge 4.11: 18–20 Kasım 2023 (10 dakika) – model karşılaştırması.	69
Çizelge 4.12: 18–20 Kasım 2023 (30 dakika) – model karşılaştırması.	71
Çizelge 4.13: 18–20 Kasım 2023 (60 dakika) – model karşılaştırması.	72
Çizelge 4.14: 23–25 Mayıs 2024 (1 dakika) – model karşılaştırması.	74
Çizelge 4.15: 23–25 Mayıs 2024 (5 dakika) – model karşılaştırması.	76
Çizelge 4.16: 23–25 Mayıs 2024 (10 dakika) – model karşılaştırması.	78
Çizelge 4.17: 23–25 Mayıs 2024 (30 dakika) – model karşılaştırması.	80
Çizelge 4.18: 23–25 Mayıs 2024 (60 dakika) – model karşılaştırması.	81
Çizelge 4.19: 13–15 Aralık 2024 (1 dakika) – model karşılaştırması.	83
Çizelge 4.20: 13–15 Aralık 2024 (5 dakika) – model karşılaştırması.	84
Çizelge 4.21: 13–15 Aralık 2024 (10 dakika) – model karşılaştırması.	86
Çizelge 4.22: 13–15 Aralık 2024 (30 dakika) – model karşılaştırması.	88
Çizelge 4.23: 13–15 Aralık 2024 (60 dakika) – model karşılaştırması.	89
Çizelge 4.24: 1–3 Mayıs 2025 (1 dakika) – model karşılaştırması.	91
Çizelge 4.25: 1–3 Mayıs 2025 (5 dakika) – model karşılaştırması.	93
Çizelge 4.26: 1–3 Mayıs 2025 (10 dakika) – model karşılaştırması.	95
Çizelge 4.27: 1–3 Mayıs 2025 (30 dakika) – model karşılaştırması.	96
Çizelge 4.28: 1–3 Mayıs 2025 (60 dakika) – model karşılaştırması.	98
Çizelge B.1: Modellere ait hata metriklerinin karşılaştırılması.	118
Çizelge B.2: Modellere ait hata metriklerinin karşılaştırılması.	119
Çizelge B.3: Modellere ait hata metriklerinin karşılaştırılması.	121
Çizelge B.4: Modellere ait hata metriklerinin karşılaştırılması.	122
Çizelge B.5: Modellere ait hata metriklerinin karşılaştırılması.	123
Çizelge B.6: Modellere ait hata metriklerinin karşılaştırılması.	125
Çizelge B.7: Modellere ait hata metriklerinin karşılaştırılması.	126

[illegible]

Çizelge B.55: Modellere ait hata metriklerinin karşılaştırılması.	180
Çizelge B.56: Modellere ait hata metriklerinin karşılaştırılması.	181
Çizelge B.57: Modellere ait hata metriklerinin karşılaştırılması.	182
Çizelge B.58: Modellere ait hata metriklerinin karşılaştırılması.	183
Çizelge B.59: Modellere ait hata metriklerinin karşılaştırılması.	184
Çizelge B.60: Modellere ait hata metriklerinin karşılaştırılması.	185
Çizelge B.61: Modellere ait hata metriklerinin karşılaştırılması.	187
Çizelge B.62: Modellere ait hata metriklerinin karşılaştırılması.	188
Çizelge B.63: Modellere ait hata metriklerinin karşılaştırılması.	190
Çizelge B.64: Modellere ait hata metriklerinin karşılaştırılması.	191
Çizelge B.65: Modellere ait hata metriklerinin karşılaştırılması.	192
Çizelge B.66: Modellere ait hata metriklerinin karşılaştırılması.	194
Çizelge B.67: Modellere ait hata metriklerinin karşılaştırılması.	195
Çizelge B.68: Modellere ait hata metriklerinin karşılaştırılması.	196
Çizelge B.69: Modellere ait hata metriklerinin karşılaştırılması.	197
Çizelge B.70: Modellere ait hata metriklerinin karşılaştırılması.	198
Çizelge B.71: Modellere ait hata metriklerinin karşılaştırılması.	199
Çizelge B.72: Modellere ait hata metriklerinin karşılaştırılması.	200
Çizelge B.73: Modellere ait hata metriklerinin karşılaştırılması.	201
Çizelge B.74: Modellere ait hata metriklerinin karşılaştırılması.	202
Çizelge B.75: Modellere ait hata metriklerinin karşılaştırılması.	203



ŞEKİL LİSTESİ

	<u>Sayfa</u>
Şekil 2.1: Rüzgâr enerjisinin enerji sistemleri ve piyasa yapısı içindeki kavramsal konumu.	24
Şekil 2.2: Türkiye elektrik kurulu gücünün kaynaklara göre dağılımı.	24
Şekil 2.3: Türkiye elektrik üretiminin kaynaklara göre dağılımı.	25
Şekil 3.1: 1 Mayıs 2025 tarihine ait METAR.	40
Şekil 3.2: 24 Mayıs 2024 tarihine ait METAR.	40
Şekil 3.3: 1 Mayıs 2025 tarihine ait METEOGRAM.	41
Şekil 3.4: 1 Mayıs 2025 tarihine ait METEOGRAM.	42
Şekil 4.1: ARIMA modeli tahmin-gözlem karşılaştırması.	56
Şekil 4.2: ANN modeli tahmin-gözlem karşılaştırması.	56
Şekil 4.3: LSTM modeli tahmin-gözlem karşılaştırması.	56
Şekil 4.4: ARIMA modeli tahmin-gözlem karşılaştırması.	58
Şekil 4.5: ANN modeli tahmin-gözlem karşılaştırması.	58
Şekil 4.6: LSTM modeli tahmin-gözlem karşılaştırması.	58
Şekil 4.7: ARIMA modeli tahmin-gözlem karşılaştırması.	60
Şekil 4.8: ANN modeli tahmin-gözlem karşılaştırması.	60
Şekil 4.9: LSTM modeli tahmin-gözlem karşılaştırması.	60
Şekil 4.10: ARIMA modeli tahmin-gözlem karşılaştırması.	61
Şekil 4.11: ANN modeli tahmin-gözlem karşılaştırması.	62
Şekil 4.12: LSTM modeli tahmin-gözlem karşılaştırması.	62
Şekil 4.13: ARIMA modeli tahmin-gözlem karşılaştırması.	63
Şekil 4.14: ANN modeli tahmin-gözlem karşılaştırması.	63
Şekil 4.15: LSTM modeli tahmin-gözlem karşılaştırması.	64
Şekil 4.16: ARIMA modeli tahmin-gözlem karşılaştırması.	65
Şekil 4.17: ANN modeli tahmin-gözlem karşılaştırması.	65
Şekil 4.18: LSTM modeli tahmin-gözlem karşılaştırması.	65
Şekil 4.19: ARIMA modeli tahmin-gözlem karşılaştırması.	66
Şekil 4.20: ANN modeli tahmin-gözlem karşılaştırması.	67
Şekil 4.21: LSTM modeli tahmin-gözlem karşılaştırması.	67
Şekil 4.22: ARIMA modeli tahmin-gözlem karşılaştırması.	68
Şekil 4.23: ANN modeli tahmin-gözlem karşılaştırması.	68
Şekil 4.24: LSTM modeli tahmin-gözlem karşılaştırması.	69
Şekil 4.25: ARIMA modeli tahmin-gözlem karşılaştırması.	70
Şekil 4.26: ANN modeli tahmin-gözlem karşılaştırması.	70
Şekil 4.27: LSTM modeli tahmin-gözlem karşılaştırması.	70
Şekil 4.28: ARIMA modeli tahmin-gözlem karşılaştırması.	71

Şekil 4.29:	ANN modeli tahmin-gözlem karşılaştırması.	72
Şekil 4.30:	LSTM modeli tahmin-gözlem karşılaştırması.	72
Şekil 4.31:	ARIMA modeli tahmin-gözlem karşılaştırması.	73
Şekil 4.32:	ANN modeli tahmin-gözlem karşılaştırması.	73
Şekil 4.33:	LSTM modeli tahmin-gözlem karşılaştırması.	74
Şekil 4.34:	ARIMA modeli tahmin-gözlem karşılaştırması.	75
Şekil 4.35:	ANN modeli tahmin-gözlem karşılaştırması.	75
Şekil 4.36:	LSTM modeli tahmin-gözlem karşılaştırması.	75
Şekil 4.37:	ARIMA modeli tahmin-gözlem karşılaştırması.	77
Şekil 4.38:	ANN modeli tahmin-gözlem karşılaştırması.	77
Şekil 4.39:	LSTM modeli tahmin-gözlem karşılaştırması.	77
Şekil 4.40:	ARIMA modeli tahmin-gözlem karşılaştırması.	79
Şekil 4.41:	ANN modeli tahmin-gözlem karşılaştırması.	79
Şekil 4.42:	LSTM modeli tahmin-gözlem karşılaştırması.	79
Şekil 4.43:	ARIMA modeli tahmin-gözlem karşılaştırması.	80
Şekil 4.44:	ANN modeli tahmin-gözlem karşılaştırması.	81
Şekil 4.45:	LSTM modeli tahmin-gözlem karşılaştırması.	81
Şekil 4.46:	ARIMA modeli tahmin-gözlem karşılaştırması.	82
Şekil 4.47:	ANN modeli tahmin-gözlem karşılaştırması.	82
Şekil 4.48:	LSTM modeli tahmin-gözlem karşılaştırması.	83
Şekil 4.49:	ARIMA modeli tahmin-gözlem karşılaştırması.	84
Şekil 4.50:	ANN modeli tahmin-gözlem karşılaştırması.	84
Şekil 4.51:	LSTM modeli tahmin-gözlem karşılaştırması.	84
Şekil 4.52:	ARIMA modeli tahmin-gözlem karşılaştırması.	85
Şekil 4.53:	ANN modeli tahmin-gözlem karşılaştırması.	85
Şekil 4.54:	LSTM modeli tahmin-gözlem karşılaştırması.	86
Şekil 4.55:	ARIMA modeli tahmin-gözlem karşılaştırması.	87
Şekil 4.56:	ANN modeli tahmin-gözlem karşılaştırması.	87
Şekil 4.57:	LSTM modeli tahmin-gözlem karşılaştırması.	87
Şekil 4.58:	ARIMA modeli tahmin-gözlem karşılaştırması.	88
Şekil 4.59:	ANN modeli tahmin-gözlem karşılaştırması.	89
Şekil 4.60:	LSTM modeli tahmin-gözlem karşılaştırması.	89
Şekil 4.61:	ARIMA modeli tahmin-gözlem karşılaştırması.	90
Şekil 4.62:	ANN modeli tahmin-gözlem karşılaştırması.	90
Şekil 4.63:	LSTM modeli tahmin-gözlem karşılaştırması.	91
Şekil 4.64:	ARIMA modeli tahmin-gözlem karşılaştırması.	92
Şekil 4.65:	ANN modeli tahmin-gözlem karşılaştırması.	92
Şekil 4.66:	LSTM modeli tahmin-gözlem karşılaştırması.	92
Şekil 4.67:	ARIMA modeli tahmin-gözlem karşılaştırması.	94
Şekil 4.68:	ANN modeli tahmin-gözlem karşılaştırması.	94
Şekil 4.69:	LSTM modeli tahmin-gözlem karşılaştırması.	94
Şekil 4.70:	ARIMA modeli tahmin-gözlem karşılaştırması.	95
Şekil 4.71:	ANN modeli tahmin-gözlem karşılaştırması.	96
Şekil 4.72:	LSTM modeli tahmin-gözlem karşılaştırması.	96

Şekil 4.73:	ARIMA modeli tahmin-gözlem karşılaştırması.	97
Şekil 4.74:	ANN modeli tahmin-gözlem karşılaştırması.	97
Şekil 4.75:	LSTM modeli tahmin-gözlem karşılaştırması.	98
Şekil B.1:	ARIMA modeli tahmin-gözlem karşılaştırması.	117
Şekil B.2:	ANN modeli tahmin-gözlem karşılaştırması.	117
Şekil B.3:	LSTM modeli tahmin-gözlem karşılaştırması.	118
Şekil B.4:	ARIMA modeli tahmin-gözlem karşılaştırması.	118
Şekil B.5:	ANN modeli tahmin-gözlem karşılaştırması.	119
Şekil B.6:	LSTM modeli tahmin-gözlem karşılaştırması.	119
Şekil B.7:	ARIMA modeli tahmin-gözlem karşılaştırması.	120
Şekil B.8:	ANN modeli tahmin-gözlem karşılaştırması.	120
Şekil B.9:	LSTM modeli tahmin-gözlem karşılaştırması.	120
Şekil B.10:	ARIMA modeli tahmin-gözlem karşılaştırması.	121
Şekil B.11:	ANN modeli tahmin-gözlem karşılaştırması.	121
Şekil B.12:	LSTM modeli tahmin-gözlem karşılaştırması.	122
Şekil B.13:	ARIMA modeli tahmin-gözlem karşılaştırması.	122
Şekil B.14:	ANN modeli tahmin-gözlem karşılaştırması.	123
Şekil B.15:	LSTM modeli tahmin-gözlem karşılaştırması.	123
Şekil B.16:	ARIMA modeli tahmin-gözlem karşılaştırması.	124
Şekil B.17:	ANN modeli tahmin-gözlem karşılaştırması.	124
Şekil B.18:	LSTM modeli tahmin-gözlem karşılaştırması.	124
Şekil B.19:	ARIMA modeli tahmin-gözlem karşılaştırması.	125
Şekil B.20:	ANN modeli tahmin-gözlem karşılaştırması.	125
Şekil B.21:	LSTM modeli tahmin-gözlem karşılaştırması.	125
Şekil B.22:	ARIMA modeli tahmin-gözlem karşılaştırması.	126
Şekil B.23:	ANN modeli tahmin-gözlem karşılaştırması.	126
Şekil B.24:	LSTM modeli tahmin-gözlem karşılaştırması.	126
Şekil B.25:	ARIMA modeli tahmin-gözlem karşılaştırması.	127
Şekil B.26:	ANN modeli tahmin-gözlem karşılaştırması.	127
Şekil B.27:	LSTM modeli tahmin-gözlem karşılaştırması.	127
Şekil B.28:	ARIMA modeli tahmin-gözlem karşılaştırması.	128
Şekil B.29:	ANN modeli tahmin-gözlem karşılaştırması.	128
Şekil B.30:	LSTM modeli tahmin-gözlem karşılaştırması.	128
Şekil B.31:	ARIMA modeli tahmin-gözlem karşılaştırması.	129
Şekil B.32:	ANN modeli tahmin-gözlem karşılaştırması.	129
Şekil B.33:	LSTM modeli tahmin-gözlem karşılaştırması.	130
Şekil B.34:	ARIMA modeli tahmin-gözlem karşılaştırması.	130
Şekil B.35:	ANN modeli tahmin-gözlem karşılaştırması.	130
Şekil B.36:	LSTM modeli tahmin-gözlem karşılaştırması.	131
Şekil B.37:	ARIMA modeli tahmin-gözlem karşılaştırması.	131
Şekil B.38:	ANN modeli tahmin-gözlem karşılaştırması.	131
Şekil B.39:	LSTM modeli tahmin-gözlem karşılaştırması.	132
Şekil B.40:	ARIMA modeli tahmin-gözlem karşılaştırması.	132
Şekil B.41:	ANN modeli tahmin-gözlem karşılaştırması.	132

Şekil B.86:	ANN modeli tahmin-gözlem karşılaştırması.	150
Şekil B.87:	LSTM modeli tahmin-gözlem karşılaştırması.	150
Şekil B.88:	ARIMA modeli tahmin-gözlem karşılaştırması.	150
Şekil B.89:	ANN modeli tahmin-gözlem karşılaştırması.	151
Şekil B.90:	LSTM modeli tahmin-gözlem karşılaştırması.	151
Şekil B.91:	ARIMA modeli tahmin-gözlem karşılaştırması.	152
Şekil B.92:	ANN modeli tahmin-gözlem karşılaştırması.	152
Şekil B.93:	LSTM modeli tahmin-gözlem karşılaştırması.	152
Şekil B.94:	ARIMA modeli tahmin-gözlem karşılaştırması.	153
Şekil B.95:	ANN modeli tahmin-gözlem karşılaştırması.	153
Şekil B.96:	LSTM modeli tahmin-gözlem karşılaştırması.	153
Şekil B.97:	ARIMA modeli tahmin-gözlem karşılaştırması.	154
Şekil B.98:	ANN modeli tahmin-gözlem karşılaştırması.	154
Şekil B.99:	LSTM modeli tahmin-gözlem karşılaştırması.	154
Şekil B.100:	ARIMA modeli tahmin-gözlem karşılaştırması.	155
Şekil B.101:	ANN modeli tahmin-gözlem karşılaştırması.	155
Şekil B.102:	LSTM modeli tahmin-gözlem karşılaştırması.	156
Şekil B.103:	ARIMA modeli tahmin-gözlem karşılaştırması.	156
Şekil B.104:	ANN modeli tahmin-gözlem karşılaştırması.	157
Şekil B.105:	LSTM modeli tahmin-gözlem karşılaştırması.	157
Şekil B.106:	ARIMA modeli tahmin-gözlem karşılaştırması.	158
Şekil B.107:	ANN modeli tahmin-gözlem karşılaştırması.	158
Şekil B.108:	LSTM modeli tahmin-gözlem karşılaştırması.	158
Şekil B.109:	ARIMA modeli tahmin-gözlem karşılaştırması.	159
Şekil B.110:	ANN modeli tahmin-gözlem karşılaştırması.	159
Şekil B.111:	LSTM modeli tahmin-gözlem karşılaştırması.	159
Şekil B.112:	ARIMA modeli tahmin-gözlem karşılaştırması.	160
Şekil B.113:	ANN modeli tahmin-gözlem karşılaştırması.	160
Şekil B.114:	LSTM modeli tahmin-gözlem karşılaştırması.	160
Şekil B.115:	ARIMA modeli tahmin-gözlem karşılaştırması.	161
Şekil B.116:	ANN modeli tahmin-gözlem karşılaştırması.	161
Şekil B.117:	LSTM modeli tahmin-gözlem karşılaştırması.	161
Şekil B.118:	ARIMA modeli tahmin-gözlem karşılaştırması.	162
Şekil B.119:	ANN modeli tahmin-gözlem karşılaştırması.	162
Şekil B.120:	LSTM modeli tahmin-gözlem karşılaştırması.	162
Şekil B.121:	ARIMA modeli tahmin-gözlem karşılaştırması.	163
Şekil B.122:	ANN modeli tahmin-gözlem karşılaştırması.	163
Şekil B.123:	LSTM modeli tahmin-gözlem karşılaştırması.	164
Şekil B.124:	ARIMA modeli tahmin-gözlem karşılaştırması.	164
Şekil B.125:	ANN modeli tahmin-gözlem karşılaştırması.	164
Şekil B.126:	LSTM modeli tahmin-gözlem karşılaştırması.	165
Şekil B.127:	ARIMA modeli tahmin-gözlem karşılaştırması.	165
Şekil B.128:	ANN modeli tahmin-gözlem karşılaştırması.	165
Şekil B.129:	LSTM modeli tahmin-gözlem karşılaştırması.	166

Şekil B.218: ANN modeli tahmin-gözlem karşılaştırması.	200
Şekil B.219: LSTM modeli tahmin-gözlem karşılaştırması.	201
Şekil B.220: ARIMA modeli tahmin-gözlem karşılaştırması.	201
Şekil B.221: ANN modeli tahmin-gözlem karşılaştırması.	201
Şekil B.222: LSTM modeli tahmin-gözlem karşılaştırması.	202
Şekil B.223: ARIMA modeli tahmin-gözlem karşılaştırması.	202
Şekil B.224: ANN modeli tahmin-gözlem karşılaştırması.	202
Şekil B.225: LSTM modeli tahmin-gözlem karşılaştırması.	203



**DERİN ÖĞRENME VE İSTATİSTİKSEL MODELLERLE
OPERASYONEL RÜZGAR ENERJİSİ TAHMİNİ:
BATMAN İÇİN LSTM, ANN VE ARIMA UYGULAMASI**

ÖZET

Kısa vadeli rüzgâr tahmini, hem enerji sistemlerinin sürekliliği hem de havacılık operasyonlarının emniyeti açısından kritik öneme sahip meteorolojik bir süreçtir. Enerji üretiminde rüzgâr şiddetindeki kısa süreli dalgalanmalar, şebeke kararlılığında ani değişimlere neden olabilmekte; havacılık alanında ise özellikle yüzeye yakın atmosferde meydana gelen wind shear, low-level jet, ani yön dönüşleri ve konvektif kaynaklı hız sıçramaları gibi olaylar operasyonel güvenliği doğrudan etkilemektedir. Bu değişkenliğin doğru şekilde modellenebilmesi, özellikle topoğrafik olarak karmaşık ve mevsim geçişlerinin belirgin olduğu bölgelerde daha büyük önem taşımaktadır. Batman Meydanı da plato yüzeyi, vadi etkileri, pürüzlülük geçişleri ve konvektif süreçler nedeniyle kısa vadeli rüzgâr tahmininde yüksek belirsizlik içeren bir mikro-ölçek atmosferik ortama sahiptir. Bu nedenle Batman için saha bazlı, çok-ölçekli ve yüksek çözünürlüklü modelleme çalışmaları hem bilimsel hem operasyonel açıdan önemli bir gerekliliktir.

Bu çalışmada, Batman Meydan Meteoroloji İstasyonu'nda gözlenen yüksek çözünürlüklü rüzgâr verileri kullanılarak, üç farklı zaman serisi modelinin Otoregresif Bütünleşik Hareketli Ortalama Modeli (ARIMA), Yapay Sinir Ağları (ANN) ve Uzun Kısa Süreli Bellek (LSTM) kısa vadeli tahmin performansları kapsamlı biçimde değerlendirilmiştir. Çalışma, mevsim geçiş dönemlerini temsil eden beş farklı tarih aralığını kapsamakta olup, her dönem rüzgârın hem kararlı hem de ani değişim gösterdiği koşulları içermesi bakımından kısa vadeli model davranışlarının karşılaştırılması için geniş bir çerçeve sunmaktadır. Ham rüzgâr verileri Meteoroloji Genel Müdürlüğü veri standartları doğrultusunda kalite kontrolden geçirilmiş; hatalı veriler düzeltilmiş, eksik kayıtlar uygun yöntemlerle işlenmiş ve ardından operasyonel tahminlerde kullanılan beş farklı zaman çözünürlüğüne (1, 5, 10, 30 ve 60 dakika) yeniden örneklenmiştir. Böylece rüzgârın mikro ölçekten saatlik ölçeğe kadar değişen dinamik yapısı hem modellerin doğruluğu hem de ölçek duyarlılığı açısından sistematik olarak incelenebilmiştir.

Modelleme sürecinde üç yöntem birbirinden bağımsız olarak eğitilmiş ve aynı dönemlere ait METAR tahakkuk verileri ile TAF/SHT tahminleri üzerinden kapsamlı bir performans değerlendirmesi yapılmıştır. ARIMA modeli, doğrusal zaman serisi yapısını temsil etmesi bakımından temel bir kıyaslama aracı olarak kullanılmış; ANN modeli doğrusal olmayan ilişkileri öğrenme kapasitesi, LSTM modeli ise ardışık bağımlılıkları koruyabilme yeteneği açısından analiz edilmiştir. Tüm modellerin

performansı ortalama mutlak hata (MAE), kök ortalama kare hata (RMSE) ve determinasyon katsayısı (R^2) ölçütleri kullanılarak değerlendirilmiş; böylece hem hata miktarı hem de hata davranışının zaman ölçeklerine göre değişimi ayrıntılı biçimde ortaya konmuştur.

Elde edilen bulgular, ANN modelinin tüm zaman çözünürlüklerinde en düşük hata değerlerini üreterek istikrarlı bir performans gösterdiğini ve hem kararlı hem değişken rüzgâr koşullarında güçlü bir tahmin yeteneği sunduğunu ortaya koymaktadır. LSTM modeli, özellikle kısa zaman aralıklarında (1–5 dakika) ani hızlanmaları ve rüzgâr serisindeki yüksek frekanslı dalgalanmaları yakalamada başarılı olmuş; konvektif geçişlerin etkili olduğu zaman dilimlerinde ARIMA modeline göre belirgin bir doğruluk artışı sağlamıştır. Buna karşın ARIMA modeli, daha stabil atmosferik koşullarda kabul edilebilir performans üretse de, konvektif süreçlerin ve topoğrafya kaynaklı kanalizasyonun baskın olduğu dönemlerde hata seviyeleri artmış ve değişken rüzgâr yapısını temsil etmekte yetersiz kalmıştır. Ayrıca çözünürlükler karşılaştırıldığında, yüksek çözünürlüklü verilerde (1 ve 5 dakika) ANN ve LSTM gibi veri odaklı modellerin avantajı daha belirgin olurken, zaman adımı uzadıkça modeller arasındaki farkın azaldığı gözlenmiştir.

Bu sonuçlar, özellikle 1–5 dakikalık çözünürlüklerde ANN ve LSTM modellerinin performansı, havacılık operasyonlarında kritik öneme sahip yüzeye yakın rüzgârın daha doğru temsil edilmesine katkı sağlamaktadır. Bu durum, yaklaşma ve kalkış aşamalarında karşılaşılan ani rüzgâr değişimlerinin daha erken ve güvenilir tahmin edilmesine olanak tanıyarak operasyonel emniyet düzeyini artırmaktadır. Enerji sektörü açısından değerlendirildiğinde ise daha isabetli kısa vadeli tahminler, rüzgâr üretimindeki dalgalanmaların daha iyi yönetilmesine, rezerv kapasite planlamasının iyileştirilmesine ve şebeke stabilitesinin korunmasına yardımcı olmaktadır.

Sonuç olarak bu tez, Batman Meydanı için çok ölçekli (çeşitli zaman aralıkları, farklı meteorolojik değişkenler) rüzgâr tahmini üzerine gerçekleştirilen kapsamlı bir değerlendirme sunmakta; farklı zaman çözünürlüklerinde uygulanan üç modelin performansını sistematik bir çerçevede karşılaştırarak bölgeye özgü kısa vadeli tahmin dinamiklerini ortaya koymaktadır. Tez bulguları, hem havacılık hem enerji sistemleri açısından operasyonel karar süreçlerini destekleyen nitelikte olup, yüksek çözünürlüklü rüzgâr verileri ile modern veri odaklı modellerin birlikte kullanılmasının kısa vadeli tahminlerde önemli kazanımlar sağlayabileceğini göstermektedir. Elde edilen sonuçlar, Batman özelinde kısa vadeli rüzgâr tahmininin ölçek duyarlılığını ortaya koyarak, operasyonel havacılık meteorolojisi ve rüzgâr enerjisi uygulamaları için karar destek niteliği taşıyan önemli bulgular sunmaktadır.

**OPERATIONAL WIND ENERGY FORECASTING USING
DEEP LEARNING AND STATISTICAL MODELS:
AN APPLICATION OF LSTM, ANN AND ARIMA FOR BATMAN**

SUMMARY

Short-term wind forecasting is a critical component for both renewable energy management and aviation operations, particularly in regions characterized by rapid atmospheric variability and complex surface–atmosphere interactions. Wind behavior in the lower levels of the atmospheric boundary layer is governed by highly dynamic processes, including sudden wind speed fluctuations, convective transitions, shear-induced disturbances, and turbulence. These processes introduce strong nonlinearity and intermittency into near-surface wind fields, significantly limiting the accuracy of operational weather forecasts. The challenge becomes especially pronounced in areas where local topography, surface roughness variations, and valley–ridge interactions strongly modulate airflow, resulting in complex wind patterns that evolve rapidly over short time scales.

Batman Airport represents a location where these controlling factors coexist and interact, producing high spatial and temporal variability in wind speed and direction. The combined influence of regional circulation patterns, local terrain features, and boundary-layer processes creates a challenging environment for short-term wind prediction. In such settings, even small-scale atmospheric disturbances can lead to abrupt changes in wind characteristics, which are difficult to resolve using conventional forecasting approaches. Consequently, accurate and high-resolution wind forecasting methods are essential to enhance operational safety, improve planning efficiency, and support reliable decision-making processes in both aviation and renewable energy applications.

In the context of renewable energy systems, even minor deviations in short-term wind forecasts can result in substantial imbalances between predicted and actual power generation. These imbalances often necessitate additional reserve capacity, increase operational costs, and reduce overall grid efficiency. Accurate short-term wind predictions therefore play a crucial role in generation scheduling, system balancing, and the reliable integration of wind energy into power systems. Similarly, in aviation operations, inaccurate representation of wind shear, gust fronts, low-level jets, and rapid directional changes can pose serious risks during critical flight phases such as take-off, landing, and approach. These risks are particularly elevated under highly variable wind conditions, where rapid changes occur on time scales of minutes.

Although numerical weather prediction (NWP) models have improved considerably over the past decade, their operational spatial and temporal resolutions remain

insufficient to fully capture microscale and boundary-layer wind variability. This limitation is especially evident at very short forecast horizons, typically ranging from one minute to one hour, where turbulent fluctuations and convective processes dominate wind behavior. As a result, many operational forecasts fail to accurately represent rapid transitions in near-surface wind fields, particularly in regions characterized by complex terrain and heterogeneous surface properties. These shortcomings underscore the importance of data-driven, site-specific, and high-frequency forecasting techniques that can complement or refine traditional NWP outputs, providing more detailed and responsive short-term predictions.

The primary objective of this study is to evaluate and compare the short-term wind forecasting performance of three widely used time-series modeling approaches (Autoregressive Integrated Moving Average (ARIMA), Artificial Neural Networks (ANN), and Long Short-Term Memory (LSTM)) across multiple temporal resolutions. High-resolution wind observations obtained from the Batman Airport Meteorological Station are used as the primary data source. A systematic multi-scale analysis framework is adopted to investigate how model performance changes as temporal resolution varies, allowing for a detailed examination of the scale dependency of wind predictability.

To ensure that the analysis captures a wide range of atmospheric conditions, five distinct periods corresponding to seasonal transition months are selected. These periods are chosen to include both relatively stable atmospheric regimes and highly variable, convective conditions during which forecasting errors typically increase. Prior to model development, a comprehensive quality control procedure is applied to the raw observational dataset to ensure data reliability and consistency. Following this process, the dataset is resampled to generate five separate temporal resolutions at 1, 5, 10, 30, and 60-minute intervals. This multi-resolution structure enables an in-depth investigation of how temporal aggregation influences model behavior and predictive skill.

Each forecasting model is trained independently for every temporal resolution to prevent information leakage and to ensure a fair and consistent comparison. The ARIMA model, representing the classical linear time-series modeling paradigm, is included as a benchmark due to its long-standing use and established applicability in meteorological forecasting. ANN is employed to assess the capability of nonlinear, feed-forward neural networks to capture complex relationships and interactions within wind time series. LSTM, a recurrent deep learning architecture equipped with memory mechanisms, is selected due to its ability to preserve temporal dependencies and model sequential patterns, making it particularly suitable for representing rapidly fluctuating and turbulent wind behavior.

Forecast outputs from all models are evaluated using Mean Absolute Error (MAE), Root Mean Square Error (RMSE), and the coefficient of determination (R^2). These performance metrics provide a robust assessment of both the magnitude and structure of model errors, allowing for a comprehensive comparison across models and temporal resolutions. METAR observations from the same periods are used as ground truth, while operational aviation forecasts such as TAF and SHT are included for comparison in order to highlight existing limitations in operational forecasting practices.

The results of the study reveal clear differences among the three modeling approaches and demonstrate the strong influence of temporal resolution on forecasting performance. ANN provides the most stable and consistently accurate predictions across all temporal resolutions, indicating a strong ability to represent both stable atmospheric conditions and periods characterized by increased variability. The LSTM model exhibits superior performance particularly at very short temporal resolutions, such as 1 and 5 minutes, where rapid wind fluctuations, gusts, and turbulence dominate the wind field. Its memory-based architecture enables more effective representation of abrupt changes compared to both ANN and ARIMA. During convective events, frontal passages, and turbulence-driven variability, ANN achieves significantly higher accuracy than ARIMA and performs comparably to or better than LSTM.

In contrast, the ARIMA model performs adequately under relatively stable atmospheric conditions and at longer temporal resolutions, such as 30 and 60 minutes. However, its linear structure limits its ability to represent nonlinear dynamics and high-frequency wind variability, resulting in larger forecast errors under highly variable conditions. These findings highlight the limitations of linear time-series models when applied to regions affected by strong turbulence, surface roughness transitions, and complex topographic influences.

The analysis further indicates that the advantages of deep learning-based models become increasingly pronounced as temporal resolution increases. When the resolution is refined from 30–60 minutes to 1–5 minutes, the performance gap between ANN/LSTM and ARIMA widens substantially. This suggests that high-frequency wind dynamics are more effectively captured using nonlinear and memory-based approaches. Conversely, as temporal resolution becomes coarser, the performance difference between ANN and LSTM gradually diminishes. This behavior is expected, as temporal averaging reduces the impact of noise, turbulence, and convective irregularities. Nevertheless, even at the coarsest resolution of 60 minutes, ANN maintains a slight performance advantage, indicating that nonlinear modeling approaches can still provide improved predictive skill when high-frequency variability is partially smoothed.

The operational implications of these findings are significant. In aviation, improved short-term wind forecasting enhances situational awareness, supports more effective risk assessment, and contributes directly to flight safety. The ability of ANN and LSTM models to capture sudden wind speed changes and short-lived gust events offers meaningful benefits for approach, taxi, and take-off planning, where sensitivity to wind conditions is highest. In renewable energy systems, accurate short-term wind forecasts enable more efficient generation balancing, reduce reserve requirements, and improve the integration of wind energy into regional power grids.

In conclusion, this thesis presents one of the most comprehensive multi-scale evaluations of short-term wind forecasting conducted for Batman Airport. By comparing three distinct model families across five temporal resolutions and five meteorologically diverse periods, the study provides detailed insight into how wind predictability varies with temporal scale and atmospheric conditions. The results demonstrate that ANN is the most stable and accurate overall performer, while LSTM offers clear advantages in capturing rapid fluctuations inherent in high-resolution

wind time series. ARIMA, although useful as a baseline model, is insufficient under highly variable and turbulent conditions. Overall, the findings highlight the substantial potential of deep learning–based approaches to enhance short-term wind forecasting accuracy and to deliver meaningful improvements for aviation safety and renewable energy system management in meteorologically complex regions.



1. GİRİŞ

1.1 Rüzgârın Fiziksel Temelleri

Rüzgâr, atmosferdeki basınç farklılıklarını dengelemek üzere hava kütlelerinin yatay doğrultuda gerçekleştirdiği hareket olarak tanımlanan temel bir dinamik süreçtir. Bu basınç farklılıklarının kaynağı, Dünya'ya ulaşan kısa dalga Güneş radyasyonunun enleme bağlı olarak uzaysal açıdan eşit dağılmaması sonucu ortaya çıkan sıcaklık gradyanlarıdır. [1]'de belirttiği gibi, ekvator bölgeleri yıl boyunca daha yoğun güneşlenmeye maruz kaldığından daha sıcak, kutup bölgeleri ise daha soğuktur. Bu ısı dengesi, atmosferde geniş ölçekli bir basınç alanı yapısı oluşturarak hem küresel hem bölgesel hava dolaşımını tetikler. Yüzeyin ısınmasıyla yoğunluğu azalan hava yükselirken, soğuyan hava çöker ve yüksek basınç merkezleri meydana getirir; böylece atmosfer sürekli bir yatay basınç gradyanı kuvveti tarafından yönlendirilen hareket hâlinde kalır.

Stull'un ayrıntılandığı üzere, rüzgâr yalnızca yatay akıştan ibaret değildir; atmosfer, sıkıştırılabilir bir akışkan olarak üç boyutlu ve oldukça karmaşık bir hareket yapısına sahiptir [2]. Özellikle atmosferik sınır tabakasında (ABL), yüzey pürüzlülüğü, arazi örtüsü, topografya ve yüzey ısı özellikleri rüzgârın şiddet ve yönünü doğrudan etkiler. Gün içinde güneşlenme ve konveksiyonun artması sınır tabakasını kalınlaştırarak dikey karışımı güçlendirir, buna bağlı olarak rüzgâr daha homojen bir dikey profile kavuşur. Gece saatlerinde ise yüzeyin soğumasıyla oluşan stabil tabakalaşma, rüzgârın birkaç metre içerisinde belirgin şekilde yavaşlamasına ve yön değişimlerinin güçlenmesine neden olur. Bu nedenle rüzgâr, hem yatay hem dikey doğrultuda yüksek zamansal ve mekânsal değişkenlik gösteren, çok ölçekli bir atmosferik değişkendir.

Holton'un dinamik meteoroloji çerçevesinde ifade ettiği gibi rüzgâr, temelde üç ana kuvvetin etkileşimiyle ortaya çıkar: basınç gradyanı kuvveti, Dünya'nın dönüşüne bağlı Coriolis kuvveti ve yüzey sürtünmesi [1]. Basınç gradyanı kuvveti hava

kütlelerini hızlandıran temel mekanizmadır; Coriolis kuvveti ise hareket eden havanın yönünü enleme bağılı olarak sağa veya sola saptırır. Yüzey sürtünmesi ve pürüzlülük etkisi, özellikle sınır tabakasında rüzgâr şiddetini azaltarak rüzgârın yönünü üst seviyelere kıyasla daha çok değiştiren önemli bir mekanizmadır. Bu kuvvetlerin dengesi, rüzgârın hem büyüklüğünü hem yönünü belirleyen temel fiziksel çerçeveyi oluşturur.

Sonuç olarak rüzgâr, yalnızca basit bir yatay akış değil; güneş kaynaklı ısıl dengesizliklerin, atmosferin üç boyutlu dinamik yapısının, sınır tabakası süreçlerinin ve yüzey-atmosfer etkileşimlerinin birleşik etkisiyle ortaya çıkan karmaşık bir atmosferik harekettir. Bu nedenle rüzgârın zaman içinde gösterdiği değişkenlik, meteorolojik tahmin modelleri açısından en büyük belirsizlik kaynaklarından biri olmaya devam etmektedir.

1.2 Atmosferik Dinamikler ve Navier–Stokes Denklemi

Rüzgârın oluşumunu belirleyen fiziksel mekanizmalar, yüzeydeki sıcaklık ve basınç değişimleriyle sınırlı olmayan, çok daha kapsamlı bir atmosfer dinamiğinin sonucudur. Atmosfer, sıkıştırılabilir bir akışkan olarak hem yatay hem de dikey doğrultuda sürekli hareket hâlinde olup, bu hareketin matematiksel temeli akışkanlar dinamiğinin genel momentum denklemleriyle tanımlanır. Bu çerçevede atmosferin davranışı; Navier–Stokes denklemi, süreklilik denklemi ve termodinamik (gaz yasaları) ilişkilerinin birleşik etkisiyle açıklanmaktadır. Gill, atmosferik hareketlerin büyük ölçekten sınır tabakasına kadar tüm ölçeklerde bu temel fiziksel yasalar tarafından yönetildiğini vurgular [3]. Navier–Stokes denklemleri, Newton’un ikinci yasasının akışkanlar için yeniden yazılmış hâlidir ve hava kütlelerinin hızını artıran veya azaltan tüm kuvvetleri içerir. Atmosferik akım için kullanılan genel momentum Denklem 1.1’de görülebilir.

$$\rho \left(\frac{\partial \vec{u}}{\partial t} + (\vec{u} \cdot \nabla) \vec{u} \right) = -\nabla p + \mu \nabla^2 \vec{u} + \rho \vec{g} - 2\rho(\vec{\Omega} \times \vec{u}) \quad (1.1)$$

Bu denklemde yer alan terimler atmosferik akımın fiziksel bileşenlerini temsil eder:

1.2.1 Basınç gradyanı kuvveti :

Hava kütlelerini yüksek basınçtan alçak basınca doğru ivmelendiren temel kuvvettir. Atmosferin yatay dolaşımını başlatan ve sürdüren birincil mekanizmadır.

1.2.2 Coriolis kuvveti :

Dünya'nın kendi eksenini etrafındaki dönüşü nedeniyle ortaya çıkan ataletsel bir kuvvettir. Gill'nin belirttiği gibi, büyük ölçekli atmosferik akımın yönünü doğrudan belirler; kuzey yarımkürede akımı sağa, güney yarımkürede sola saptırır [3]. Geostrofik ve gradient rüzgârın oluşmasında temel rol oynar.

1.2.3 Viskoz/türbülanslı sürtünme :

Csanady'nin özellikle yüzey etkileşimli akımlarda ayrıntılı biçimde vurguladığı üzere, atmosfer tamamen laminar bir akışkan değildir; moleküler viskozite atmosferde çok küçük olsa da, türbülans sınır tabakasında baskın hâle gelir [4]. Bu nedenle viskoz terim, pratik atmosferik modellerde çoğunlukla türbülans parametreleri (K-teorisi, TKE tabanlı şemalar) ile temsil edilir.

1.2.4 Yerçekimi kuvveti :

Dikey momentum bileşenini belirler, hidrostatik denge ilişkisiyle sonuçlanır ve atmosferik basınç profilinin temel fiziksel nedenidir.

Bu denklemlerin birleşimi, atmosferin üç boyutlu hareketini tanımlayan en kapsamlı fiziksel çerçeveyi sunar. Ancak bu formun doğrudan çözümü, atmosferin hem türbülanslı doğası hem de çok büyük Reynolds sayıları nedeniyle son derece karmaşıktır. Bu nedenle Navier–Stokes denklemleri çoğu zaman ölçek indirgeme, ortalama alma (Reynolds ayrıştırması), parametrisasyon ve sayısal çözümlerle sadeleştirilerek uygulanır. Csanady, özellikle atmosfer yüzey etkileşimlerinin yoğun olduğu sınır tabakası akımlarında tam Navier–Stokes formunun çözümsel olarak uygulanabilir olmadığını, mutlaka parametrik türbülans modelleri gerektirdiğini belirtmektedir. Sonuç olarak rüzgâr, yalnızca basınç farklarından türeyen basit bir yatay akış değil; basınç gradyanı, Coriolis kuvveti, viskoz–türbülanslı sürtünme ve

yerçekimi arasındaki karmaşık dengenin bir ürünüdür. Bu fiziksel süreçlerin her biri, atmosferin hem yatay hem dikey dolaşımını şekillendirerek rüzgârın yüksek değişkenlik göstermesine ve tahmin edilmesinin güçleşmesine neden olmaktadır [3,4].

1.3 Atmosferik Sınır Tabakası, Türbülans ve Modelleme Zorlukları

Atmosferin alt 1–2 kilometrelik kısmını oluşturan Atmosferik Sınır Tabakası (ABL), rüzgârın hem zamansal hem de mekânsal değişkenliğinin en yoğun görüldüğü bölge olup, kısa vadeli rüzgâr tahmini açısından kritik bir öneme sahiptir. Garratt'ın belirttiği gibi ABL, yüzeyle doğrudan etkileşim içinde olduğu için, sürtünme, gizli ısı akıları, nem değişimleri ve arazi pürüzlülüğü gibi yüzey süreçlerine karşı oldukça duyarlıdır [5]. Bu nedenle rüzgâr şiddeti ve yönü, ABL içinde genellikle üst atmosfer katmanlarına kıyasla çok daha hızlı değişir.

Günlük güneşlenme döngüsü, ABL'nin termodinamik ve dinamik yapısını belirleyen başlıca mekanizmadır. Gündüz saatlerinde yüzey ısınmasıyla birlikte gelişen güçlü konvektif oluşum, türbülansı artırarak sınır tabakasının kalınlaşmasına ve dikey hız profiline daha homojen bir yapıya sahip olmasını sağlar. Bu koşullarda rüzgâr, yüzeyden yaklaşık birkaç yüz metre yükseklikte bile benzer hız karakteristikleri gösterebilir. Buna karşın gece saatlerinde yüzeyin hızla soğuması sonucunda oluşan kararlı sınır tabakası, dikey hızı büyük ölçüde zayıflatır ve yüzeye yakın birkaç metrelik tabakada rüzgâr şiddetinin dramatik şekilde azalmasına yol açar. Bu durum, özellikle gece ve sabahın erken saatlerinde hız gradyanları, düşük türbülans ve belirgin yön değişiklikleri ortaya çıkarır.

ABL'nin yapısı yalnızca ısı süreçleriyle değil, topografyanın mekânsal karakteristikleriyle de önemli ölçüde şekillenir. Vadi–tepe sistemleri, plato yüzeyleri, yerel eğimler ve arazi pürüzlülüğü, kanalizasyon etkisi, hızlanma yavaşlama bölgeleri ve türbülans üretimi gibi mekanizmalar aracılığıyla rüzgâr akımını belirgin biçimde modifiye edebilir. Bu nedenle ABL, hem mikroölçek hem mezoölçek süreçlerin eş zamanlı olarak etkili olduğu karmaşık bir atmosferik katmandır.

Lorenz'in atmosferik hareketlerin kaotik doğasına ilişkin bulguları, özellikle ABL içinde belirginleşmektedir [6]. Başlangıç koşullarındaki küçük farkların kısa zaman

dilimlerinde hızla büyümesi, ABL'deki rüzgâr akımlarının yüksek doğrusal olmayan bir yapıya sahip olduğunu göstermektedir. Bu nedenle ABL, kısa vadeli tahmin modellerinde hata büyümesinin en hızlı gerçekleştiği atmosferik katmandır.

Bauer modern sayısal hava tahmin modellerindeki büyük ilerlemelere rağmen, ABL'deki sürtünme, türbülans, arazi etkileri ve yüzey atmosfer akıları gibi küçük ölçekli süreçlerin hâlen deterministik olarak tam doğrulukla temsil edilemediğini vurgulamaktadır [7]. Bu süreçlerin parametrizasyonundaki eksiklikler, özellikle yüzeye yakın rüzgâr şiddetindeki tahmin hatalarının diğer atmosferik değişkenlere göre daha yüksek olmasına neden olmaktadır.

Sonuç olarak ABL, rüzgârın hem en yüksek değişkenliğe sahip olduğu hem de fiziksel süreçlerin en karmaşık şekilde etkileştiği atmosfer katmanı olduğundan, rüzgâr tahmini çalışmalarında belirsizliğin en yoğun görüldüğü bölgeyi temsil etmektedir.

1.4 Topografya, Yüzey–Atmosfer Etkileşimi ve Rüzgârın Dikey Profili

Kompleks topoğrafyada rüzgâr akışının davranışı, arazi eğimi, yönelimi ve pürüzlülük geçişleri nedeniyle ciddi biçimde değişmekte; vadilerde koridor etkisiyle hızlanma, sırt çizgilerinde akış ayrılması ve tepe arkası bölgelerde türbülans artışı gözlenmektedir. Bu süreçler, hem yüzey rüzgârı hem de düşük seviyeli jet oluşumları üzerinde belirleyici bir rol oynar. Belušić, kompleks arazi yapılarının rüzgâr alanını nasıl modifiye ettiğini detaylı biçimde göstermiş; özellikle vadilerdeki koridor etkisi, tepe arkası türbülans zonları ve topoğrafya kaynaklı hızlanma bölgelerinin kısa vadeli rüzgâr tahmininde sistematik hatalara yol açtığını ortaya koymuştur [8]. Batman Havzası gibi dağlık bölgelerde bu tür topoğrafik etkiler belirgin olduğundan, hem sayısal hava tahmini modelleri hem de istatistiksel yöntemler topoğrafya kaynaklı akış deformasyonlarına karşı duyarlıdır.

Rüzgârın dikey profili, yüzeye yakın atmosferdeki pürüzlülük, sürtünme ve türbülans süreçleri tarafından belirlenmektedir. Nötr atmosfer koşulları altında geniş ölçekte kabul gören logaritmik hız profili Denklem 1.2'de paylaşılmıştır.

$$U(z) = \frac{u_*}{\kappa} \ln \left(\frac{z}{z_0} \right) \quad (1.2)$$

Bu denklemde u_* yüzey sürtünme hızını, κ Von Kármán sabitini ve z_0 yüzey pürüzlülük uzunluğunu temsil eder. Emeis, bu profilin yalnızca nötr kararlılık koşullarında geçerli olduğunu ve atmosferin kararlı veya kararsız hâle gelmesi durumunda rüzgâr profilinin önemli ölçüde değiştiğini vurgular [9]. Kararlı koşullarda rüzgâr şiddetinin yüzeye yakın tabakalarda daha hızlı azaldığı; kararsız koşullarda ise akış yoğunluğunun artmasıyla profilin daha doygun hâle geldiği bilinmektedir. Dolayısıyla rüzgârın tahmini yalnızca atmosfer dinamiğini bilmekle değil; aynı zamanda yüzey atmosfer etkileşimini doğru modellemekle de yakından ilişkilidir.

Bu süreçlerin tamamı, atmosferin alt tabakalarında rüzgâr ölçümlerinin neden yüksek varyans gösterdiğini açıklamaktadır. Skamarock, yüzey türbülans etkileşimlerinin sayısal hava tahmin modellerinde hâlâ tam olarak çözülemeyen en kritik fiziksel süreçlerden biri olduğunu belirtmektedir [10]. Bu nedenle küçük ölçekli topografik etkiler, türbülansın parametrizasyonu ve yüzey pürüzlülüğünün doğru temsil edilememesi modellerin tahmin performansını doğrudan sınırlar.

Lynch ise atmosferik hareketlerin kaotik yapısının özellikle yüzeye yakın seviyelerde daha belirgin olduğuna dikkat çekerek, kısa vadeli rüzgâr tahminlerinde başlangıç koşullarına duyarlılığın son derece yüksek olduğunu ifade etmektedir [11]. Bu durum, hem fizik tabanlı hem istatistiksel hem de derin öğrenme yöntemleri için temelde bir sınırlayıcı unsur oluşturur. Dolayısıyla rüzgâr tahmininin başarısı, yalnızca atmosfer dinamiğinin anlaşılmasına değil, aynı zamanda yüzey atmosfer etkileşiminin doğru şekilde modellenmesine ve yerel topografyanın fiziksel etkilerinin yeterince temsil edilmesine bağlıdır.

Atmosferin kaotik doğası, Edward Lorenz'in çığır açıcı çalışmasıyla bilimsel olarak ortaya konmuş ve modern hava tahmininin temel kavramsal çerçevesini oluşturmuştur [6]. Lorenz, atmosferik hareketleri betimleyen diferansiyel denklemlerin deterministik olmasına rağmen, sistemin başlangıç koşullarına son derece duyarlı olduğunu; başlangıçtaki çok küçük farklılıkların dahi zaman içerisinde üstel büyüyerek çok büyük tahmin sapmalarına yol açtığını göstermiştir. Bu bulgu, literatürde “başlangıç koşullarına duyarlılık” ve “kelebek etkisi” kavramlarıyla anılmakta ve özellikle kısa vadeli rüzgâr tahminlerinde belirsizliğin temel fiziksel nedenini oluşturmaktadır.

Atmosferik akımların bu kaotik karakteri, rüzgâr gibi yüksek frekanslı, küçük ölçekli dalgalanmalara duyarlı ve türbülans tarafından güçlü şekilde modifiye edilen değişkenlerde daha belirgin hâle gelir. Pope atmosferik türbülansın çok ölçekli ve doğrusal olmayan yapısını ayrıntılı biçimde açıklayarak, enerjinin büyük ölçekli girdaplardan daha küçük ölçekli girdaplara bir “enerji şelalesi” mekanizmasıyla aktarıldığını ve bu sürecin rüzgârın kısa zaman ölçeklerindeki yüksek varyansının temel dinamiğini oluşturduğunu ortaya koymuştur hâle gelir [12]. Türbülansın bu çok ölçekliliği ile Lorenz’in tanımladığı kaotik davranış birleştiğinde, rüzgâr tahmininde başlangıç koşullarındaki en küçük ölçüm hataları, sensör gürültüsü, zamansal çözünürlük eksikliği veya veri kayıpları bile 30–180 dakika gibi kısa zaman aralıklarında ciddi tahmin sapmalarına dönüşebilmektedir. Bu nedenle atmosferin kaotik ve türbülanslı doğası, kısa vadeli rüzgâr tahminini meteorolojideki en zorlu problemlerden biri hâline getirmekte; hem sayısal hava tahmini modelleri hem de istatistiksel ve derin öğrenme tabanlı yöntemlerin performansını sınırlayan en temel fiziksel süreç olarak karşımıza çıkmaktadır hâle gelir.

1.5 NWP Modelleri ve Türbülansın Çok Ölçekli Yapısı

Atmosfer, mikroölçekten (1–100 m) sinoptik ve küresel ölçeklere (1000–10.000 km) kadar uzanan çok geniş bir uzaysal yelpazede birbirleriyle etkileşim hâlinde olan süreçlerle yönetilen karmaşık bir sistemdir. Rüzgâr alanı özellikle atmosferik sınır tabakası ölçeğinde (0–1000 m) güçlü türbülans, yüzey sürtünmesi ve topografik etkilerinin baskın olduğu yüksek derecede heterojen bir yapıya sahiptir. Bu ölçekte rüzgâr, vadilerde kanalize olabilir, dağ eteklerinde hızlanabilir veya yüzey pürüzlülüğündeki ani değişikliklere bağlı olarak küçük mesafelerde büyük varyans gösterebilir. Belušić, kompleks topoğrafyaya sahip bölgelerde rüzgâr akımının küçük ölçekli kanalize olma süreçleri tarafından şekillendiğini ve bu süreçlerin çoğu zaman birkaç yüz metre ile birkaç kilometre arasında sınırlı olduğunu göstermektedir [13]. Ancak küresel ve bölgesel sayısal hava tahmin (NWP) modellerinin tipik yatay çözünürlüğü 9–25 km aralığındadır. Bu ölçekte çalışan bir modelin 100–500 metrelik türbülans girdaplarını, vadi içi hızlanmaları veya yerel pürüzlülük değişimlerini doğrudan çözebilmesi fiziksel ve matematiksel olarak mümkün değildir. Bu nedenle

NWP modelleri, yüzeye yakın rüzgâr akımını gerçek fiziksel süreçleri çözerek değil, zorunlu olarak parametrik şemalar aracılığıyla temsil eder. Parametrizasyon ise küçük ölçekli türbülans, yüzey akıları ve topografik detayların istatistiksel yaklaşımlarla modele eklenmesi anlamına geldiği için, özellikle kompleks arazi koşullarında rüzgâr şiddetinde belirgin tahmin hatalarına yol açar. Bu durum, kısa vadeli operasyonel tahminlerin başarısını sınırlayan en önemli unsurlardan biri olarak meteorolojik literatürde geniş şekilde rapor edilmiştir.

Atmosferik sınır tabakasında türbülans, rüzgârın hem şiddetinde hem de yönünde yüksek derecede doğrusal olmayan dalgalanmalara yol açan temel bir fiziksel süreçtir. Türbülansın çok ölçekli yapısı nedeniyle, akım içerisindeki enerji büyük ölçekli girdaplardan daha küçük ölçekli girdaplara doğru karakteristik bir “enerji şelalesi” mekanizmasıyla aktarılır. Bu dinamik yapı, rüzgâr serisinin istatistiksel özelliklerini zaman içinde sürekli değişen ve ölçekler arası etkileşime açık bir hâle getirerek, ARIMA gibi doğrusal varsayımlara dayalı yöntemlerin tahmin kapasitesini doğal olarak sınırlar. Buna karşılık derin öğrenme tabanlı modeller, doğrusal olmayan paternleri temsil edebilme ve çok ölçekli ilişkileri veri üzerinden öğrenebilme yetenekleri sayesinde türbülansın karmaşık yapısını daha başarılı bir şekilde yakalayabilmektedir [14].

Sayısal Hava Tahmin (NWP) modelleri atmosferin dinamik yapısını Navier–Stokes denklemlerinin ayrıklaştırılmış çözümleriyle temsil eder; ancak bu denklemlerin tam çözümleri hem hesaplama maliyeti hem de atmosferin çok ölçekli karmaşık doğası nedeniyle pratik olarak mümkün değildir. Bu nedenle modeller, çözünürlüklerinin altında kalan fiziksel süreçleri (konveksiyon, bulut mikrofiziği, sınır tabakası türbülansı, yüzey-atmosfer akıları ve radyasyon süreçleri gibi) parametrizasyon şemaları aracılığıyla modele dâhil eder. Parametrizasyonun niteliği, bu süreçlerin doğrudan çözülmesi yerine ampirik ve istatistiksel ilişkilerle temsil edilmesine dayandığından, özellikle hızlı gelişen ve küçük ölçekli atmosferik olaylarda model performansını sınırlayan en önemli hata kaynaklarından birini oluşturur. Skamarock, konvektif bulutların, derin dikey hareketlerin ve sınır tabakası türbülansının NWP modellerinde hâlen deterministik olarak çözülemediğini; bu nedenle rüzgâr şiddetinin kısa zaman ölçeklerindeki ani değişimlerinin çoğu kez hatalı veya gecikmeli temsil edildiğini

vurgulamaktadır [10]. Konvektif fırtınaların etkili olduğu dönemlerde rüzgâr alanında gözlenen ani hızlanma ve yavaşlamalar, hem mekânsal hem de zamansal olarak birkaç yüz metre ve birkaç dakika ölçeğinde gerçekleştiğinden operasyonel modeller bu değişimleri doğrudan çözememektedir. ICAO'nun Wind Shear Manual'ına göre, bu tür ani rüzgâr değişimleri (wind shear) hem havacılık açısından kritik tehlike oluşturmakta hem de sayısal modellerdeki parametrisasyonların en zayıf performans gösterdiği koşullar arasında yer almaktadır [7,10,15].

Batman'ın da içinde bulunduğu Güneydoğu Anadolu Bölgesi, dağlık alanlar, vadiler ve plato yüzeyleriyle karakterize edilen belirgin bir topoğrafik çeşitlilik sergilemektedir. Panofsky ve Dutton, karmaşık topoğrafyanın atmosferik akımı hem şiddet hem yön açısından önemli ölçüde modifiye ettiğini; özellikle vadilerde rüzgârın kanalize olarak hızlanabileceğini, dağ yamaçlarında ise hızlanma yavaşlama bölgelerinin sıkça oluştuğunu belirtmektedir [16]. Bu tür topoğrafik yönlendirme ve hızlanma etkileri, sınır tabakası içinde türbülans üretimini artırarak rüzgâr hızının kısa zaman aralıklarında ani ve düzensiz değişimler göstermesine yol açar. Bu nedenle Batman gibi dalgalı topoğrafyaya sahip bölgelerde rüzgâr alanı hem mekânsal hem de zamansal olarak yüksek değişkenlik sergilemekte, bu durum da kısa vadeli rüzgâr tahmininde belirsizliği artırmaktadır.

Rüzgâr ölçüm cihazları belirli hassasiyete sahiptir. Ölçüm hatası küçük görünse bile kaotik yapının etkisiyle tahminde geometrik şekilde büyüyebilir. Bu nedenle istasyon verileri temizlenmeden modellemeye alınırsa tahmin hatası daha da artar.

1.6 Rüzgârın Enerji Sistemleri ve Havacılık Operasyonları Açısından Önemi

Rüzgâr, hem enerji sistemlerinin sürdürülebilir işletimi hem de havacılık operasyonlarında güvenilir karar alma süreçleri açısından stratejik öneme sahip bir meteorolojik değişkendir. Kısa zaman ölçeklerinde dahi yüksek değişkenlik göstermesi, enerji üretimi, uçuş güvenliği ve operasyonel planlama üzerinde belirgin belirsizlikler oluşturur. Bu nedenle rüzgâr şiddetinin ve yönünün güvenilir biçimde tahmin edilmesi; risk azaltma, sistem güvenilirliğini artırma ve operasyonel maliyetleri optimize etme açısından kritik bir gereklilik hâline gelmiştir.

Enerji sektöründe rüzgârın dalgalı doğası, rüzgâr enerjisi üretiminin zaman içinde önemli ölçüde değişmesine neden olur. Bu değişkenlik, özellikle rüzgâr santrallerinin elektrik şebekesine entegre olduğu durumlarda frekans istikrarsızlıkları, yedek kapasite ihtiyacının artması ve arz talep dengesizlikleri şeklinde kendini gösterebilir. Giebel, kısa vadeli rüzgâr tahminlerinin üretim planlamasında merkezi bir rol oynadığını; özellikle tahmin doğruluğunun artmasının enerji depolama stratejilerini, rezerv yönetimini ve şebeke kararlılığını doğrudan etkilediğini belirtmektedir [17]. Benzer şekilde Milligan, rüzgâr gücü tahmin hatalarının sistem işletmecileri için ek maliyetlere yol açtığını, dolayısıyla kısa vadeli rüzgâr tahmininin yenilenebilir enerji entegrasyonunun kritik bileşenlerinden biri olduğunu vurgulamaktadır [18]. Bu bağlamda doğru kısa vadeli rüzgâr tahmini; şebekede esneklik sağlanması, çevrim içi/çevrim dışı santral kararlarının optimize edilmesi, enerji depolama sistemlerinin verimli kullanılması ve genel işletme maliyetlerinin azaltılması açısından temel bir gereklilik olarak karşımıza çıkmaktadır.

Türkiye özelinde değerlendirildiğinde, T.C. Enerji ve Tabii Kaynaklar Bakanlığı tarafından yayımlanan 2023–2035 Ulusal Enerji Planı, elektrik üretiminde yenilenebilir enerji kaynaklarının payının 2035 yılına kadar yaklaşık %54–55 seviyesine çıkarılmasını hedeflemektedir [19]. Bu hedef, rüzgâr enerjisinin hem mevcut sahalarda daha verimli işletilmesi hem de yeni potansiyel bölgelerde güvenilir biçimde sisteme entegre edilmesi gerekliliğini ortaya koymaktadır. Türkiye Rüzgâr Enerjisi Birliği'nin (TÜREB) güncel istatistik raporuna göre, 2024 yılı sonu itibarıyla Türkiye'de toplam rüzgâr enerjisi kurulu gücü yaklaşık 13.792,50 MW'a ulaşmış olup bu kapasite toplam elektrik üretiminde yaklaşık yüzde 11,34 oranında bir paya sahiptir. 2024 yılı boyunca sisteme yaklaşık 1.310,07 MW yeni rüzgâr kapasitesi dahil edilmiştir [20]. Bu veriler, rüzgâr enerjisinin Türkiye elektrik sistemindeki artan rolünü ve yenilenebilir enerji üretimindeki stratejik konumunu göstermektedir.

Havacılık sektöründe rüzgâr tahmininin doğruluğu, uçuş operasyonlarının güvenliği ve sürekliliği açısından kritik bir rol oynar. Özellikle yüzeye yakın atmosferik tabakada meydana gelen wind shear, low level jet, crosswind ve ani rüzgâr yön ve şiddet değişimleri, uçuş emniyetini doğrudan tehdit eden meteorolojik olgulardır. FAA'nın vurguladığı üzere, yaklaşma, kalkış ve iniş gibi düşük irtifa manevralarında rüzgâr

profilindeki hızlı deęişimlerin pilot karar süreçlerini belirgin biçimde etkiledięi, hatta operasyonel limitlerin aşılması durumunda ciddi güvenlik riskleri oluşturabileceęi belirtilmektedir [21]. Yüzeye yakın rüzgâr profilinin dikey yapısı, topoğrafya, yüzey pürüzlülüęü, termal yapı ve sınır tabakası kararlılıęı gibi faktörlerle güçlü biçimde modüle edilir. Lin, havacılık operasyonları için uygun rüzgâr profil modellerinin geliştirilmesinin, özellikle karmaşık arazi koşullarına sahip meydanlarda rüzgâr akışının kısa mesafelerde bile önemli ölçüde deęişebilmesinden dolayı hayati önem taşıdığını göstermektedir [22]. Batman gibi topoğrafyanın belirgin olduęu bölgelerde rüzgârın yönü ve şiddeti kısa zaman ölçeklerinde yüksek varyans gösterebildiğinden, yüksek çözünürlüklü gözlem verilerinin analizi ve uygun tahmin modellerinin kullanılması uçuş güvenlięi ve operasyonel risk yönetimi açısından vazgeçilmez bir gereklilik hâline gelmektedir.

1.7 Kısa Vadeli Rüzgâr Tahmin Yöntemleri: ARIMA, ANN ve LSTM

Rüzgâr tahmininde yaygın olarak kullanılan istatistiksel yöntemlerin temelini oluşturan ARIMA (Autoregressive Integrated Moving Average) modeli, George Box ve Gwilym Jenkins'in 1970 yılında yayımladıkları klasik eserle bilimsel literatüre kazandırılan "Box-Jenkins Metodolojisi"ne dayanmaktadır [23]. Bu metodoloji, zaman serilerinin yapısal özelliklerini sistematik biçimde inceleyerek uygun model sınıfının belirlenmesini, parametre tahmininin yapılmasını ve modelin geçerliliğinin artık analizleriyle test edilmesini içeren bütüncül bir yaklaşım sunar. Box-Jenkins çerçevesi; serinin durağanlaştırılması, otoregresif ve hareketli ortalama terimlerinin sırasının belirlenmesi, maksimum olabilirlik veya en küçük kareler yöntemleriyle parametre tahmini ve modelin diagnostik kontrollerden geçirilmesi gibi aşamalardan oluşur. ARIMA modeli, doğrusal stokastik süreçlerin matematiksel yapısını temsil ettięi için özellikle istasyonier veya fark alma yoluyla zaman serilerinde kısa vadeli tahmin açısından yüksek performans göstermektedir. Model, geçmiş deęerlere olan bağımlılıęı (AR kısmı), serideki birikimli eğilim veya durağan olmama durumlarını (I kısmı) ve hata terimlerindeki otokorelasyonu (MA kısmı) birlikte ele alarak, zaman serisinin iç dinamiklerini kompakt bir biçimde yakalamayı amaçlar. Bu nedenle ARIMA, rüzgâr gibi yüksek frekanslı deęişkenlerde tam anlamıyla yeterli olmasa da,

doğrusal bileşenlerin güçlü olduğu birçok uygulamada hâlen başvuru yöntemlerinden biri olarak kullanılmaktadır.

ARIMA ve ARMA modellerinin meteorolojik uygulamalarda kullanılmaya başlanması 1980'li yıllara uzanmaktadır. Bu dönemde atmosferik zaman serilerinin, özellikle sıcaklık, basınç ve rüzgâr şiddetinin belirli otokorelasyon yapıları içerdiği görülmüş; böylece Box–Jenkins metodolojisinin meteorolojik tahmin problemlerine uyarlanabileceği anlaşılmıştır. Rüzgâr şiddetinin kısa vadeli tahmini üzerine yapılan erken dönem çalışmalardan biri olan Alexiadis, AR ve ARMA modellerinin rüzgâr şiddetinin stokastik yapısını başarılı biçimde temsil ettiğini ve kısa vadeli tahminlerde yüksek doğruluk elde edilebildiğini ortaya koymuştur [24]. Bu çalışma, istatistiksel zaman serisi modellerinin rüzgâr enerjisi ve hava tahmini alanlarında güvenilir bir yöntem olarak benimsenmesinde önemli bir kilometre taşı olmuş; ARIMA ailesi modellerinin meteorolojik verilerdeki doğrusal bileşenleri yakalamadaki etkinliğini akademik anlamda kanıtlamıştır.

ARIMA'nın en önemli avantajlarından biri uygulanabilirliğinin kolay olmasıdır. Model parametrelerinin uygun seçilmesi hâlinde seri içindeki doğrusal yapıyı yakalayabilir. Ancak ARIMA'nın doğrusal olmayan süreçlerde performansı düşmekte; türbülans, konveksiyon, ani rüzgâr değişimleri gibi fiziksel süreçleri temsil etmede yetersiz kalmaktadır. Bu nedenle istatistiksel modeller, özellikle rüzgâr şiddeti gibi yüksek varyanslı meteorolojik değişkenlerde tek başına yeterli olamamıştır.

Yapay sinir ağlarının temeli, Frank Rosenblatt'ın 1957–1958 yılları arasında geliştirdiği ve Psychological Review dergisinde yayımlanan klasik Perceptron modeline dayanmaktadır [25]. Rosenblatt'ın Perceptron'u, biyolojik nöronların çalışma prensibini matematiksel bir yapıda temsil etmeye yönelik ilk sistematik girişim olup yapay zekâ araştırmalarında önemli bir başlangıç noktası oluşturmuştur. Bununla birlikte Perceptron yalnızca doğrusal olarak ayrılabilen problemleri çözebildiğinden, 1960'lı yılların sonunda çok katmanlı ağların eğitilememesi nedeniyle sinir ağları araştırmaları yaklaşık yirmi yıl boyunca duraklama dönemine girmiştir. Bu durağanlık, 1986 yılında Rumelhart, Hinton ve Williams tarafından geliştirilen geri yayılım (backpropagation) algoritması ile sona ermiştir. Bu çalışma ile çok katmanlı sinir

ağlarının eğitilebilmesini mümkün kılmış, böylece yapay sinir ağlarının hem teorik hem de uygulamalı alanlarda yeniden merkezi bir konuma taşınmasını sağlamıştır [26].

1990'lı yıllardan itibaren ANN modelleri meteorolojik zaman serilerine uygulanmaya başlanmış; özellikle türbülans, konveksiyon, yüzey atmosfer etkileşimi gibi doğrusal olmayan süreçlerin öğrenilmesinde istatistiksel modellere kıyasla daha yüksek başarı elde edilmiştir. Kalogirou tarafından gerçekleştirilen çalışma, yapay sinir ağlarının enerji ve atmosferik süreçlerdeki doğrusal olmayan ilişkileri etkili biçimde temsil edebildiğini ve kısa vadeli tahmin problemlerinde güçlü bir alternatif sunduğunu göstermiştir [27]. ANN modellerinin en önemli avantajı, doğrusal olmayan ilişkileri temsil edebilme kapasitesi ve karmaşık fiziksel süreçlerin “öğrenilmiş temsillerini” oluşturabilmesidir. Bununla birlikte, klasik ANN yapılarının zamana bağımlı bilgiyi uzun süre tutamaması, ardışık ilişkileri modelleme konusunda sınırlamalara yol açmıştır. Bu eksiklik daha sonra uzun kısa süreli bellek (LSTM) gibi gelişmiş ağ mimarilerinin ortaya çıkmasına zemin hazırlamış ve derin öğrenme modellerinin zaman serisi tahmininde yeni bir dönem başlatmasına katkı sağlamıştır.

Rüzgâr şiddetinin tahmin edilmesinde modern derin öğrenme yöntemleri arasında çığır açıcı bir yere sahip olan LSTM (Long Short-Term Memory) modeli, 1997 yılında Sepp Hochreiter ve Jürgen Schmidhuber tarafından geliştirilmiştir [28]. LSTM mimarisi, klasik tekrar eden sinir ağı (RNN) yapılarının uzun süreli bağımlılıkları öğrenmesini engelleyen “vanishing gradient” problemini çözmek amacıyla tasarlanmıştır. RNN modelleri ardışık veriler üzerinde güçlü bir temsil kapasitesine sahip olmalarına karşın, gradyanların zaman içinde hızla küçülmesi nedeniyle özellikle uzun süreli bellek gerektiren verilerde öğrenme başarısı büyük ölçüde düşmektedir. LSTM, bu sorunu “unutma kapısı”, “giriş kapısı” ve “çıkış kapısı” gibi özel kapı mekanizmalarıyla aşarak hem kısa süreli dalgalanmaları hem de uzun süreli bağımlılıkları aynı yapıda tutabilen bir bellek hücresi geliştirmiştir. Bu kapı sistemleri sayesinde LSTM modeli, zaman içinde hangi bilginin saklanacağına, güncelleneceğine veya silineceğine dinamik olarak karar verebilmekte; böylece karmaşık zaman serilerindeki çok ölçekli yapıları etkili biçimde öğrenebilmektedir.

Meteorolojik zaman serilerinde, özellikle rüzgâr şiddetinde, hem türbülans kaynaklı yüksek frekanslı değişimler hem de daha büyük ölçekli atmosferik süreçlerin etkisi bulunduğundan, LSTM mimarisinin çok ölçekli bağımlılıkları yakalama kapasitesi önemli bir avantaj sunmaktadır. LSTM'nin rüzgâr tahminlerinde uygulanmaya başlamasının dönüm noktalarından biri Liu tarafından gerçekleştirilen çalışma olup, saatlik rüzgâr şiddeti tahmininde LSTM modellerinin geleneksel ANN ve ARIMA yöntemlerine kıyasla belirgin biçimde daha yüksek doğruluk sağladığı gösterilmiştir [29]. Bu bulgu, LSTM modellerinin doğrusal olmayan atmosferik süreçleri temsil etme gücünü ve kısa vadeli tahmin performansını ortaya koyarak, LSTM'nin meteoroloji alanında standart ve güvenilir bir araç hâline gelmesinde kritik bir rol oynamıştır.

Modern literatür, tekil modellerin rüzgâr şiddetindeki çok ölçekli değişimleri temsil etmede yetersiz kalabildiğini ve özellikle türbülans, konveksiyon, yüzey atmosfer etkileşimi ile NWP parametrisasyon hatalarının birleşik etkisini yakalayabilmek için hibrit yaklaşımların giderek daha yaygın hâle geldiğini göstermektedir. Bu hibrit modeller, fizik tabanlı yöntemlerin dinamik yapısını veri odaklı derin öğrenme tekniklerinin esnekliği ile birleştirilerek tahmin doğruluğunda belirgin artış sağlamaktadır. Zhang tarafından geliştirilen CNN-GRU (Convolutional Neural-Gated Recurrent Unit) tabanlı hibrit model, kısa vadeli rüzgâr şiddeti tahmininde geleneksel derin öğrenme yapılarına göre daha yüksek performans elde etmiş ve özellikle ani rüzgâr değişimlerinin olduğu dönemlerde doğruluğu artırmıştır [30]. Benzer şekilde Li, sayısal hava tahminlerinden elde edilen rüzgâr şiddetini derin öğrenme tabanlı bir yaklaşımla kalibre ederek NWP hatalarının özellikle konvektif dönemlerde önemli ölçüde azaltılabildiğini göstermiştir [31]. Bu çalışma, rüzgâr tahmininde fizik tabanlı modellerin (NWP) ürettiği sistematik hataların derin öğrenme yöntemleriyle düzeltilebileceğine dair güçlü kanıtlardan biri olarak literatürde önemli bir yere sahiptir. Ayrıca Liu tarafından önerilen adaptif LSTM mimarisi, zaman serisi içerisindeki değişen dinamiklere uyum sağlayarak klasik LSTM modellerine göre daha düşük hata değerleri üretmiş ve rüzgâr tahmini çalışmalarında önemli bir gelişme sunmuştur [32]. Bu sonuçlar hibrit modellerin, hem fiziksel süreçleri hem de veri odaklı öğrenmeyi bir arada kullanarak modern rüzgâr tahmininde standart hâline gelmeye başladığını göstermektedir. Modern literatür, rüzgâr tahmini için

tekil modellerin atmosferin çok ölçekli yapısını temsil etmekte yetersiz kaldığını ve hibrit yaklaşımların giderek daha yaygın hâle geldiğini göstermektedir. Bu hibrit modeller, fizik tabanlı yöntemlerin (özellikle NWP çıktılarının) sağladığı dinamik bilgiyi, derin öğrenme mimarilerinin esnek ve veri odaklı öğrenme kapasitesiyle birleştirerek tahmin doğruluğunu anlamlı biçimde artırmaktadır. Rasp ve Thuerey tarafından ortaya konan çalışma, derin öğrenmenin NWP model hatalarını sistematik biçimde düzeltebildiğini ve özellikle konvektif süreçlerin etkili olduğu dönemlerde önemli iyileşmeler sağladığını göstermiştir [33]. Bunun yanında GAN tabanlı mimariler, rüzgârın yüksek frekanslı değişkenliğini daha gerçekçi simüle edebilme potansiyeli nedeniyle kısa vadeli tahminlerde dikkat çeken sonuçlar üretmektedir [34]. Transformer tabanlı modeller ise uzun süreli bağımlılıkları daha etkin biçimde yakalayabilme kapasiteleri sayesinde rüzgâr şiddetinin hem kısa hem uzun vadeli bileşenlerini aynı anda öğrenebilmektedir [35]. Ayrıca Graph Neural Network (GNN) tabanlı modeller, rüzgâr alanlarının mekânsal bağlantılarını doğrudan öğrenerek yüksek çözünürlüklü bölgesel tahminlerde önemli kazanımlar sağlamaktadır [36]. Bu gelişmeler, rüzgâr tahmininde hibrit ve derin öğrenme tabanlı yaklaşımların modern meteoroloji ve enerji sistemlerinde standart hâle gelmeye başladığını göstermektedir.

Rüzgâr şiddeti tahmini, hem yenilenebilir enerji teknolojilerinin verimli işletimi hem de havacılık operasyonlarının emniyetli şekilde yürütülmesi açısından stratejik bir öneme sahiptir. Bunun temel nedeni, rüzgârın hem zamansal hem de mekânsal olarak yüksek derecede değişkenlik göstermesi, atmosferik sınır tabakasındaki türbülansın baskın etkileri ve atmosferin kaotik yapısı nedeniyle tahmin hatalarının kısa sürelerde hızlı biçimde büyümesidir. Batman Meydan Meteoroloji İstasyonu, plato yüzeyi, vadi etkileri, arazi pürüzlülüğündeki ani değişimler ve konvektif süreçlerin belirginliği nedeniyle rüzgâr tahmini açısından zorlayıcı bir mikroölçek atmosferik çevre sunmaktadır. Bu nedenlerle Batman Meydan için yüksek çözünürlüklü rüzgâr tahmini çalışmaları hem bilimsel hem de operasyonel açıdan ehemmiyet arz etmektedir.

1.8 Tezin Amacı, Kapsamı ve Yapısı

Bu çalışmanın temel amacı, kısa vadeli rüzgâr tahminine yönelik geliştirilen istatistiksel ve derin öğrenme tabanlı modellerin performanslarını karşılaştırmalı

olarak incelemek ve farklı zaman çözünürlüklerinde model davranışlarını ortaya koymaktır. Bununla birlikte çalışma, rüzgâr enerjisi tahminini yalnızca meteorolojik doğruluk problemi olarak ele almakla sınırlı kalmayarak, elde edilen tahmin çıktılarının enerji sistemleri ve yenilenebilir enerji entegrasyonu bağlamındaki potansiyel etkilerini kavramsal düzeyde tartışmayı amaçlamaktadır. Günümüzde rüzgâr enerjisi gibi değişken yenilenebilir enerji kaynaklarının elektrik üretimindeki payının artması, kısa vadeli tahmin doğruluğunu yalnızca teknik bir modelleme problemi olmaktan çıkararak enerji piyasası dengesi, sistem işletme güvenliği ve üretim planlaması açısından kritik bir unsur hâline getirmiştir [37].

Kısa vadeli rüzgâr tahmin hataları, üretim programlarının sapmasına, sistem işletmecisinin daha fazla dengeleme rezervi ayırmasına ve piyasa mekanizmalarında belirsizlik artışına neden olabilmektedir. Literatürde, tahmin doğruluğundaki iyileşmenin şebeke esnekliği, rezerv yönetimi, santral işletme kararları ve genel işletme maliyetleri üzerinde belirleyici rol oynadığı vurgulanmaktadır [38]. Bu bağlamda rüzgâr enerjisi tahmini, yalnızca üretim miktarının öngörülmesi değil, enerji sistemlerinin daha öngörülebilir biçimde işletilmesini destekleyen temel bir bileşen olarak değerlendirilmektedir.

Enerji piyasası perspektifinden bakıldığında, kısa vadeli tahmin hataları pozitif ve negatif dengesizlik mekanizmalarının oluşmasına zemin hazırlamakta; bu durum sistemde dengeleme ihtiyacını artırmakta ve kaynak kullanım verimliliğini etkilemektedir. Bu çalışmada dengesizlik mekanizmaları doğrudan sayısal olarak modellenmemekle birlikte, rüzgâr tahmin doğruluğunun artmasının dengesizliklerin azaltılmasına katkı sağlayabilecek yapısal bir unsur olduğu literatür çerçevesinde tartışılmaktadır. Dolayısıyla çalışma, rüzgâr tahminini enerji piyasası işleyişi ve sistem dengesi bağlamında kavramsal bir çerçeveye yerleştirmektedir.

Türkiye özelinde değerlendirildiğinde, yenilenebilir enerji politikaları ve uzun vadeli üretim hedefleri, bu tür çalışmaların stratejik önemini artırmaktadır. 2023–2035 Ulusal Enerji Planı’nda elektrik üretiminde yenilenebilir enerji kaynaklarının payının artırılmasının hedeflenmesi, rüzgâr enerjisinin güvenilir ve öngörülebilir biçimde sisteme entegrasyonunu önemli bir ihtiyaç hâline getirmektedir [39]. TÜREB ve

TWEA raporlarında Türkiye’de rüzgâr enerjisi kurulu gücünün bölgesel dağılımı ve teknik potansiyelin henüz tam olarak değerlendirilememiş alanları ortaya konulmakta; bu durum saha bazlı ve yüksek çözünürlüklü tahmin çalışmalarının önemini güçlendirmektedir [40].

Bu durumlar göz önüne alınarak, farklı matematiksel ve yapay zekâ yaklaşımlarının kısa vadeli rüzgâr tahmini üzerindeki performanslarını karşılaştırarak hangi modelin daha düşük hata, daha yüksek kararlılık ve operasyonel uygulanabilirlik açısından üstün olduğunu ortaya koymaktır. Bu kapsamda üç temel model sınıfı seçilmiştir:

- ARIMA, doğrusal istatistiksel zaman serisi modeli,
- ANN, doğrusal olmayan ilişkileri öğrenebilen çok katmanlı yapay sinir ağı,
- LSTM, uzun zaman bağımlılıklarını koruyabilen derin öğrenme tabanlı seri modeli.

Bu üç model meteorolojik zaman serisi yaklaşımındaki üç ana paradigmayı temsil etmektedir (doğrusal modeller, klasik yapay sinir ağları, derin öğrenme tabanlı ardışık ağlar). Çalışmanın özgün yönlerinden biri, modellerin yalnızca tek bir zaman çözünürlüğünde değil; 1 dk, 5 dk, 10 dk, 30 dk ve 60 dk olmak üzere beş farklı zaman ölçeğinde uygulanmasıdır. Böylece rüzgârın mikroölçek (1–5 dk), kısa mezoölçek (10–30 dk) ve saatlik ölçeklerdeki dinamik yapısı ayrı ayrı incelenmiş, modellerin ölçek duyarlılığı karşılaştırmalı olarak değerlendirilmiştir. Batman gibi rüzgâr şiddetinde ani değişimler olan ve türbülansın belirgin olduğu bölgelerde bu çok ölçekli yaklaşım, modellerin gerçek operasyon koşullarındaki performansını anlamak açısından kritik öneme sahiptir. Batman Havalimanı’nda özellikle konvektif yağış geçişlerinin yaşandığı dönemlerde rüzgâr tahminlerinde düzensizlikler ve kısa süreli ani sapmaların görüldüğü bilinmektedir; bu nedenle daha güvenilir, daha hassas ve operasyonel açıdan uygulanabilir tahmin yöntemlerine duyulan ihtiyaç giderek artmaktadır. Bu kapsamda, TAF ve SHT tahminleri METAR tahakkuk verileriyle sistematik biçimde karşılaştırılmış ve incelenen dönemlerde tahakkuk başarı oranlarında belirgin azalmalar gözlenmiştir. Bu bulgu, mevcut operasyonel tahmin sistemlerinin özellikle kısa vadeli rüzgâr şiddeti tahminlerinde iyileştirmeye ihtiyaç duyduğunu göstermektedir. Bu nedenle üç farklı model kullanılarak tahmin kalitesinin artırılması hedeflenmiş ve modellerden elde edilen çıktılar gerçek zamanlı

gözlem verileriyle karşılaştırılarak kapsamlı performans değerlendirmesi yapılmıştır. Analizlerde MAE, RMSE ve R^2 performans ölçütleri kullanılarak modellerin doğruluğu, tutarlılığı ve hata davranışları detaylı biçimde incelenmiştir. Bu çalışmanın sonunda, Batman için kısa vadeli rüzgâr şiddeti karşılaştırmasında hangi modelin en yüksek performansı sergilediği belirlenmiş, farklı zaman çözünürlüklerinin model başarısına etkisi değerlendirilmiş ve havalimanı operasyonları ile enerji planlaması açısından kullanılabilir sonuçlar ortaya konmuştur.

Bu bağlamda tez kapsamında izlenen yöntem adımları aşağıda özetlenmektedir. Öncelikli olarak literatür çalışmasına yer verildikten sonra çalışma kapsamında ele alınan tarih aralıkları, operasyonel METAR ve TAF tahminlerinin kendi içlerinde tahakkuk verileri ile karşılaştırılması sonucunda, özellikle oraj geçişleri, cephe ve sistem etkilerinin belirgin olduğu ve tahminler arasında görece uyumsuzlukların gözlemlendiği dönemler arasından seçilmiştir. Bu yönüyle belirlenen beş farklı tarih aralığı, kısa vadeli rüzgâr tahmininin meteorolojik açıdan en zorlayıcı olduğu ve model performanslarının anlamlı biçimde sınanabildiği koşulları temsil etmektedir. Seçilen bu dönemlere ait ham gözlemler kalite kontrolden geçirilmiş, eksik ve hatalı kayıtlar temizlenmiştir. Ardından bu veriler, çalışmanın çok ölçekli yapısını yansıtacak biçimde 1 dk, 5 dk, 10 dk, 30 dk ve 60 dk zaman çözünürlüklerine yeniden örneklenmiş; her bir çözünürlük için ayrı rüzgâr zaman serileri oluşturulmuştur. Bu aşamada, istasyon konumu, topoğrafik özellikler ve seçilen dönemlerin meteorolojik karakteristikleri de kısaca tanımlanacaktır.

Daha sonra, her bir zaman çözünürlüğü için ARIMA, ANN ve LSTM modellerinin kurulumu gerçekleştirilmiş, eğitim doğrulama test ayrımları, girdi/çıkış yapıları ve model hiperparametreleri sistematik biçimde tanımlanmıştır. Modelleme sürecinde, meteorolojik değişkenlerin rüzgâr tahminine olan katkılarını aşamalı olarak ortaya koyabilmek amacıyla kademeli bir girdi yapısı benimsenmiştir. İlk aşamada yalnızca rüzgâr değişkeni kullanılarak temel tahmin performansları değerlendirilmiş; ardından rüzgâr-sıcaklık kombinasyonu ile termodinamik etkilerin modele katkısı incelenmiştir. Takip eden aşamada rüzgâr, sıcaklık ve basınç değişkenlerinden oluşan çok değişkenli yapı ele alınarak atmosferik dinamiklerin tahmin başarısına olan etkisi analiz edilmiştir. Son aşamada ise atmosferik süreçlerin daha bütüncül biçimde temsil edi-

lebilmesi amacıyla rüzgâr, sıcaklık, basınç, bağıl nem ve yağış değişkenlerinin birlikte kullanıldığı beş değişkenli modelleme çalışmaları gerçekleştirilmiştir. Bu yaklaşım sayesinde, artan girdi çeşitliliğinin farklı zaman çözünürlüklerinde kısa vadeli rüzgâr tahmin performansı üzerindeki etkileri sistematik olarak değerlendirilmiş; özellikle konvektif ve türbülanslı koşullar altında modellerin davranışları ayrıntılı biçimde ortaya konulmuştur.

Modellerden elde edilen kısa vadeli rüzgâr tahminlerinin performans analizinde MAE, RMSE ve R^2 ölçütleri esas alınmış ayrıca modellerin farklı zaman ölçeklerindeki davranışları, hataların konvektif dönemlerdeki değişimi ve Batman Meydanı'nın türbülanslı koşullarına verdikleri tepki ayrıntılı biçimde incelenecektir. Böylece, hem yöntemsel olarak izlenen adımlar açıklığa kavuşturulmakta hem de ilerleyen bölümlerde sunulacak ayrıntılı analizlere bir çerçeve çizilmektedir.

Bu tez kapsamında yürütülen çalışma, rüzgâr enerjisi tahminini yalnızca model performansı açısından değil, yenilenebilir enerji sistemlerinin güvenli ve sürdürülebilir biçimde işletilmesine katkı sağlayabilecek bir bilimsel altyapı olarak ele almaktadır. Geliştirilen modeller, doğrudan piyasa mekanizmalarını modellememekle birlikte, enerji üretim şirketleri ve sistem işletmecileri açısından daha öngörülebilir üretim planlaması, daha dengeli sistem yönetimi ve daha güvenilir yenilenebilir entegrasyonu için kullanılacak bilimsel bir referans çerçevesi sunmaktadır. Bu yönüyle çalışma, rüzgâr enerjisi tahminini yalnızca meteorolojik bir çıktı değil, enerji sistemlerinin planlama ve yönetim süreçlerini destekleyen bilimsel bir karar destek girdisi olarak konumlandırmaktadır.



2. LİTERATÜR

2.1 Kısa Vadeli Rüzgâr Tahminine Genel Bakış

Kısa vadeli rüzgâr tahmini, atmosferik süreçlerin kaotik doğası, türbülansın çok ölçekli yapısı ve topoğrafik etkileşimlerin karmaşıklığı nedeniyle meteorolojinin en zorlu tahmin problemlerinden biridir. Rüzgâr akımının temel dinamikleri Navier–Stokes denklemlerinin tanımladığı, başlangıç koşullarına aşırı duyarlı bir sistemdir ve Lorenz’in kaos teorisinin ortaya koyduğu üzere küçük ölçekli atmosferik bozulmalar çok kısa sürede büyük farklılıklara neden olabilir [6]. Bu nedenle rüzgâr şiddetinin dakikalık ve saatlik ölçeklerde tahmini, atmosferin düşük frekanslı davranışını modellemekten çok, yüksek frekanslı türbülans ve konvektif süreçlerin etkilerini temsil etmeye bağlıdır.

Kısa vadeli rüzgâr tahmini genellikle 1 dakika ile 3 saat arasındaki zaman dilimlerini içerir ve bu ölçeklerde atmosferik süreçler büyük ölçüde ABL içinde gerçekleşir. ABL’nin yapısı, yüzey pürüzlülüğü, topoğrafya, arazi eğimi, yüzey ısı akıları ve mekanik karışım gibi etkenlerle sürekli değişim hâlinindedir [5,9]. Türbülans, rüzgâr akışının içsel bir özelliği olarak rüzgâr şiddetinin yüksek frekanslı bileşenlerini domine eder ve bu nedenle kısa vadeli tahmin modellerinin performansını doğrudan etkiler [16].

Rüzgâr tahmini literatüründe kullanılan yöntemler tarihsel olarak üç ana grupta toplanmıştır: doğrusal istatistiksel modeller (AR, ARMA, ARIMA), yapay sinir ağları (ANN) gibi doğrusal olmayan makine öğrenmesi yöntemleri ve LSTM gibi modern derin öğrenme yöntemleri. Bu yöntemlerin bir kısmı yalnızca zamansal bağımlılıkları hedeflerken, diğerleri atmosferik süreçlerin doğrusal olmayan ilişkilerini öğrenmeyi amaçlar.

Enerji ve havacılık sektörleri kısa vadeli rüzgâr tahminine en fazla ihtiyaç duyan alanlardır. Enerji sektöründe rüzgâr şiddetindeki küçük sapmalar bile güç üretiminde

büyük deęişikliklere neden olurken [17,18], havacılık sektöründe özellikle wind shear ve ani rüzgâr deęişimleri operasyonel güvenlięi doğrudan etkiler [15]. Bu nedenle literatürde kısa vadeli tahmin yöntemlerini deęerlendiren çalışmaların çoęu hem operasyonel meteoroloji hem de yenilenebilir enerji planlaması için kritik bilgiler sunmaktadır.

2.2 Rüzgâr Enerjisi Tahmininin Sistemsel Önemi

Rüzgâr enerjisi tahmini, modern enerji sistemlerinde yalnızca meteorolojik bir öngörü faaliyeti olarak deęil, üretimden tüketime uzanan tüm enerji zincirini yönlendiren stratejik bir karar destek mekanizması olarak konumlanmaktadır. Yenilenebilir enerji kaynaklarının elektrik üretimi içindeki payının artması, kısa vadeli tahmin doğruluęunu yalnızca teknik bir modelleme problemi olmaktan çıkararak enerji piyasası dengesi, sistem işletme güvenlięi ve üretim planlaması açısından kritik bir unsur hâline getirmiştir. Bu bağlamda rüzgâr enerjisi tahmini, yalnızca üretim miktarının öngörülmesi deęil, enerji sistemlerinin daha öngörülebilir biçimde işletilmesini destekleyen yapısal bir bileşen olarak deęerlendirilmektedir [37,38].



Enerji üretim şirketleri açısından rüzgâr tahmini, santral işletmecilięinin operasyonel yönetiminde belirleyici bir role sahiptir. Üretimin doğrudan kontrol edilememesi, işletme süreçlerini büyük ölçüde öngörü kapasitesine baęımlı hâle getirmekte; tahmin doğruluęu türbin yük dağılımı, bakım planlaması, üretim süreklilięi ve ekipman yıpranması gibi süreçler üzerinde dolaylı etki oluşturmaktadır. Bu nedenle rüzgâr enerjisi tahmini, yalnızca meteorolojik bir çıktı deęil, santral işletme verimlilięini destekleyen bütüncül bir yönetim girdisi olarak deęerlendirilmektedir [41,42].

Yüksek yenilenebilir enerji penetrasyonuna sahip enerji sistemlerinde üretim–tüketim dengesi dinamik bir yapı sergilemekte, özellikle rüzgâr gibi deęişken üretim kaynaklarının entegrasyonu sistem geçişlerini daha karmaşık hâle getirmektedir. Bu geçiş süreçlerinde frekans dalgalanmaları, gerilim kararsızlıkları ve ani rezerv ihtiyacı gibi teknik riskler ortaya çıkabilmekte; kısa vadeli tahmin doğruluęu bu risklerin yönetilebilir hâle gelmesinde yapısal bir rol üstlenmektedir. Bu yönüyle rüzgâr tahmini, yalnızca üretim planlaması açısından deęil, doğrudan şebeke kararlılıęı ve sistem güvenlięi açısından da temel bir bileşen olarak konumlanmaktadır [43,44].

Enerji piyasası perspektifinden bakıldığında, kısa vadeli rüzgâr tahmin hataları pozitif ve negatif dengesizlik mekanizmalarının oluşmasına zemin hazırlamakta; bu durum sistemde dengeleme ihtiyacını artırmakta ve kaynak kullanım verimliliğini etkilemektedir. Rüzgâr tahmin doğruluğunun artması, bu dengesizliklerin azaltılmasına katkı sağlayarak piyasa istikrarını ve sistem işletme güvenliğini destekleyen yapısal bir unsur olarak değerlendirilmektedir [45,46].


Türkiye özelinde değerlendirildiğinde, yenilenebilir enerji politikaları ve uzun vadeli üretim hedefleri, rüzgâr enerjisinin güvenilir ve öngörülebilir biçimde sisteme entegrasyonunu stratejik bir gereklilik hâline getirmektedir. 2023–2035 Ulusal Enerji Planı’nda yenilenebilir enerji kaynaklarının payının artırılmasının hedeflenmesi, rüzgâr enerjisinin enerji arz güvenliği açısından taşıdığı önemi açık biçimde ortaya koymaktadır [39]. Bu bağlamda rüzgâr enerjisi tahmini, yalnızca teknik bir modelleme alanı değil, ulusal enerji sistemlerinin sürdürülebilir biçimde yapılandırılmasına katkı sağlayan bilimsel bir altyapı olarak değerlendirilmektedir (Şekil 2.1).

Bu çalışma kapsamında geliştirilen kısa vadeli rüzgâr tahmin modelleri, doğrudan piyasa mekanizmalarını veya ekonomik çıktıları modellememekle birlikte, yenilenebilir enerji sistemlerinin güvenli ve sürdürülebilir biçimde işletilmesine katkı sağlayabilecek bilimsel bir referans çerçevesi sunmaktadır. Bu yönüyle çalışma, rüzgâr enerjisi tahminini yalnızca meteorolojik bir çıktı değil, enerji sistemlerinin planlama ve yönetim süreçlerini destekleyen bilimsel bir karar destek girdisi olarak konumlandırmaktadır.



Şekil 2.2: Türkiye elektrik kurulu gücünün kaynaklara göre dağılımı.

Türkiye Elektrik Üretimi Dağılımı (MWh) — Eylül 2025



Şekil 2.3: Türkiye elektrik üretiminin kaynaklara göre dağılımı.

Türkiye elektrik sistemi incelendiğinde, kurulu güç dağılımı ile fiili üretim dağılımı arasındaki farklar (Şekil 2.2, Şekil 2.3), enerji sisteminin yapısal karakterini açık biçimde ortaya koymaktadır. Kurulu güç dağılımı grafiği, yenilenebilir enerji kaynaklarının (hidrolik, güneş ve rüzgâr) toplam kapasite içerisinde önemli bir paya ulaştığını göstermektedir. Özellikle güneş ve rüzgâr enerjisinin kurulu güç içerisindeki artan ağırlığı, Türkiye enerji politikasının yenilenebilir kaynaklara yönelimini yansıtmaktadır. Buna karşılık üretim dağılımı grafiğinde kömür ve doğal gaz kaynaklı üretimin hâlen yüksek paya sahip olması, sistemin fiili işletiminde fosil yakıtların belirleyici rolünü sürdürdüğünü ortaya koymaktadır. Bu durum, kurulu güç kapasitesi ile gerçek üretim performansı arasındaki yapısal farkı göstermekte; yenilenebilir enerji kaynaklarının sistemde artan kurulu güce rağmen üretim sürekliliği ve kaynak sürekliliği açısından fosil kaynaklarla tam anlamıyla ikame edilebilir bir yapıya henüz ulaşmadığını düşündürmektedir.

Rüzgâr enerjisi özelinde değerlendirildiğinde, kurulu güç içerisindeki payının üretim içindeki payına kıyasla daha dengeli bir yapı sergilediği görülmektedir. Bu durum, rüzgâr enerjisinin Türkiye elektrik sisteminde yalnızca kapasite bazlı değil, üretim bazlı olarak da anlamlı bir katkı sunduğunu göstermektedir. Ancak üretim grafiğinde görülen dalgalı dağılım, rüzgâr enerjisinin doğası gereği değişken üretim

karakterini yansıtmakta ve sistem işletimi açısından öngörülebilirliğin önemini ortaya koymaktadır. Bu bağlamda kısa vadeli rüzgâr tahmin doğruluğu, yalnızca meteorolojik bir başarı ölçütü olarak değil, enerji sisteminin denge, güvenlik ve planlama süreçlerini destekleyen yapısal bir unsur olarak önem kazanmaktadır. Kurulu güç ve üretim dağılımlarının birlikte değerlendirilmesi, rüzgâr enerjisinin enerji sistemindeki rolünün yalnızca kapasite artışıyla değil, sistem entegrasyonu, üretim sürekliliği ve dengeleme mekanizmalarıyla birlikte ele alınması gerektiğini göstermektedir.

2.3 Doğrusal Yöntemler: AR, ARMA ve ARIMA Model Ailesi

Box ve Jenkins'in zaman serisi analizine yönelik geliştirdiği ARIMA modeli [23], meteorolojik zaman serilerinin durağanlaştırıldıktan sonra doğrusal bir çerçevede modellenmesine olanak tanımaktadır. ARIMA modeli, otoregresif (AR), bütünleşik (I) ve hareketli ortalama (MA) bileşenlerinin birleşiminden oluşur ve temel formu Denklem 2.1'de paylaşılmıştır.

$$\phi(L)(1-L)^d X_t = \theta(L)\varepsilon_t \quad (2.1)$$

Burada $\phi(L)$ otoregresif polinomu, $\theta(L)$ hareketli ortalama polinomu ve d serideki durağanlaştırma derecesini temsil eder. ARIMA modellerinin en önemli avantajı, serideki otokorelasyon yapısını doğrudan temsil edebilmesidir; bu nedenle düşük frekanslı davranışlarda genellikle başarılı sonuçlar verir. Ancak rüzgâr şiddetinin doğası gereği ani değişimler, konvektif kaynaklı türbülans ve topoğrafya etkisi gibi doğrusal olmayan süreçler, ARIMA'nın temsil kapasitesini sınırlar [24]. Rüzgâr şiddetinin spektral bileşenleri incelendiğinde yüksek frekanslı türbülans etkilerinin belirgin olduğu görülmekte ve ARIMA bu tür harmonik bileşenleri temsil etmekte yetersiz kalmaktadır. Ayrıca kompleks topoğrafyada, türbülans ve kanalizasyon etkileri rüzgâr alanını doğrusal olmayan bir yapıya taşıdığı için, ARIMA'nın performansının sınırlanabileceği pek çok çalışmada vurgulanmıştır [8,47].

ARIMA modelleri daha çok durağan rüzgâr davranışına sahip bölgelerde güçlü performans sergiler. Ancak kanalize akımların, mikro ölçekli girdapların ve sık yön değişimlerinin görüldüğü bölgelerde doğrusal model varsayımları atmosferin gerçek dinamiğini yansıtmakta yetersizdir. Bu nedenle ARIMA, kısa vadeli tahmin

literatüründe sıklıkla bir “benchmark” model olarak kullanılmış; ANN ve LSTM gibi doğrusal olmayan yöntemlerle karşılaştırma amacıyla değerlendirilmiştir.

2.4 Yapay Sinir Ağları ile Rüzgâr Tahmini Çalışmaları

ANN modelleri, doğrusal olmayan ilişkileri öğrenme kabiliyetleri nedeniyle 1990’lardan itibaren meteorolojik tahmin problemlerinde yaygın kullanılmaya başlamıştır [26]. Çok katmanlı ileri beslemeli ağlar (MLP), geri yayılım algoritması ile eğitilerek rüzgâr şiddetinin karmaşık örüntülerini öğrenebilir. ANN’in bu başarı nedeni, aktivasyon fonksiyonları sayesinde doğrusal olmayan dönüşümleri yüksek bir şekilde işleyebilmesidir [27].

Birçok çalışmada ANN modellerinin, rüzgâr gücü ve rüzgâr şiddetinin tahmininde ARIMA gibi doğrusal modellere göre daha düşük hata verdiği gösterilmiştir [24,27]. Enerji sistemleri literatüründe ANN modellerinin rüzgâr gücü tahmininde güçlü performans gösterdiği, özellikle kısa vadeli rüzgâr değişimlerini yakalamada başarılı olduğu rapor edilmiştir. Bununla birlikte ANN’in önemli sınırlılıkları mevcuttur. Zaman bağımlılığı doğrudan modele gömülü değildir; bu nedenle uygun gecikme vektörlerinin seçilmesi gerekir. Ayrıca ANN’in öğrenme süreci, hiperparametre seçimine karşı hassastır ve Batman gibi yüksek varyanslı serilere sahip bölgelerde aşırı öğrenme (overfitting) eğilimi gösterebilir.

Literatürde yapay sinir ağları (ANN) ile rüzgâr şiddeti tahmini çalışmalarının büyük bölümü, yüksek frekanslı (1 dakika ve altı) verilerden ziyade 10 dakikalık, 30 dakikalık veya saatlik zaman çözünürlüklerinde gerçekleştirilmiştir. Özellikle Li ve Shi, ANN modellerini kısa vadeli rüzgâr şiddeti tahmini için saatlik veriler üzerinde uygulamış ve bu çözünürlüklerde yüksek doğruluk sağlandığını göstermiştir [48]. Mohandes ve arkadaşları ile Mohandes ve Rehman çalışmalarında, ANN tabanlı modeller 10 dakikalık ve saatlik rüzgâr tahminlerinde kullanılmıştır [49,50]. Benzer biçimde Sfetsos, çeşitli tahmin yöntemlerini karşılaştırdığı çalışmasında ANN’nin özellikle saatlik ortalama rüzgâr şiddetinde etkili olduğunu rapor etmiştir [51]. Ghiassi ve Cadenas & Rivera ise ANN modellerini 10 dakikalık rüzgâr şiddeti verileri üzerinde uygulayarak bu bantta başarılı sonuçlar elde etmişlerdir [52,53]. Enerji üretimi bağlamında Oh, saatlik rüzgâr gücü tahmininde ANN modellerinin uygunluğunu

göstermiştir. Daha yakın tarihli çalışmalar, daha kısa süreli tahminlerde de ANN'nin kullanılabilirliğini ortaya koysa da (ör. Nguyen [54]'te), bu uygulamalar hâlen sınırlı sayıdadır [55]. Dolayısıyla, ANN modellerinin ağırlıklı olarak 10 dakika ile 60 dakika arasındaki zaman çözünürlüklerinde araştırıldığı görülmektedir. Bu durum, 1 dakikalık yüksek çözünürlüklü rüzgâr tahmini konusunda literatüre katkıda bulunmak adına bu tezde ele alınacaktır.

2.5 LSTM Tabanlı Derin Öğrenme Yaklaşımları

Uzun Kısa Süreli Bellek (Long Short-Term Memory, LSTM) ağırları, tekrarlayan sinir ağlarının (RNN) zaman içinde bilgi taşıma kapasitesini geliştirerek özellikle uzun bağımlılıklara sahip zaman serilerinin tahmininde yüksek başarı sağlayan derin öğrenme modelleridir. Hochreiter ve Schmidhuber [28] tarafından geliştirilen LSTM mimarisi, klasik RNN'lerin eğitimi sırasında ortaya çıkan “vanishing gradient” sorununu kapı mekanizması aracılığıyla ortadan kaldırarak, uzun süreli bilgi taşıyabilmektedir. Bu özellik, atmosferik sınır tabakasında kısa zaman ölçeklerinde oluşan ani türbülans girdileri, rüzgâr şiddetindeki dalgalanmalar ve yön değişimleri gibi süreçlerin modellenmesinde önemli bir avantaj sağlamaktadır.

LSTM felsefesi "Unutma ama gereksiz şeyleri de hatırlama." şeklindedir. Hangi bilgiyi hatırlayacağını, hangi bilgiyi sileceğini zaman içerisinde kendisi öğrenir. LSTM, bir hücre durumu (cell state, C_t) ile bu duruma bilgi girişini ve çıkışını düzenleyen üç temel kapıdan oluşur:

unutma kapısı (f_t),

giriş kapısı (i_t),

çıkış kapısı (o_t).

Bu kapılar sigmoid aktivasyon fonksiyonu (σ) ile çalışır ve her biri 0–1 arasında bir değer üreterek bilginin ne kadar taşınacağını veya güncelleneceğini belirler. LSTM'nin temel denklemleri aşağıdaki gibidir [28,32].

Unutma Kapısı (Forget Gate):

Bu kapı, önceki hücre bilgisinin ne kadarının korunacağını belirler:

$$f_t = \sigma(W_f x_t + U_f h(t-1) + b_f) \quad (2.2)$$

f_t : unutma kapısı çıkışı, x_t : t anındaki girdi (örneğin rüzgâr şiddeti), $h(t-1)$: önceki zaman adımının çıktı durumu, W_f, U_f, b_f : öğrenilen parametreler.

Rüzgâr zaman serisinde bu, modelin önceki rüzgâr yapısını ne kadar hatırlaması gerektiğini belirler.

Giriş Kapısı (Input Gate):

Yeni bilginin hücreye ne kadar ekleneceğini belirler:

$$i_t = \sigma(W_i x_t + U_i h(t-1) + b_i) \quad (2.3)$$

Hücreye aday bilgi ($\tilde{C}_t$) ise tanh fonksiyonu ile hesaplanır:

$$\tilde{C}_t = \tanh(W_C x_t + U_C h_{t-1} + b_C) \quad (2.4)$$

Hücre Durumunun Güncellenmesi Hücre durumu hem unutma hem giriş kapısının bileşimiyle güncellenir:

$$C_t = f_t \cdot \tilde{C}(t-1) + i_t \cdot \tilde{C}_t \quad (2.5)$$

Bu ifade, LSTM'nin uzun süreli bağımlılıkları taşıyabilmesinin temel nedenidir. Çıkış Kapısı (Output Gate):

Hücreden çıkacak bilginin ne kadarının dışarıya aktarılacağını belirler:

$$o_t = \sigma(W_o x_t + U_o h(t-1) + b_o) \quad (2.6)$$

LSTM'in zaman adımı çıktısı aşağıdaki şekilde elde edilir:

$$h_t = o_t \cdot \tanh(C_t) \quad (2.7)$$

Bellek mekanizmalı tekrarlayan sinir ağı yapısı olan LSTM, kısa vadeli rüzgâr şiddet tahmini çalışmalarında öne çıkan modern yöntemlerden biridir ve atmosferik sınır

tabakasına özgü çok ölçekli dinamikleri temsil etme kapasitesi nedeniyle literatürde geniş bir uygulama alanı bulmuştur. Rüzgâr şiddeti zaman serileri; ani hızlanmalar (gust), düşük frekanslı dalgalanmalar, basınç alanındaki değişimler ve topoğrafya kaynaklı kanalizasyon etkileri gibi hem kısa hem de uzun zaman ölçeklerine yayılan karmaşık bağımlılık yapıları içermektedir. LSTM, kapı mekanizması sayesinde bu bağımlılıkların zaman içindeki seyrini koruyabilmekte ve klasik tekrarlayan ağların karşılaştığı bilgi kaybı sorunlarını önemli ölçüde azaltmaktadır. ARIMA gibi doğrusal modeller ise rüzgâr akışının doğasında bulunan doğrusal olmayan bileşenleri ve kompleks topoğrafya ile konvektif süreçlerin tetiklediği ani değişimleri temsil etmede sınırlı kalabilmektedir [23,47]. Geleneksel yapay sinir ağı (ANN) modelleri kısa süreli ilişkileri öğrenebilse de, LSTM hem kısa hem de uzun ölçekli bağımlılıkları aynı anda modelleyebilmesi sayesinde kısa vadeli tahminlerde gürültü ve türbülans etkilerine karşı daha esnek bir yapı sunmaktadır. Literatürde yapılan çalışmalar, LSTM'nin çeşitli bölgelerde ARIMA ve ANN modellerine kıyasla daha düşük hata değerleri elde edebildiğini göstermektedir [29,32] ancak bu sonuçlar çoğunlukla farklı coğrafi koşullar altında elde edildiğinden, LSTM'nin Batman gibi topoğrafyası karmaşık alanlarda nasıl bir performans göstereceği ayrıntılı biçimde ele alınacaktır.

2.6 Hibrit Modeller: CNN–LSTM, GRU, GAN-LSTM ve Modern Yaklaşımlar

Derin öğrenme yöntemlerinin rüzgâr tahmini performansını artırmak amacıyla hibrit mimarilerin geliştirilmesi son yıllarda önemli bir araştırma alanı hâline gelmiştir. Hibrit modellerin temel motivasyonu, atmosferik zaman serilerinin hem doğrusal olmayan hem de çok ölçekli bileşenlerini aynı çatı altında işleyebilmektir. LSTM modelleri zamansal bağımlılığı temsil etmede başarılı olmasına rağmen, yüksek frekanslı gürültü bileşenlerini filtrelemek veya mekânsal özellikleri yakalamak konusunda sınırlı kalabilmektedir. Bu nedenle literatürde CNN, GRU ve GAN gibi farklı mimarilerin LSTM ile birleştirildiği yöntemler geliştirilmiştir [30,31].

CNN–LSTM modelleri, özellikle kısa vadeli rüzgâr tahmininde yaygın kullanım alanı bulmuştur. CNN katmanları zaman serisindeki yüksek frekanslı bileşenleri filtreleyerek belirgin özellikleri çıkarırken, LSTM katmanları daha düşük frekanslı bağımlılıkları öğrenir. Bu yapı, rüzgâr şiddetindeki ani artış ve düşüşlerin daha doğru

temsil edilmesine olanak sağlar. Meteorolojik verinin hem zamansal hem spektral bileşenlere sahip olması nedeniyle CNN–LSTM modellerinin birçok araştırmada yüksek doğruluk sağladığı gösterilmiştir [31]. GRU tabanlı hibrit modeller, LSTM’ye kıyasla daha az parametre içermesi nedeniyle hesaplama verimliliği açısından avantaj sağlar. Rüzgâr tahmini çalışmalarında GRU’nun LSTM’ye benzer performans sunduğu, özellikle kısa vadeli kestirimlerde daha kararlı sonuçlar üretebildiği rapor edilmiştir [30]. Bununla birlikte, GRU’nun uzun dönem bağımlılıklarını LSTM kadar etkili öğrenemediği durumlar özellikle topoğrafik etkilerin baskın olduğu bölgelerde görülebilmektedir.

GAN tabanlı hibrit modeller, rüzgâr şiddetinin istatistiksel dağılımının daha gerçekçi bir biçimde öğrenilmesini hedefler. GAN mimarilerinde generative ağ, rüzgâr şiddetinin muhtemel dağılımlarını üretirken, discriminator bu dağılımları gözlemsel veri ile karşılaştırarak modelin gerçek rüzgâr davranışını daha iyi yansıtmayı sağlar. Ren ve arkadaşları, GAN–LSTM hibrit modellerinin ani rüzgâr değişimlerini temsil etmede klasik LSTM’ye göre daha başarılı olduğunu göstermiştir [34]. Özellikle Batman gibi ani hızlanma ve mikro ölçekli girdapların sık görüldüğü bölgelerde GAN tabanlı modellerin potansiyel olarak üstünlük sağlayabileceği değerlendirilmektedir [47].

Son yıllarda derin öğrenme tabanlı modeller, özellikle uzun sekanslı zaman serilerinin işlenmesinde klasik RNN tabanlı yaklaşımların ötesine geçmiştir. Vaswani tarafından önerilen transformer mimarisi, dikkat mekanizması sayesinde uzun bağımlılıkların hesaplanmasında önemli bir devrim yaratmış ve rüzgâr tahmini uygulamalarında giderek daha fazla kullanılmaya başlanmıştır [35]. Bu ilerlemenin bir uzantısı olarak Zhou, uzun sekans tahmin görevleri için geliştirilen informer mimarisinin, özellikle yüksek değişkenliğe sahip meteorolojik zaman serilerinde klasik transformer modellerine göre daha verimli ve daha düşük hesaplama maliyetli olduğunu göstermiştir [56]. Bu nedenle informer, rüzgâr şiddeti ve güç tahmini gibi uzun patern bağımlılığı içeren problemlerde öne çıkan modern yaklaşımlardan biridir. Bununla birlikte, mekânsal bağımlılıkların belirgin olduğu durumlarda (örneğin kompleks topoğrafya, istasyonlar arası etkileşim, rüzgâr akışındaki kanalizasyon etkileri), grafik sinir ağları (GNN) güçlü bir alternatif sunmaktadır. Li, GNN tabanlı

yapıların mekânsal korelasyonları klasik derin öğrenme yöntemlerine göre daha başarılı biçimde modelleyebildiğini göstermiştir [36]. Benzer şekilde, Y. Li ve çalışma arkadaşları, yüksek çözünürlüklü rüzgâr tahmini ve bölgesel akış örüntülerinin temsilinde modellerin daha düşük hata değerleri sağlayabildiğini rapor etmiştir. Bu sonuçlar, LSTM gibi modellerin rüzgâr tahmininde giderek artan biçimde kullanılan modern yöntemler olduğunu göstermektedir [57].

2.7 Kompleks Topografya ve ABL Üzerindeki Etkileri: Dağ–Vadi Sistemlerinde Literatür

Kompleks topoğrafya, atmosferik sınır tabakasının (ABL) yapısını belirleyen en önemli faktörlerden biri olup, rüzgâr akışının hem yatay hem dikey doğrultuda belirgin ölçüde heterojenleşmesine yol açmaktadır. Özellikle dağ, vadi, plato, keskin eğim değişimleri ve arazi kullanımındaki çeşitlilik gibi yüzey özellikleri, rüzgâr akımının hız, yön ve türbülans karakteristiklerini büyük ölçüde değiştirmektedir. Belušić ve Güttler, kompleks arazi koşullarında rüzgârın mekânsal süreksizlikler, hızlanma bölgeleri, kanalizasyon etkileri ve ani sapmalar sergilediğini göstermiştir [8]. Benzer şekilde Emeis, yüzey pürüzlülüğündeki değişimlerin ABL'nin alt tabakalarında önemli hız gradyanları oluşturduğunu ve bunun logaritmik rüzgâr profili varsayımlarında sapmalara yol açabileceğini vurgulamaktadır [9]. Batman bölgesi de topoğrafik olarak heterojen bir yapıya sahiptir. Arazi örtüsü tipleri, yüzey pürüzlülük sınıfları ve arazi yükseltileri kısa mesafelerde anlamlı farklılıklar göstermekte; bu durum sınır tabakasında yerel ölçekte hızlanma, yavaşlama ve yön değiştirme bölgeleri oluşmasına neden olabilmektedir. Özellikle yerleşim alanları, tarım yüzeyleri, çıplak arazi ve tepelik yapıların birbirine yakın konumlandığı bölgelerde rüzgâr akımlarının logaritmik profil varsayımından sapma eğilimi artmaktadır. Bu sapmalar, sabit pürüzlülük parametresi veya tek tip yüzey kabul eden modellerde ek belirsizlik yaratmaktadır. Panofsky ve Dutton, heterojen yüzeylerde rüzgâr profilinin klasik logaritmik yapıdan sistematik olarak ayrılabilceğini, bu nedenle parametrik yaklaşımların karmaşık yüzeylerde daha dikkatli uygulanması gerektiğini belirtmiştir [16]. Kompleks topoğrafya sadece hız profilini değil, aynı zamanda türbülans üretimini de önemli ölçüde artırmaktadır. Chow ve Street, eğimli arazilerde mekanik türbülansın

keskin biçimde güçlendiğini, kanalizasyon etkileri nedeniyle rüzgâr alanlarının dar koridorlar içinde hızlanabildiğini, bunun da hem yerel rüzgâr iklimini hem de sayısal model performansını etkileyebildiğini ortaya koymuştur [58]. Batman gibi topoğrafik çeşitliliğin bulunduğu bölgelerde, bu etkileşimler sonucunda rüzgârın kısa zaman ölçeklerinde (1–5 dakika) yüksek frekanslı salınımlar göstermesi beklenmektedir. Bu durum özellikle kısa vadeli rüzgâr tahmini çalışmalarında öngörülmesi zor mikro ölçek süreçlerin ortaya çıkmasına yol açmaktadır.

Yerel topoğrafyanın neden olduğu hızlanmalar, rüzgâr yönündeki ani sapmalar, ters akımlar, dalgalı akış bölgeleri ve pürüzlülük geçişleri; hem fiziksel temelli hem de istatistiksel öğrenme tabanlı modeller için ek zorluklar oluşturur. Doğrusal yaklaşımlar (ARIMA), istasyonellik varsayımına bağlı olduğundan bu tür ani değişimlerde performans kayıpları yaşayabilmektedir. Doğrusal olmayan yapay sinir ağı tabanlı modeller (ANN) ile LSTM gibi hafızalı derin öğrenme yaklaşımları ise zamansal bağımlılıkları daha iyi yakalayabilse de, yüzey kaynaklı ani girdiler ve kompleks topoğrafya nedeniyle oluşan yüksek frekanslı türbülans, bu modellerde de belirsizlik artırıcı bir faktördür. Chow ve Street tarafından ortaya konduğu üzere, kompleks topoğrafya ve heterojen yüzey şartları, model performansını doğrudan değil fakat potansiyel olarak etkileyen bir belirsizlik kaynağıdır [58].

Sonuç olarak, kompleks topoğrafya ve heterojen yüzey özellikleri, kısa vadeli rüzgâr tahminlerinde modelleme zorluklarını artırmakta; logaritmik profil varsayımındaki sapmalar, türbülans üretimindeki artış ve yön değişkenliği nedeniyle hem fiziksel hem veri odaklı modellerin hata seviyeleri yükselme eğilimi göstermektedir. Bu nedenle, Batman gibi topografik çeşitliliğin yüksek olduğu bölgelerde yüksek çözünürlüklü (1 dakika) rüzgâr tahmini çalışmaları hem bilimsel hem operasyonel açıdan kritik bir gerekliliktir.

2.8 Sayısal Hava Tahmini Modelleri ve Sınırları

Sayısal hava tahmin modelleri (Numerical Weather Prediction, NWP), atmosfer dinamiklerinin temel fizik yasalarına dayalı olarak çözümlenmesiyle rüzgâr tahmininde önemli bir araçtır. Modern NWP modelleri; yüksek çözünürlüklü grid yapıları, gelişmiş sınır tabakası (PBL) şemaları, bulut mikro fiziği paketleri, yüzey atmosfer

etkileşimi parametризasyonları ve kapsamlı veri asimilasyon sistemleri sayesinde bölgesel ölçekte detaylı tahmin üretebilmektedir. Bununla birlikte, atmosferik sınır tabakasının yüksek derecede kaotik, çok ölçekli ve yerel topoğrafyaya duyarlı yapısı nedeniyle kısa vadeli (0–6 saat) rüzgâr tahminleri hâlen önemli belirsizlik barındırmaktadır. Bauer, NWP modellerinin küresel ölçekte başarılı olsa dahi, kısa zaman ölçeklerinde sınır tabakası süreçlerinin temsilinde ciddi zorluklarla karşılaştığını göstermiştir [7]. NWP tahminlerindeki belirsizliğin temel nedenlerinden biri, ABL (Atmospheric Boundary Layer) süreçlerinin karmaşıklığıdır. Yüzey pürüzlülüğündeki değişim, arazi eğimi, arazi kullanım türleri, inversiyon katmanları, zayıf karışım koşulları, konvektif girdiler ve yön değiştiren lokal akışlar; rüzgâr şiddetindeki kısa sürede gözlenen ani değişimlere ve yüksek frekanslı türbülans üretimine neden olabilmektedir.

Holton ve Panofsky & Dutton, ABL'nin bu çok ölçekli yapısının özellikle kısa vadeli rüzgâr tahminlerinde deterministik modellerin doğruluğunu sınırlayan en önemli faktörlerden biri olduğunu belirtmektedir [2,16]. Kompleks topoğrafya koşullarında NWP modellerinin kısıtları daha da belirgin hâle gelmektedir. Eğimli arazi, vadiler, tepelik yapılar ve pürüzlülük geçişleri; rüzgâr akımında hızlanmayı, kanalizasyon etkilerini, yön değişimlerini ve rotor benzeri küçük ölçekli girdapları artırarak model alanlarında çözünemeyen süreçlerin payını genişletmektedir. Chow ve Street, kompleks arazi koşullarında sınır tabakası şemalarının türbülans üretimini ve kesme etkisini doğru temsil etmekte zorlandığını, bunun da model performansını potansiyel olarak olumsuz etkilediğini göstermiştir [58]. Yüksek çözünürlüklü bölgesel modeller, bu zorlukları gidermek amacıyla geliştirilmiş olsa da, belirsizlik tamamen ortadan kalkmamaktadır. Özellikle 3 km çözünürlüklü HRRR (High Resolution Rapid Refresh) gibi operasyonel modeller, sık güncellenen veri asimilasyonu ve gelişmiş fizik paketleri ile kısa vadeli rüzgâr tahmini için yaygın biçimde kullanılmaktadır. Ancak Benjamin tarafından gerçekleştirilen kapsamlı değerlendirme [48]'de, HRRR'nin yüksek çözünürlüklü yapısına rağmen kompleks topoğrafya koşullarında arazi kaynaklı hızlanma bölgelerini, ani yön sapmalarını, pürüzlülük sınıfı geçişlerini ve yüzeye yakın türbülansın neden olduğu lokal etkileri tam olarak yakalayamadığını göstermiştir. Bu bulgular, modern NWP modellerinin dahi kısa vadeli rüzgâr

tahminlerinde mikro ölçek süreçler karşısında belirli sınırlılıklar taşıdığını ortaya koymaktadır. NWP modellerinin kısa vadeli rüzgâr tahmini performansını etkileyen bir diğer önemli unsur ise konvektif sistemlerdir. Konvektif hücrelerin, squall hatlarının, ani rüzgâr şiddetlenmelerinin (gust front), rüzgâr yönü dönüşlerinin ve mikrodalga yağış bantlarının hem zaman hem mekân açısından yüksek değişkenlik göstermesi; parametrisasyon temelli modellerde önemli hatalara neden olabilmektedir. Bu tür hızlı gelişen olaylar, özellikle 1–5 dakikalık çözünürlüklerde operasyonel uygulamalar açısından kritik olup NWP modellerinin çözünürlük ve zaman adımı gerekliliklerini zorlamaktadır. Bu nedenlerle, kısa vadeli rüzgâr şiddetinin doğru tahmini için tek başına fizik tabanlı NWP modellerinin kullanılması çoğu zaman yeterli olmamakta; model hatalarının post processing adımlarıyla düzeltilmesi, istatistiksel veya derin öğrenme tabanlı hibrit yapıların uygulanması gerekmektedir. Rasp ve Thuerey ile Li, NWP çıktılarının makine öğrenmesi yöntemleriyle düzeltilmesinin (bias correction) kısa vadeli tahmin performansını anlamlı biçimde artırabileceğini göstermiştir. Bu bağlamda, özellikle kompleks topoğrafya ve 1 dakikalık gibi yüksek zaman çözünürlüklü tahminlerde veri odaklı yöntemler kritik bir tamamlayıcı rol üstlenmektedir [31,33]. Sonuç olarak, modern NWP modelleri atmosfer dinamiğini fiziksel temelli bir çerçevede temsil eden güçlü araçlar olsa da, kısa vadeli rüzgâr tahminlerinde kompleks topoğrafya, yüzey heterojenliği, konvektif süreçler ve mikro ölçek türbülans nedeniyle belirgin sınırlılıklar taşımaktadır. Bu durum, özellikle Batman gibi topoğrafik çeşitliliğin yüksek olduğu bölgelerde yüksek çözünürlüklü (1 dakika) veri odaklı modellerin kullanımını hem bilimsel hem operasyonel açıdan gerekli kılmaktadır.

2.9 Literatürdeki Boşluklar ve Bu Tezin Konumlandırılması

Kısa vadeli rüzgâr şiddeti tahmini üzerine yapılan çalışmaların büyük bir bölümü, belirli zaman çözünürlüklerinde (çoğunlukla 10 dakika, 30 dakika veya saatlik) ve belirli topoğrafik koşullarda geliştirilmiş modellere dayanmaktadır. ARIMA, ANN ve LSTM gibi yaygın kullanılan yöntemlerin performansları literatürde kapsamlı biçimde karşılaştırılmış olmakla birlikte, bu değerlendirmeler çoğunlukla nispeten homojen topoğrafyaya sahip bölgeler veya düşük zaman çözünürlüklü veri setleri üzerinden

yapılmıştır [24,27,29,32]. Beluđić, Emeis ve Chow & Street tarafından ortaya konulduđu üzere, kompleks topoğrafya rüzgâr alanını hem yatay hem dikey doğrultuda önemli ölçüde heterojenleştirmekte ve bu durum kısa vadeli tahmin modellerinin hata seviyelerini belirgin biçimde etkileyebilmektedir [8,9,58]. Bu nedenle, kompleks topoğrafyaya sahip bölgelerde yüksek çözünürlüklü rüzgâr tahminleri hâlen literatürde önemli bir eksiklik olarak durmaktadır. Ayrıca, ANN ve LSTM gibi derin öğrenme tabanlı modeller literatürde genellikle 10–60 dakikalık çözünürlüklerde uygulanmış olup, 1 dakikalık veya alt dakikalık veri setleri üzerinde yapılan çalışmalar oldukça sınırlıdır [48,54]. Bu durum, sınır tabakasının (ABL) yüksek frekanslı türbülans bileşenlerinin temsil edilebilmesi açısından mevcut literatürün önemli bir kısıtını oluşturmaktadır. Yüksek çözünürlüklü veri kullanımı, modellerin kısa zaman ölçeklerinde görülen ani hız değişimlerini, konvektif etkileşimleri ve topoğrafya kaynaklı hızlanma bölgelerini daha doğru temsil edebilmesi açısından kritik öneme sahiptir.

Diğer taraftan, NWP modellerinin (özellikle HRRR gibi yüksek çözünürlüklü sistemlerin) kompleks topoğrafya altında kısa vadeli rüzgâr tahminlerinde belirli sınırlılıklara sahip olduđu çeşitli çalışmalarla ortaya konmuştur [7,49,58]. HRRR'nin arazi kaynaklı mikro-ölçek hızlanmaları, yön değişimlerini ve pürüzlülük geçişlerini tam olarak temsil edememesi, veri odaklı post processing yöntemlerinin önemini daha da artırmaktadır.

Bu bağlamda, Batman bölgesi hem topoğrafik çeşitliliği hem de operasyonel ihtiyaçları nedeniyle literatürde ayrıntılı bir şekilde ele alınmamış özgün bir çalışma alanı sunmaktadır. Batman Meydanı'nın çevresinde kısa mesafelerde değişen pürüzlülük sınıfları, yerleşim, tarım, çıplak arazi geçişleri ve tepelik yapıların varlığı, rüzgâr alanının zamansal ve mekânsal heterojenliğini artırarak yüksek çözünürlüklü modelleme ihtiyacını güçlendirmektedir. Literatürde Batman'a özgü çoklu model ve çoklu çözünürlük (1 dakika, 5 dakika, 10 dakika, 30 dakika, 60 dakika) karşılaştırması yapan kapsamlı bir çalışma bulunmamaktadır.

Bu tez, ARIMA, ANN ve LSTM modellerinin Batman gibi kompleks topoğrafyaya sahip bir bölgede yüksek çözünürlüklü rüzgâr verileriyle karşılaştırmalı olarak

değerlendirilmesiyle literatürdeki bu boşluğu doldurmayı amaçlamaktadır. Farklı zaman çözünürlüklerinin (1–60 dakika) model performansı üzerindeki etkisinin sistematik olarak incelenmesi, hem rüzgâr enerjisi uygulamaları hem de havacılık operasyonları için önemli bilimsel ve pratik katkılar sunmaktadır.





3. UYGULAMA

3.1 Amaç

Bu bölümde, Batman Meydan’da elde edilen yüksek çözünürlüklü rüzgâr verileri kullanılarak, kısa vadeli rüzgâr şiddeti tahmininde kullanılan üç farklı yaklaşımın Otoregresif Bütünleşik Hareketli Ortalama Modeli (ARIMA), Yapay Sinir Ağları (ANN) ve Uzun Kısa Süreli Bellek (LSTM) performansları ayrıntılı biçimde incelenmiştir. Uygulamanın amacı, modellerin:

- farklı zaman çözünürlüklerindeki davranışlarını,
- atmosferik süreçlerle olan uyumlarını,
- seçilen parametrelerin fiziksel ve istatistiksel gerekçelerini,
- literatürde açıklanan teorik temellerin pratik karşılığını

ortaya koymaktır. Bu kapsamda, tüm modeller aynı veri seti, aynı test dönemleri ve aynı değerlendirme metrikleri kullanılarak karşılaştırılmış; hem modelleme aşamasında kullanılan kod parametreleri hem de tahmin çıktıları meteorolojik fizik ve zaman serisi modelleme literatürü ile ilişkilendirilerek yorumlanmıştır.

Batman Meydanı’nın operasyonel gereklilikleri doğrultusunda, kısa vadeli rüzgâr tahminlerinin doğruluğu yalnızca model çıktılarının kendi iç tutarlılığıyla değil, aynı zamanda sahadaki gerçek meteorolojik koşulların SHT (Sayısal Hava Tahmin) kapsamında yayımlanan TAF ve tahakkuk etmiş METAR verileriyle ne ölçüde örtüştüğüyle de değerlendirilmektedir. Bu nedenle çalışmada kullanılan tahmin modelleri incelenirken, özellikle rüzgâr yönü, rüzgâr şiddeti, hamle (gust) değerleri, görüş mesafesi ve bulutu oluşturan meteorolojik parametrelerin zaman içerisindeki değişimleri SHT çıktılarıyla karşılaştırılmıştır. Batman Meydan’da gözlenen topoğrafik etkiler, pürüzlülük geçişleri, konveksiyon ve gece gündüz kararlılık değişimleri nedeniyle yüksek zamansal değişkenlik göstermektedir. Bu atmosferik değişkenlik, özellikle yaklaşma-kalkış aşamalarında kritik öneme sahip olan operasyonel rüzgâr

tahminlerinde belirgin belirsizlikler oluşturmakta; SHT ve TAF tahminleri ile aynı dönemlere ait METAR tahakkukları karşılaştırıldığında sistematik ve dönemsel uyumsuzluklar ortaya çıkmaktadır. SHT/TAF tahminlerinin ani rüzgar şiddetindeki değişimler, hamleler ve konvektif geçişlere duyarlılığının düşük olması, operasyonel karar süreçlerinde gereksinim duyulan yüksek doğruluğu sınırlamakta ve sahada emniyet odaklı değerlendirmeleri güçleştirmektedir.

Bağlı olduğu Metar/Taflar

Metar

LTCJ 011450Z VRB04KT 9999 FEW025CB BKN035 BKN090 19/13 Q1014 NOSIG RMK RWY20 VRB04KT 1CB025 5CU035 7AC090 =

Ana Taf

LTCJ 011040Z 0112/0212 15012KT CAVOK TEMPO 0112/0115 15015G30KT BECMG 0113/0115 FEW040 BKN100 TEMPO 0115/0119 VRB15G30KT -TSRA FEW025CB BKN035 BKN090 TEMPO 0119/0123 VRB15G30KT -TSRA FEW025CB BKN035 BKN090 TEMPO 0123/0203 -TSRA FEW025CB BKN035 BKN090 TEMPO 0203/0207 -TSRA FEW025CB BKN035 BKN090 =

Bağlı Olduğu İç Taf

BECMG 0113/0115 FEW040 BKN100

Şekil 3.1: 1 Mayıs 2025 tarihine ait METAR.

Bağlı olduğu Metar/Taflar

Metar

LTCJ 241620Z 23003KT CAVOK 25/07 Q1005 NOSIG RMK RWY20 21004KT SKC =


Ana Taf

LTCJ 240440Z 2406/2506 18012KT CAVOK BECMG 2406/2409 FEW040 SCT100 TEMPO 2409/2413 18015G25KT TEMPO 2413/2417 21015G25KT BECMG 2417/2419 CAVOK BECMG 2422/2424 FEW040 BKN100 =


Bağlı Olduğu İç Taf

TEMPO 2413/2417 21015G25KT

Şekil 3.2: 24 Mayıs 2024 tarihine ait METAR.



Şekil 3.3: 1 Mayıs 2025 tarihine ait METEOGRAM.



Şekil 3.4: 1 Mayıs 2025 tarihine ait METEOGRAM.

3.1, 3.2, 3.3 ve 3.4 numaralı şekillerde de görüldüğü üzere, Batman Meydanı'nda kısa vadeli rüzgâr yapısı hem zamansal hem de konvektif süreçlere bağlı olarak yüksek değişkenlik göstermektedir. Özellikle 24 Mayıs 2024 tarihine ait METAR ve SHT/TAF karşılaştırmalarında, tahmin edilen rüzgâr şiddeti ve yönünün, gerçekleşen ile örtüşmediği; rüzgar şiddeti tahminlerinin uyumlu olmadığı açıkça görülmektedir. Benzer biçimde, 1 Mayıs 2025 tarihine ait METAR–SHT değerlendirmesinde de operasyonel TAF/SHT tahminleri, yüzeye yakın rüzgâr alanındaki kısa süreli dalgalanmaları, konvektif geçişleri ve topoğrafya kaynaklı mikro-ölçekli etkileri

yakalamakta yetersiz kalmış; bu durum özellikle yaklaşma–kalkış aşamaları açısından kritik öneme sahip olan rüzgâr şiddeti tahminlerinde belirgin hatalara yol açmıştır. Şekillerden de anlaşılacağı üzere, mevcut operasyonel tahmin–gerçekleşme uyumsuzlukları, yüksek zaman çözünürlüklü ve veri odaklı modellerin kullanımının tahminlerde fayda sağlayacağı düşünülmekte ve bu tez çalışmasının temel amacı söz konusu uyumsuzlukları azaltarak rüzgâr şiddeti tahmininin doğruluğunu ve operasyonel güvenilirliğini artırmaktır.

Çalışmada incelenen örnekler, kısa vadeli rüzgâr tahminlerinin hem enerji üretim planlamaları açısından hem de havacılık sektörü için kritik önemini açık biçimde ortaya koymaktadır. Örneğin Şekil 3.2 ve Şekil 3.4’te incelenen 24 Mayıs tarihi için 16–20 Z saat aralığı için öngörülen rüzgâr şiddetinin ortalama 15 kt, hamle değerlerinin ise 25 kt düzeylerine ulaşacağı tahmin edilmiş olmasına karşın, gerçekleşen rüzgâr şiddetinin yalnızca 3 kt seviyelerinde kaldığı görülmüştür. Beklenen ve gerçekleşen rüzgâr şiddetleri arasındaki bu belirgin fark, kısa vadeli üretim tahminlerinde anlamlı sapmalara neden olabileceği gibi, türbin güç eğrilerinin düşük hız bölgelerinde yüksek duyarlılık göstermesi nedeniyle enerji çıktısının ciddi biçimde azalmasına yol açmaktadır. Benzer bir durum 1 Mayıs tarihindeki örnekte de gözlenmiştir; bu tarihte yaklaşık 15 kt’lik rüzgâr şiddeti ve 30 kt seviyelerine ulaşması öngörülen hamle değerleri beklenirken, gerçekleşen rüzgâr şiddetinin çeşitli yönlerden yalnızca 4 kt düzeyinde seyretmesi, rüzgâra dayalı güç üretimi açısından operasyonel anlamda düşük verimlilik koşullarına işaret etmektedir.

Bununla birlikte, bu tür uyumsuzlukların yalnızca iki örnek olaya özgü olmadığı, çalışmada değerlendirilen diğer beş olay gününde de benzer davranışların tekrarlandığı görülmüştür. Özellikle konvektif sistemlerin etkin olduğu zaman aralıklarında; kümülonimbus (CB) geçişleri, oraj geçişleri ve ani yağış süreçlerinin hızlı atmosferik kararsızlık yarattığı, bunun da rüzgâr şiddetinin kısa zaman ölçeklerinde belirgin şekilde dalgalanmasına yol açtığı anlaşılmaktadır. Bu koşullar altında rüzgâr şiddetinin hem düşey hem yatay bileşenlerinde ortaya çıkan ani ivmelenmeler, kısa vadeli tahmin modelleri açısından önemli bir belirsizlik kaynağı oluşturmaktadır.

3.2 Veri Hazırlama ve Ön İşleme

3.2.1 Veri kaynağı, topoğrafik etki ve zaman çözünürlükleri

Batman Meydanı, plato yüzeyi, vadi kanalları, topoğrafik sırt çizgileri ve pürüzlülük geçişleri ile karakterize edilen, sınır tabakası türbülansının güçlü olduğu bir bölgedir.

Bu nedenle rüzgâr verisi:

- Ani hızlanma ve yavaşlamalar,
- Konvektif sıçramalar,
- Termal kararsızlıklar,
- Yön değişimleri,
- Mikro ölçek topoğrafik kanalizasyon

gibi davranışlar gösterir. Bu özellikler, özellikle 1 dakikalık çözünürlükte yüksek frekanslı türbülans bileşenlerinin belirginleşmesine neden olur. Literatürde belirtildiği üzere [2,5,12], rüzgâr sinyali:

- Türbülansın yüksek frekanslı bileşenleri baskındır.
- Hem yüksek frekanslı türbülansın bir kısmı korunur hem de 1 dakikalık gürültü filtrelenir. Bu çözünürlük, kısa vadeli operasyonel tahminlerde çok kritik kabul edilir çünkü ABL'deki kararsız yapı 5–20 dakikalık döngülerle gelişir.
- Konvektif hücrelerin yükseliş–çöküş yapıları daha belirgin hâle gelir; sinyal daha dengelidir.
- Düşük frekanslı bileşenler baskın hâle gelir, türbülansın çoğu ortalanır.
- Sinyal neredeyse tamamen doğrusal davranır.

Bu nedenle veri aynı dönemler için 1 dk, 5 dk, 10 dk, 30 dk ve 60 dk çözünürlüklerde yeniden örneklenmiş ve her çözünürlükte üç model ayrı ayrı eğitilmiştir.

3.2.2 Kalite kontrol ve veri dönüşümleri

Rüzgâr zaman serileri, meteorolojik sensörlerin bulunduğu çevresel koşullar, rotor etkisi, yağış sıçramaları, sensör titreşimleri ve kısa süreli elektriksel kesintiler nedeniyle hatalar içerir.

Bu nedenle veri üzerinde şu işlemler yapılmıştır:

3.2.2.1 Uç değer temizleme:

Tek bir uç değer bile özellikle 1 dakikalık veride ANN ve LSTM'in gradyan akışını bozabileceğinden, istatistiksel dağılıma uymayan aşırı değerler temizlenmiştir.

3.2.2.2 Eksik veri işlemleri:

Türbülans yüksek frekanslı olduğundan doldurma işlemi sinyalin yapısını bozmaktadır. Bu yüzden 1–3 dakikalık eksikler dolduruldu.

3.2.2.3 Zamanı yeniden örnekleme:

Saniyelik rüzgâr ölçümleri ABL'nin en yüksek frekanslı türbülans bileşenlerini içerdiğinden, doğrudan tahmin modellerine uygulanması hem gürültü kaynaklı belirsizliği artırmakta hem de modellerde gereksiz karmaşıklığa yol açmaktadır. Literatürde belirtildiği üzere [12], saniyelik türbülans enerji spektrumu, kısa vadeli tahminler için anlamsız olan yüksek frekanslı bileşenlerle doludur. Bu nedenle veri önce 1 dakikalık ortalamaya indirgenmiş, daha sonra 5, 10, 30 ve 60 dakika gibi daha büyük zaman pencereleri bu temel çözünürlük üzerinden elde edilmiştir.

3.2.2.4 Normalizasyon :

Modelleme sürecinde kullanılan yapay sinir ağı (ANN) ve uzun-kısa süreli bellek (LSTM) modellerinin istikrarlı ve verimli bir biçimde eğitilebilmesi için veri seti üzerinde normalizasyon uygulanmıştır. ARIMA modeli ise ham veri üzerinde çalıştırılmıştır. Bunun temel nedeni ARIMA'nın matematiksel yapısının, verinin mutlak ölçeği ve fiziksel değer aralığı ile doğrudan ilişkili olmasıdır. ARIMA modeli,

zaman serisinin kendi geçmiş değerleri ile hata terimlerinin doğrusal kombinasyonuna dayanan bir model olduğundan, veri setine uygulanan her türlü doğrusal olmayan dönüşüm ARIMA'nın otokorelasyon yapısını, varyansını ve durağanlık özelliklerini yapay biçimde değiştirmektedir. MinMaxScaler gibi ölçekleme yöntemleri ANN ve LSTM için sayısal kararlılık sağlarken, ARIMA'da tam tersine modelin yapısını bozarak yanlış p–d–q (p:Autoregressive, d:Differencing, q:Moving Average) derecesi seçimine ve önyargılı tahminlere yol açabilir. Literatürde, özellikle [23] metodolojisi, ARIMA'nın verinin orijinal ölçeğinde, yalnızca gerekliyse fark alma (differencing) işlemi ile durağanlaştırılarak uygulanmasını önermektedir. Bu nedenle ARIMA modelinin performansı için normalizasyon değil, serinin durağanlığı esastır; ANN ve LSTM'de ise normalizasyon, modelin eğitimi için kritik bir gerekliliktir. Dolayısıyla ARIMA'nın ham veri ile, ANN ve LSTM'nin ise normalize edilmiş veri ile eğitilmesi metodolojik olarak doğru ve literatür ile tamamen uyumludur.

3.3 Model Formülasyonları ve Kod Parametre Seçimlerinin Bilimsel Gerekçesi

Bu bölümde, her model için kullanılan parametrelerin neden seçildiği, bu parametrelerin Bölüm 2'de açıklanan atmosferik süreçlerle ve literatürdeki modellerle nasıl ilişkili olduğu açıklanmaktadır.

3.3.1 ARIMA modeli parametreleri

Bu tezde kullanılan ARIMA modelinin uygulama adımları Ek A.1'de ayrıntılı olarak sunulmuştur. Ek A.1.2'de gösterildiği üzere ARIMA modelinin p, d ve q parametreleri hem ACF–PACF analizleri hem de literatürde Box–Jenkins metodolojisinin önerdiği adımlar doğrultusunda seçilmiştir. Parametre araması için kullanılan döngülü yapı (Ek A.1.5) rüzgâr serilerinde sık görülen kısa süreli otokorelasyon kümelerini yakalayabilmek üzere tasarlanmıştır. Rüzgâr şiddetindeki ani dalgalanmalar doğrusal modellerde artan hata ürettiği için, oluşturulan Python fonksiyonları yalnızca istatistiksel uygunluğu değil, aynı zamanda fiziksel yapılabilirliği de gözeterek model seçimini gerçekleştirmiştir. Böylece ARIMA, literatürde önerildiği biçimde hem benchmark model hem de doğrusal bileşenlerin ayrıştırılması için kullanılmıştır.

Kodda sabit olarak tanımlanan $D_FIXED = 1$ değeri (Ek A.1.2), rüzgâr şiddetinin atmosferik doğası gereği orta ve uzun vadede birinci dereceden entegre bir süreç gibi davranmasından kaynaklanır. Rüzgâr şiddeti, özellikle 30–60 dakikalık zaman çözünürlüğünde trend içermeyen, fakat hafif kaymalı bir yapı gösterir. Hem literatürde [2,12] hem de operasyonel meteoroloji verilerinde rüzgâr serisinin çoğu zaman birinci farkta durağanlaştığı bilinmektedir. Ek A.1.5'te AIC'e dayalı model araması da bu varsayım ile uyumludur; yüksek d değerleri hem fiziksel açıdan anlamsız hem de modelin aşırı yumuşamasına yol açacağından tercih edilmemiştir. Dolayısıyla $d=1$ seçimi hem ARIMA teorisine hem de atmosferik veri özelliklerine uygun, en kararlı yapıyı sunmaktadır.

Ek A.1.5'te hem p hem q parametreleri $P_LIST = [0, 1, 2]$, $Q_LIST = [0, 1, 2]$ olacak şekilde sınırlandırılmıştır. Rüzgâr serilerinde özellikle 1 saatlik çözünürlükte otokorelasyon genellikle kısa vadeli ve hızlı sönümlü olduğu için yüksek p ve q değerleri hem fiziksel açıdan anlamlı değildir hem de yöntemsel olarak aşırı uyum (overfitting) riskini artırır. Box–Jenkins literatürü, atmosferik verilerde $p, q \leq 2$ 'nin büyük çoğunlukla yeterli olduğunu gösterir. Ek A.1 ACF ve PACF analizlerinde de ilk iki gecikmenin anlamlı olduğu gözlemlendiğinden, parametre araması istatistiksel ve fiziksel sınırlar içinde tutulmuştur. Benimsenen bu yaklaşım, hem hesaplama verimliliğini artırmakta hem de aşırı parametreliliğin hata varyansını yükseltme riskini azaltmaktadır.

Ek A.1.5'te ARIMA modelinin AIC (Akaike Information Criterion) değerine göre seçilmesi, literatürde kısa vadeli rüzgâr tahmini için en yaygın kullanılan yöntemlerden biridir. AIC, model karmaşıklığı ile doğruluk arasında denge kuran bir kriterdir. Rüzgâr veri setleri gürültülü, ani sıçramalara açık ve heterojen olduğu için klasik RMSE'ye göre model seçmek aşırı uyuma yol açar; AIC bu nedenle daha güvenilir bir ölçüttür.

Smoothing değeri 2 seçilmiştir. Bu, meteorolojide kullanılan median filter prensibiyle uyumludur ve özellikle ani dalgalanmaları yumuşatarak ARIMA'nın tahmin eğrisinin daha okunaklı hâle gelmesini sağlar. Modeli matematiksel olarak değiştirmez, sadece görsel yorumu güçlendirir.

3.3.2 ANN modeli parametreleri

Bu çalışmada kullanılan Yapay Sinir Ağı (ANN) modeli, rüzgâr şiddetinin özellikle kısa ve orta zaman ölçeklerinde gösterdiği belirgin nonlinear davranışları temsil etmede güçlü bir yaklaşım sunduğundan, parametre seçimleri atmosferik süreçlerin zaman ölçekleri dikkate alınarak yapılmıştır. ANN mimarisinin kurulmasından önce gerçekleştirilen veri ölçeklendirme adımı (Ek A.2.2), rüzgâr şiddetinin istatistiksel dağılım özellikleri nedeniyle kritik öneme sahiptir. Rüzgâr verileri genellikle pozitif tanımlı, sağa çarpık ve yüksek varyansa sahip bir yapı gösterir. Bu nedenle modelde MinMaxScaler kullanılarak tüm gözlemler 0 ile 1 aralığına dönüştürülmüş; böylece gradyan hesaplamaları kararlı hâle gelmiş ve ağın öğrenme dinamikleri normalize edilmiştir. Literatürde kısa vadeli rüzgâr tahminlerinde ölçeklendirme yapılmadan eğitilen sinir ağlarının ani şiddet değişimlerini yakalamakta başarısız olduğu rapor edildiğinden, bu adım hem istatistiksel hem fiziksel açıdan zorunludur.

Ek A.2.3'te gösterilen gecikme yapısı (lag/sekans) oluşturulurken LAG_STEPS = 12 değeri tercih edilmiştir. Rüzgâr şiddetleri, yaklaşık 5 ile 60 dakika arasındaki zaman ölçeğinde güçlü bir zaman bağımlılığı sergiler ve bu aralık atmosferik sınır tabakası içerisinde türbülans-konveksiyon etkileşiminin baskın olduğu zaman penceresini temsil eder. Bu nedenle 12 saatlik geçmiş bilginin modele sunulması, hem rüzgârın hafıza davranışını doğru şekilde temsil etmekte hem de ANN'in kısa vadeli dalgalanmaları yakalama kapasitesini artırmaktadır. Bu yaklaşım, literatürde kısa vadeli rüzgâr tahminlerinde kullanılan ideal gecikme aralıklarıyla uyumludur.

ANN mimarisinde kullanılan iki gizli katman (Ek A.2.4), rüzgâr serilerinin doğrusal olmayan yapısını modellemek için yeterli esnekliği sağlamaktadır. Birinci katmandaki 64 nöron ve ikinci katmandaki 32 nöron, kısa vadeli rüzgâr tahmini çalışmalarında sık kullanılan optimum aralıklardadır. Aktivasyon fonksiyonu olarak seçilen ReLU, hem hesaplama verimliliği hem de negatif olmayan rüzgâr verisi dağılımları ile uyumluluğu nedeniyle tercih edilmiştir. ReLU'nun gradyan kaybını azaltarak öğrenme sürecini hızlandırması, özellikle ani rüzgâr değişimlerinin hâkim olduğu veri setlerinde büyük avantaj sağlamaktadır.

Model eğitiminde kullanılan EPOCHS = 30, BATCH = 64 ve validation_split = 0.10 değerleri hem literatürde önerilen aralıklarla uyumludur hem de bu çalışmanın veri setine yönelik yapılan ön testler sonucunda belirlenmiştir. Rüzgâr serilerinin yüksek varyanslı ve gürültülü doğası dikkate alındığında, çok yüksek epoch değerleri aşırı uyuma yol açabileceğinden eğitim süreci 30 epoch ile sınırlandırılmıştır. Batch size değerinin 64 olarak seçilmesi, optimizasyon sürecinin stabilitesini artırmış ve öğrenme sürecini hızlandırmıştır. Validasyon oranı ise modelin eğitim sırasında aşırı uyuma girmesini önlemek amacıyla %10 olarak tercih edilmiştir.

Aktivasyon fonksiyonu olarak ReLU seçilmiştir; çünkü rüzgâr şiddetinin fiziksel olarak negatif değer almaması, ani hızlanmaların (gust) pozitif yönlü ve keskin karakteristiği, ReLU'nun gürültülü sinyallerde doygunluğa girerek bilgi kaybına neden olabilen sigmoid veya tanh fonksiyonlarına kıyasla daha uygun olmasını sağlamaktadır.

Tüm bu parametreler birlikte ele alındığında ANN modelinin rüzgâr şiddetindeki kısa ölçekli, yüksek varyanslı ve nonlinear atmosferik süreçleri başarılı bir şekilde öğrenmesine olanak sağladığı görülmektedir.

3.3.3 LSTM modeli parametreleri

Bu çalışmada kullanılan Uzun-Kısa Süreli Bellek (LSTM) modeline ilişkin uygulama adımları Ek A.3 bölümünde ayrıntılı olarak sunulmuştur. LSTM, zaman bağımlılığı yüksek olan meteorolojik veriler üzerinde başarılı performansı nedeniyle tercih edilmiştir. Rüzgâr şiddeti, atmosferik sınır tabakası süreçlerine bağlı olarak kısa ve orta vadede güçlü bir hafıza etkisi gösterdiğinden, klasik derin öğrenme yaklaşımlarına kıyasla LSTM'nin kapı mekanizmaları (input, forget ve output gates) bu tür dinamikleri daha etkili biçimde temsil eder. Literatürde rüzgâr gibi gürültülü ve doğrusal olmayan süreçlerde LSTM'nin hem ani değişimleri hem de uzun süreli bağımlılıkları öğrenmede üstün performans gösterdiği belirtilmektedir.

Ek A.3.4'te gösterilen gecikme penceresi oluşturma adımında LOOKBACK = 12 değerinin seçilmesi, rüzgâr şiddetinin 20–60 dakika aralığında belirgin zaman

bağımlılığı taşıdığına ilişkin atmosferik literatürle uyumludur. Bu lookback penceresi, LSTM katmanlarına hem yakın geçmişin türbülans etkilerini hem de sinoptik küçük ölçekli döngüleri aktarmak açısından optimal bir uzunluk sağlamaktadır. Çok küçük lookback değerleri hafıza etkisini zayıflatırken, aşırı büyük değerler model karmaşıklığını artırıp öğrenmeyi zorlaştırmaktadır. Bu nedenle 12 adımlık geçmiş bilgisi hem fiziksel hem istatistiksel açıdan dengeli bir seçimdir.

Bu çalışmada kullanılan $LOOKBACK = 12$ parametresi, modelin her tahmini üretirken önceki 12 zaman adımını (60 dakikalık çözünürlükte 12 saatlik geçmiş) girdi olarak kullanması anlamına gelmektedir. Böylece LSTM, rüzgâr şiddetinin kısa vadeli türbülans bileşenlerini ve daha uzun ölçekli konvektif/topografik etkileri aynı anda temsil edebilmektedir.

Modelin eğitim sürecinde $EPOCHS = 40$ değeri tercih edilmiştir. Rüzgâr serilerinin yüksek varyanslı ve gürültülü doğası nedeniyle çok yüksek epoch değerleri modelin aşırı öğrenme eğilimini artırmaktadır. Ön testler, 30–50 epoch aralığının en dengeli performansı verdiğini göstermiş; bu nedenle 40 epoch değeri hem öğrenme sürecinin tamamlanması hem de aşırı uyum riskinin azaltılması açısından uygun bulunmuştur.

LSTM mimarisinde kullanılan iki katmanlı yapı (Ek A.3.5) rüzgâr şiddetinin hem düşük frekanslı hem de yüksek frekanslı bileşenlerini modellemek için uygundur. İlk LSTM katmanındaki 128 nöron, girdilerden karmaşık zamansal ilişkiler çıkarırken; ikinci LSTM katmanı 64 nöron ile daha yoğun olmayan bir temsil oluşturarak yüksek seviyeli özellikleri süzer. Bu yapı, literatürde rüzgâr tahmini için önerilen çok katmanlı LSTM mimarileriyle tutarlıdır. Son katmandaki $Dense(1)$ çıkış birimi ise doğrudan rüzgâr şiddetinin (m/s) tahmin edecek şekilde yapılandırılmıştır.

Modelde kullanılan $Dropout$ katmanları (Ek A.3.5) rüzgâr serisinin yüksek varyanslı doğası nedeniyle aşırı öğrenmeyi engellemek için kritik bir bileşendir. LSTM modelleri, yüksek parametre sayıları nedeniyle aşırı uyuma eğilimlidir; bu nedenle yüzde 10 ile yüzde 20 aralığında dropout uygulanması, modelin genelleme kapasitesini artırır. Dropout, özellikle ani hız değişimleri içeren dönemlerde modelin belirli nöronlara aşırı bağımlı hâle gelmesini engelleyerek daha dengeli bir temsil üretir.

Modelin eğitim sırasında aşırı uyuma girmesini önlemek amacıyla verinin %12'si doğrulama (validation) için ayrılmıştır ($VAL_SPLIT = 0.12$). Rüzgâr şiddetinin zamansal değişkenliği yüksek olduğundan, doğrulama setinin yeterli büyüklükte olması modelin genel performansını daha sağlıklı izlemesini sağlamaktadır.

Erken durdurma mekanizması olarak $PATIENCE = 6$ değeri kullanılmıştır. Bu parametre, doğrulama kaybında art arda altı epoch boyunca iyileşme görülmediğinde eğitimin durdurulmasını sağlamaktadır. Böylece modelin gereksiz yere uzun süre eğitilmesi engellenmiş, hem aşırı uyum (overfitting) riski azaltılmış hem de eğitim süresi optimize edilmiştir.

Eğitim sürecinde kullanılan `EarlyStopping` ve `ReduceLROnPlateau` callback mekanizmaları (Ek A.3.5) literatürde LSTM eğitim stabilitesini artırmak için en çok önerilen stratejiler arasındadır. `EarlyStopping`, validasyon kaybında iyileşme olmadığında eğitimi durdurarak aşırı uyumu önlerken, `ReduceLROnPlateau` öğrenme hızının dinamik biçimde ayarlanmasını sağlar. Rüzgâr şiddetinin gürültülü yapısı nedeniyle optimizasyon süreci zaman zaman “plateau” olarak bilinen duraklama bölgelerinde takılabildiğinden, bu mekanizmaların birlikte kullanımı modelin daha hızlı ve kararlı biçimde yakınsamasını sağlamaktadır.

Bu çalışmada gecikme yapısının ve model parametrelerinin seçimine ilişkin yapılan tüm açıklamalar, 60 dakikalık zaman çözünürlüğüne sahip veri seti için geçerlidir. Rüzgâr şiddetinin 5 ile 60 dakika arasındaki zaman ölçeğinde belirgin bir hafıza etkisi göstermesi nedeniyle, 60 dakikalık veride kullanılan $LAG_STEPS = 12$ değeri hem fiziksel hem istatistiksel açıdan uygun bir temsil sağlamaktadır. Daha yüksek veya daha düşük çözünürlüklere sahip veri setlerinde (örneğin 1, 5, 10 veya 30 dakikalık serilerde) rüzgârın karakteristik zaman ölçekleri değişeceğinden, gecikme adımlarının yeniden belirlenmesi gerekmektedir. Dolayısıyla bu bölümde sunulan gecikme penceresi, ölçeklendirme yaklaşımı ve model yapılandırması yalnızca 60 dakikalık zaman aralığı için optimize edilmiştir.



4. SONUÇLAR VE DEĞERLENDİRMELER

Bu bölümde model çıktı grafiklerinin meteorolojik ve istatistiksel yorumu yapılmıştır.

4.1 Meteorolojik Değişkenlerin İncelenmesi

Model performansını girdi duyarlılığı açısından değerlendirebilmek için ilk aşamada yalnızca rüzgâr değişkeni kullanılarak tahmin çıktıları elde edilmiştir. İkinci aşamada giriş setine sıcaklık değişkeni eklenmiş; böylece atmosferin termodinamik yapısının kısa vadeli rüzgâr değişimlerine katkısı modellenmiştir. Üçüncü aşamada modele basınç değişkeninin dâhil edilmesiyle atmosferik kararlılık ve büyük ölçekli basınç gradyanlarına bağlı rüzgâr davranışı daha tutarlı şekilde temsil edilmiştir. Bu bölümde, modellerin (ARIMA, ANN, LSTM) farklı çözünürlüklerdeki tahmin performansı Ek B’de sunulan tablolar ve şekiller üzerinden değerlendirilmiştir.

Çizelge 4.1: Yalnızca rüzgar verileri ile modellere ait hata metriklerinin karşılaştırılması (1 dk).

Model	MSE	RMSE	MAE	R ²
ARIMA	9.809280	3.131977	2.342993	-0.173391
ANN	0.772904	0.879150	0.623524	0.907545
LSTM	0.605414	0.778083	0.519290	0.927580

Çizelge 4.2: Rüzgâr ve sıcaklık girdileri kullanılarak elde edilen modellere ait hata metriklerinin karşılaştırılması (1 dk).

Model	MSE	RMSE	MAE	R ²
ANN	0.796416	0.892421	0.657508	0.904732
LSTM	1.224951	1.106775	0.825252	0.853471
ARIMA	12.920835	3.594556	2.664601	-0.545596

Çizelge 4.3: Rüzgâr, sıcaklık ve basınç verileri kullanılarak elde edilen modellere ait hata metriklerinin karşılaştırılması (1 dk).

Model	MSE	RMSE	MAE	R ²
LSTM	0.609730	0.780852	0.524770	0.927064
ANN	1.919172	1.385342	1.063342	0.770428
ARIMA	13.599141	3.687701	2.733698	-0.626735

10–12 Nisan 2023 dönemine ait modellerin 1 dakikalık çözünürlükteki hata metrikleri incelendiğinde, yalnızca rüzgâr girdilerinin kullanıldığı Çizelge 4.1’de LSTM modelinin en düşük MSE, RMSE ve MAE değerlerini üreterek açık ara en başarılı performansı sergilediği görülmektedir. ANN modeli orta düzeyde bir doğruluk sunarken, ARIMA modeli hem yüksek hata değerleri hem de negatif R² katsayısı ile kısa vadeli değişimlere uyum sağlamakta yetersiz kalmıştır. Bu sonuçlar, tek değişkenli rüzgâr tahminlerinde doğrusal olmayan öğrenme yöntemlerinin (LSTM, ANN) belirgin bir üstünlüğe sahip olduğunu göstermektedir.

Rüzgâr ve sıcaklık girdilerinin birlikte kullanıldığı Çizelge 4.2 incelendiğinde, model performanslarında dikkate değer iyileşmeler gözlenmektedir. Özellikle ANN modelinin sıcaklık kaynaklı yavaş trendleri başarılı biçimde temsil ederek hata metriklerinde belirgin düşüş sağladığı görülmektedir. LSTM modeli ise girdi setine sıcaklığın eklenmesiyle kısa ölçekli dalgalanmaları daha kararlı bir şekilde yakalamış, ancak bu senaryoda ANN ile benzer bir doğruluk düzeyi elde etmiştir. ARIMA modeli ise sıcaklık değişkeninin eklenmesine rağmen doğrusal yapısının sınırları nedeniyle gelişmiş modellerin oldukça gerisinde kalmıştır. Bu bulgu, sıcaklığın rüzgâr şiddetinin kısa vadeli varyasyonları üzerinde anlamlı bir bilgi katkısı sunduğunu göstermektedir.

Rüzgâr, sıcaklık ve basınç girdilerinin birlikte değerlendirildiği Çizelge 4.3’te ise model performansının en yüksek seviyeye ulaştığı açıkça görülmektedir. LSTM modeli üç değişkenli veri setinde en düşük hata değerlerini üreterek hem kısa vadeli hem de trend bileşenli değişimleri en başarılı biçimde temsil etmiştir. ANN modeli de güçlü bir performans sergilemiş, ancak LSTM’in küçük ölçekli gürültülü değişimlere daha hızlı tepki verme kapasitesi nedeniyle ikinci sırada kalmıştır. ARIMA modeli ise basınç değişkeninin eklenmesine rağmen belirgin bir iyileşme sağlayamamış ve modern derin

öğrenme modellerinin oldukça gerisinde kalmıştır. Bu karşılaştırma genel olarak, özellikle basınç değişkeninin eklenmesiyle fiziksel süreçlerin daha bütüncül şekilde temsil edildiğini ve veri odaklı modellerin tahmin doğruluğunun anlamlı biçimde arttığını göstermektedir.

Ayrıca bu çalışma kapsamında yalnızca örnek niteliğindeki tarihler değil, incelenen 5 farklı tarihe ait modellerin yalnızca rüzgâr, rüzgâr&sıcaklık ve rüzgâr&sıcaklık&basınç girdileri kullanılarak elde edilen 1, 5, 10, 30 ve 60 dakikalık çözünürlükteki tüm hata metrikleri ve zaman serisi çıktıları ayrıntılı biçimde değerlendirilmiştir. Bu kapsamlı sonuçlar, karşılaştırmalı incelemelerin bütünlüğünü sağlamak amacıyla Ek 2’de toplu şekilde sunulmuştur.


4.2 Belirlenen Tarihler için Model Sonuçları

Bu bölümde, çalışma kapsamında seçilen beş farklı tarihe ait kısa vadeli rüzgâr şiddeti tahmin performansları ayrıntılı biçimde değerlendirilmiştir. Her bir tarih için 1, 5, 10, 30 ve 60 dakikalık zaman çözünürlüklerinde model çıktıları üretilmiş; böylece hem yüksek frekanslı ani değişimlerin hem de daha uzun ölçekli eğilimlerin temsil yeterliliği karşılaştırmalı olarak incelenmiştir.


Çalışmada, kısa vadeli rüzgâr şiddeti tahminini etkileyen atmosferik koşulların bütüncül bir çerçevede değerlendirilmesi amacıyla rüzgâr, sıcaklık, basınç, yağış ve nem olmak üzere beş temel meteorolojik değişken birlikte ele alınmış ve modeller bu çok bileşenli veri seti üzerinden test edilmiştir. Bu çoklu değişken yaklaşımı, rüzgâr şiddetinin atmosferik koşullara bağlı karmaşık yapısının daha bütüncül bir şekilde temsil edilmesini amaçlamakta olup, farklı çözünürlüklerde ve farklı günlerde gözlenen model performans farklılıklarının meteorolojik süreçlerle ilişkisini ortaya koymayı hedeflemektedir.

4.2.1 1 Şubat-12 Nisan 2023 tarihine ait sonuçlar


4.2.1.1 1 Dakikalık zaman çözünürlüğü sonuçları



Şekil 4.1: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil 4.2: ANN modeli tahmin-gözlem karşılaştırması.




Şekil 4.3: LSTM modeli tahmin-gözlem karşılaştırması.

Çizelge 4.4: 10–12 Nisan 2023 (1 dakika) – model karşılaştırması.


Model	MSE	RMSE	MAE	R ²
ANN	0.796416	0.892421	0.657508	0.904732
LSTM	1.224951	1.106775	0.825252	0.853471
ARIMA	9.809280	3.131977	2.342993	-0.173391

1 Şubat–12 Nisan 2023 dönemine ait 1 dakikalık rüzgâr şiddeti verilerinin modellenmesine ilişkin sonuçlar incelendiğinde, Şekil 4.1–4.3 ile Çizelge 4.4’te de görüldüğü üzere, üç model arasında yalnızca ANN’in tatmin edici bir performans sergilediği, LSTM’in sınırlı ölçüde başarılı olduğu, ARIMA modelinin ise yüksek zaman çözünürlüklü veriyi temsil etmede belirgin biçimde yetersiz kaldığı anlaşılmaktadır. ARIMA modelinin tahmin eğrisi (Şekil 4.1), gözlenen rüzgâr şiddetindeki yüksek frekanslı dalgalanmaları neredeyse tamamen düzleştirerek düşük varyanslı bir yapı üretmiş; özellikle ani artış ve azalışların yaşandığı zaman dilimlerinde gerçek seriden sistematik ve büyük sapmalar vermiştir. LSTM modeli (Şekil 4.3) genel eğilim ve orta ölçekli değişimleri kısmen yakalayabilse de, pik değerleri ve kısa süreli şiddetli dalgalanmaları bastırarak daha yumuşak bir tahmin üretmiş ve bu nedenle ANN’e kıyasla daha yüksek hata değerlerine sahip olmuştur. Çizelge 4.4’te sunulan metrikler de bu gözlemleri sayısal olarak doğrulamakta; ANN modelinin en düşük MSE, RMSE ve MAE değerleri ile en yüksek R² katsayısına sahip olduğu, LSTM’in ise orta düzeyde bir doğruluk sunarken ARIMA’nın negatif R² değeri ile temel bir doğrusal modelin dahi gerisinde kaldığı görülmektedir. Bu sonuçlar, söz konusu dönem için 1 dakikalık zaman çözünürlüğüne sahip rüzgâr verilerinin modellenmesinde yalnızca ANN modelinin operasyonel anlamda kullanılabilir nitelikte olduğunu, LSTM’in ise ancak ikincil veya destekleyici bir model olarak değerlendirilebileceğini, ARIMA yaklaşımının ise bu çözünürlükte uygun olmadığını ortaya koymaktadır.


4.2.1.2 5 Dakikalık zaman çözünürlüğü sonuçları



Şekil 4.4: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil 4.5: ANN modeli tahmin-gözlem karşılaştırması.




Şekil 4.6: LSTM modeli tahmin-gözlem karşılaştırması.

Çizelge 4.5: 10–12 Nisan 2023 (5 dakika) – model karşılaştırması.


Model	MSE	RMSE	MAE	R ²
ANN	1.409689	1.187303	0.914460	0.818707
LSTM	2.469512	1.571468	1.213533	0.682408
ARIMA	12.342017	3.513121	2.656758	-0.587245

10–12 Nisan 2023 dönemine ait 5 dakikalık rüzgâr şiddeti verilerinin modellenmesine ilişkin çıktılar incelendiğinde, Şekil 4.4–4.6 ile Çizelge 4.5’te sunulan performans metrikleri, modeller arasında belirgin bir ayrışma olduğunu göstermektedir. ARIMA modelinin tahmin eğrisi (Şekil 4.4), gözlenen rüzgâr şiddetindeki orta ve yüksek frekanslı dalgalanmaları temsil edemeyerek aşırı düzleşmiş bir yapı ortaya koymuş; özellikle pik değerler ile hızlı yön değişimlerinin yaşandığı zaman aralıklarında gerçek seriden büyük sapmalar vermiştir. LSTM modeli (Şekil 4.6), genel eğilimleri ve olayların zamanlamasını kısmen yakalayabilmiş olmakla birlikte, ani hızlanma ve yavaşlamaları sistematik biçimde yumuşatarak tahmin genliğini düşürmüş ve bu nedenle ANN modelinin gerisinde kalmıştır. Buna karşılık ANN modeli (Şekil 4.5), hem rüzgâr şiddetinin genlik yapısını hem de kısa zaman ölçekli değişimlerini yüksek doğrulukla temsil ederek gözlem serisiyle büyük ölçüde çakışan bir tahmin üretmiştir. Çizelge 4.5’te sunulan MSE, RMSE ve MAE değerleri de bu gözlemleri sayısal olarak desteklemekte; ANN modelinin en düşük hata metriklerine ve en yüksek R² değerine sahip olduğu, LSTM’in orta düzeyde performans gösterdiği, ARIMA modelinin ise negatif R² değeri ile temel doğrusal eğilimleri dahi yakalayamadığı anlaşılmaktadır. Bu sonuçlar, 5 dakikalık zaman çözünürlüğüne sahip rüzgâr verilerinin modellenmesinde ANN yaklaşımının en güvenilir ve operasyonel olarak en uygun yöntem olduğunu, LSTM’in ek bir yardımcı model olarak değerlendirilebileceğini, ARIMA’nın ise bu çözünürlükte kullanılabilirliğinin son derece sınırlı kaldığını ortaya koymaktadır.


4.2.1.3 10 Dakikalık zaman çözünürlüğü sonuçları



Şekil 4.7: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil 4.8: ANN modeli tahmin-gözlem karşılaştırması.




Şekil 4.9: LSTM modeli tahmin-gözlem karşılaştırması.

Çizelge 4.6: 10–12 Nisan 2023 (10 dakika) – model karşılaştırması.


Model	MSE	RMSE	MAE	R ²
ANN	1.749393	1.322646	1.005611	0.762488
LSTM	3.237982	1.799439	1.421735	0.560385
ARIMA	10.445628	3.231970	2.414160	-0.418184

10–12 Nisan 2023 dönemine ait 10 dakikalık rüzgâr şiddeti verilerinin modellenmesine ilişkin elde edilen sonuçlar incelendiğinde, Şekil 4.7–4.9 ile Çizelge 4.6’da da görüldüğü üzere, ANN modelinin bu zaman çözünürlüğünde en başarılı performansı sergilediği belirlenmiştir. ANN tahminleri, özellikle orta ölçekli dalgalanmaların genliğini ve zamanlamasını yüksek doğrulukla yakalayarak gözlem serisi ile büyük ölçüde çakışan bir yapı sunmuştur. LSTM modeli ise genel eğilimleri takip etmesine rağmen, ani hızlanma ve yavaşlamaları sistematik biçimde yumuşatmış; bu nedenle tahmin genliğinde belirgin azalmalar gözlenmiş ve ANN’in gerisinde kalmıştır. ARIMA modelinin tahmin eğrisi (Şekil 4.7), rüzgâr şiddetindeki değişkenliği temsil etmekte bariz bir yetersizlik göstermiş; düşük varyanslı ve düzleşmiş bir tahmin yapısı ortaya koyarak gerçek seriden önemli sapmalar üretmiştir. Çizelge 4.6’da sunulan hata metrikleri de bu değerlendirmeleri desteklemekte; ANN modelinin en düşük MSE, RMSE ve MAE değerlerine ve en yüksek R² katsayısına sahip olduğu, LSTM’in orta düzeyde performans sunduğu, ARIMA’nın ise negatif R² değeri ile temel doğrusal eğilimleri dahi yakalayamadığı görülmektedir.


4.2.1.4 30 Dakikalık zaman çözünürlüğü sonuçları



Şekil 4.10: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil 4.11: ANN modeli tahmin-gözlem karşılaştırması.



Şekil 4.12: LSTM modeli tahmin-gözlem karşılaştırması.


Çizelge 4.7: 10–12 Nisan 2023 (30 dakika) – model karşılaştırması.

Model	MSE	RMSE	MAE	R ²
ANN	2.284922	1.511596	1.184581	0.655273
LSTM	5.180350	2.276038	1.823651	0.218439
ARIMA	7.589214	2.754853	2.044901	-0.144987


10–12 Nisan 2023 dönemine ait 30 dakikalık rüzgâr şiddeti verilerinin modellenmesine ilişkin sonuçlar incelendiğinde, Şekil 4.10–4.12 ile Çizelge 4.7’de görüldüğü üzere, ANN modelinin bu çözünürlükte de en başarılı tahmin performansını sunduğu belirlenmiştir. ANN tahminleri, gözlenen serinin genlik yapısını ve olayların zamanlamasını büyük oranda korumuş; model, hem pik değerleri hem de geçiş bölgelerini makul doğrulukla yakalamıştır. LSTM modeli ise düşük frekanslı bir tahmin yapısı üretmiş, özellikle hızlı değişimlerin yaşandığı dönemlerde genliği belirgin biçimde bastırarak gerçek seriden sapmıştır. ARIMA modeli, önceki zaman

çözünürlüklerinde olduğu gibi, rüzgâr şiddetindeki değişkenliği temsil etmekte yetersiz kalmış; düzleşmiş tahmin eğrileri nedeniyle gözlem serisinin dinamik yapısını yakalayamamıştır. Çizelge 4.7’de sunulan hata metrikleri bu bulguları desteklemekte; ANN modelinin en düşük MSE, RMSE ve MAE değerlerine, LSTM’in orta düzey bir performansa, ARIMA’nın ise negatif R^2 değeri ile zayıf bir temsil gücüne sahip olduğu görülmektedir.


4.2.1.5 60 Dakikalık zaman çözünürlüğü sonuçları



Şekil 4.13: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil 4.14: ANN modeli tahmin-gözlem karşılaştırması.



Şekil 4.15: LSTM modeli tahmin-gözlem karşılaştırması.


Çizelge 4.8: 10–12 Nisan 2023 (60 dakika) – model karşılaştırması.

Model	MSE	RMSE	MAE	R ²
ANN	3.335609	1.826365	1.373851	0.450470
LSTM	6.352466	2.520410	2.005110	-0.046546
ARIMA	6.716475	2.591616	1.903531	-0.106516


10–12 Nisan 2023 dönemine ait 60 dakikalık rüzgâr şiddeti verilerinin modellenmesine ilişkin sonuçlar incelendiğinde, Şekil 4.13–4.15 ile Çizelge 4.8’de görüldüğü üzere, ANN modelinin bu çözünürlükte de diğer modellere kıyasla daha başarılı bir performans sergilediği belirlenmiştir. ANN tahminleri, düşük örnekleme frekansının getirdiği bilgi kaybına rağmen, gözlenen serinin genel eğilimlerini ve pik yapılarını makul doğrulukla yakalamıştır. LSTM modeli ise yüksek genlikli değişimleri belirgin biçimde yumuşatarak tahmin genliğini düşürmüştü ve özellikle pik değerlerde gerçek serinin gerisinde kalmıştır. ARIMA modeli, önceki çözünürlüklerde olduğu gibi, rüzgâr şiddetinin dinamik yapısını temsil etmekte yetersiz kalmış; düzleşmiş tahmin eğrileri nedeniyle gözlem serisinden büyük sapmalar üretmiştir. Çizelge 4.8’de sunulan hata metrikleri bu değerlendirmeleri desteklemekte; ANN modelinin en düşük hata değerleri ve en yüksek R² katsayısına sahip olduğu, LSTM’in sınırlı doğruluk sunduğu, ARIMA’nın ise negatif R² değeri ile zayıf temsil gücüne sahip olduğu görülmektedir.

4.2.2 1 Eylül-20 Kasım 2023 tarihine ait sonuçlar


4.2.2.1 1 Dakikalık zaman çözünürlüğü sonuçları



Şekil 4.16: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil 4.17: ANN modeli tahmin-gözlem karşılaştırması.




Şekil 4.18: LSTM modeli tahmin-gözlem karşılaştırması.

Çizelge 4.9: 18–20 Kasım 2023 (1 dakika) – model karşılaştırması.


Model	MSE	RMSE	MAE	R ²
ANN	1.028355	1.014079	0.609907	0.953674
LSTM	2.671957	1.634612	1.063316	0.879631
ARIMA	65.327276	8.082529	6.579237	-1.942921

18–20 Kasım 2023 dönemine ait 1 dakikalık rüzgâr şiddeti verilerinin modellenmesine ilişkin bulgular, Şekil 4.16–4.18 ile Çizelge 4.9’da sunulduğu üzere, modeller arasında belirgin bir performans farklılığı olduğunu göstermektedir. ANN modeli, hem düşük hem yüksek rüzgâr şiddetlerinde gerçek serinin genlik yapısını ve geçiş bölgelerini başarıyla yakalayıp dönem boyunca en tutarlı ve en doğru tahminleri üretmiştir. LSTM modeli de genel eğilimi temsil etme açısından güçlü bir performans sergilemiş; ancak özellikle şiddetli rüzgâr artışlarının yaşandığı zamanlarda tahmin genliğini kısmen yumuşatarak ANN’in gerisinde kalmıştır. ARIMA modeli ise yüksek zaman çözünürlüğüne sahip bu veri setini temsil etmekte belirgin biçimde yetersiz kalmış; tahmin eğrisi düşük varyanslı ve aşırı düzleştirilmiş bir yapı göstermiş, bu nedenle pik değerlerin neredeyse tamamında gerçek seriden uzaklaşmıştır. Çizelge 4.9’da sunulan hata metrikleri de bu değerlendirmeleri doğrulamakta; ANN modelinin en düşük MSE, RMSE ve MAE değerleri ile en yüksek R² katsayısına sahip olduğu, LSTM’in orta düzeyde bir doğruluk sunduğu, ARIMA’nın ise negatif R² değeri ile temel eğilimleri dahi yakalayamadığı görülmektedir.


4.2.2.2 5 Dakikalık zaman çözünürlüğü sonuçları



Şekil 4.19: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil 4.20: ANN modeli tahmin-gözlem karşılaştırması.



Şekil 4.21: LSTM modeli tahmin-gözlem karşılaştırması.


Çizelge 4.10: 18–20 Kasım 2023 (5 dakika) – model karşılaştırması.

Model	MSE	RMSE	MAE	R ²
ANN	1.636991	1.279450	0.929263	0.922356
LSTM	2.738218	1.654756	1.217543	0.870124
ARIMA	66.242485	8.138949	6.701517	-2.141946


18–20 Kasım 2023 dönemine ait 5 dakikalık rüzgâr şiddeti verilerinin modellenmesine ilişkin sonuçlar incelendiğinde, Şekil 4.19–4.21 ile Çizelge 4.10’da sunulan performans metrikleri, ANN modelinin bu çözünürlükte de en başarılı yöntem olduğunu ortaya koymaktadır. ANN tahminleri, hem düşük hem yüksek rüzgâr şiddetlerinde gerçek seri ile yüksek uyum göstermiş; özellikle dalgalanmaların genlik ve zamanlama özelliklerini başarıyla yakalamıştır. LSTM modeli genel eğilimi temsil etmekte etkili olsa da, ani hızlanma ve yavaşlamaların görüldüğü zamanlarda tahmin genliğini yumuşatmış ve ANN’in gerisinde kalmıştır. ARIMA modeli ise yüksek

zaman çözünürlüğündeki davranışını bu çözünürlükte de sürdürmüş; düşük varyanslı ve aşırı düzleştirilmiş tahmin eğrileri nedeniyle gerçek seriyi temsil etmede belirgin şekilde yetersiz kalmıştır. Çizelge 4.10'daki hata metrikleri de bu değerlendirmeleri desteklemekte; ANN modelinin en düşük MSE, RMSE ve MAE değerlerine ve en yüksek R^2 katsayısına sahip olduğu, LSTM'in orta düzeyde bir performans sunduğu, ARIMA'nın ise negatif R^2 değeri ile başarısız bir tahmin ortaya koyduğu görülmektedir.


4.2.2.3 10 Dakikalık zaman çözünürlüğü sonuçları



Şekil 4.22: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil 4.23: ANN modeli tahmin-gözlem karşılaştırması.




Şekil 4.24: LSTM modeli tahmin-gözlem karşılaştırması.

Çizelge 4.11: 18–20 Kasım 2023 (10 dakika) – model karşılaştırması.


Model	MSE	RMSE	MAE	R ²
ANN	1.914355	1.383602	1.013749	0.909138
LSTM	4.125128	2.031041	1.512200	0.804208
ARIMA	45.577828	6.751135	5.072346	-1.163272

18–20 Kasım 2023 dönemine ait 10 dakikalık rüzgâr şiddeti verilerinin modellenmesine ilişkin sonuçlar incelendiğinde, Şekil 4.22–4.24 ve Çizelge 4.11 modeller arasındaki performans farklarını açık bir biçimde ortaya koymaktadır. ANN modeli, hem düşük hem yüksek şiddet rejimlerinde gözlenen serinin genlik yapısını başarıyla yakalamış, pik değerlerin zamanlamasını büyük ölçüde doğru temsil etmiştir. LSTM modeli ise genel eğilimi makul ölçüde takip etmekle birlikte, özellikle ani hız artışlarının yaşandığı zaman aralıklarında genliği bastırma eğilimi göstermiş ve bu durum modelin hata metriklerine yansımıştır. ARIMA modeli ise önceki zaman çözünürlüklerinde olduğu gibi, serinin yüksek frekanslı bileşenlerini temsil edememiş; düzleşmiş tahmin eğrileri nedeniyle hem genlik hem varyans açısından gerçek seriden önemli ölçüde sapmıştır. Çizelge 4.11’de sunulan MSE, RMSE, MAE ve R² değerleri, ANN’in açık ara en düşük hata seviyesine ve en yüksek doğruluk katsayısına sahip olduğunu; LSTM’in orta düzeyde bir performans sergilediğini; ARIMA’nın ise negatif R² değeri ile bu çözünürlükte rüzgâr şiddetinin değişken yapısını temsil etmekte yetersiz kaldığını göstermektedir.


4.2.2.4 30 Dakikalık zaman çözünürlüğü sonuçları



Şekil 4.25: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil 4.26: ANN modeli tahmin-gözlem karşılaştırması.




Şekil 4.27: LSTM modeli tahmin-gözlem karşılaştırması.

Çizelge 4.12: 18–20 Kasım 2023 (30 dakika) – model karşılaştırması.


Model	MSE	RMSE	MAE	R ²
ANN	4.154103	2.038162	1.525332	0.795318
LSTM	9.366401	3.060458	2.291354	0.538497
ARIMA	41.544002	6.445464	4.765115	-1.046963

18–20 Kasım 2023 dönemine ait 30 dakikalık rüzgâr şiddeti modelleme sonuçları incelendiğinde, Şekil 4.25–4.27 ile Çizelge 4.12’de sunulan bulgular, ANN modelinin bu çözünürlükte de açık biçimde en başarılı yaklaşım olduğunu göstermektedir. ANN tahminleri, hem pik değerlerin genlik yapısını hem de geçiş dönemlerindeki artış–azalış eğilimlerini büyük ölçüde doğru temsil etmiş; model, yüksek frekanslı dalgalanmaların bir kısmını yumuşatsa da genel dinamiği koruyarak gözlem serisine oldukça yakın bir davranış ortaya koymuştur. LSTM modeli ise orta düzeyde bir performans sergilemiş; özellikle ani hız artışlarının ve hızlı düşüşlerin yaşandığı zaman dilimlerinde genliği belirgin biçimde bastırmış ve gözlem değerlerinin altında kalmıştır. ARIMA modeli ise düşük varyanslı ve aşırı düzleştirilmiş tahmin yapısı nedeniyle gerçek serinin dinamiklerini yakalayamamış; hem pik değerleri hem de olay zamanlamalarını temsil etmekte başarısız olmuştur. Çizelge 4.12’deki hata metrikleri bu değerlendirmeleri desteklemekte olup ANN modelinin en düşük MSE, RMSE ve MAE değerleriyle en yüksek R² katsayısına ulaştığı, LSTM’in sınırlı düzeyde bir doğruluk sağladığı, ARIMA’nın ise negatif R² değeriyle zayıf performans sergilediği görülmektedir.


4.2.2.5 60 Dakikalık zaman çözünürlüğü sonuçları



Şekil 4.28: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil 4.29: ANN modeli tahmin-gözlem karşılaştırması.



Şekil 4.30: LSTM modeli tahmin-gözlem karşılaştırması.

Çizelge 4.13: 18–20 Kasım 2023 (60 dakika) – model karşılaştırması.


Model	MSE	RMSE	MAE	R ²
ANN	5.702257	2.387940	1.814683	0.713721
LSTM	19.477407	4.413322	3.246618	0.022146
ARIMA	40.347862	6.351997	4.677212	-1.025644

18–20 Kasım 2023 dönemine ait 60 dakikalık rüzgâr şiddeti modelleme sonuçları incelendiğinde, Şekil 4.28–4.30 ile Çizelge 4.13’te görüldüğü üzere, ANN modeli bu zaman çözünürlüğünde de en başarılı performansı göstermiştir. ANN tahminleri, özellikle pik değerlerin zamanlaması ve orta ölçekli değişimlerin büyüklüğü açısından gözlem serisiyle yüksek uyum sağlamış; model, dalgalanma genliklerini bir miktar yumuşatmakla birlikte genel dinamiği büyük ölçüde korumuştur. LSTM modeli ise 60 dakikalık çözünürlükte belirgin biçimde zayıflamış; hem yükseliş hem düşüş evrelerinde genlik kaybı gözlenmiş ve yüksek hızların yaşandığı dönemlerde gerçek


değerlerin oldukça altında kalmıştır. ARIMA modeli ise düşük varyanslı, aşırı düzleştirilmiş yapısı nedeniyle serinin hem ani değişimlerini hem de tepe değerlerini temsil edememiş; uzun dönemli eğilimi takip etmeye çalışsa da gerçek seriden belirgin biçimde ayrılmıştır. Çizelge 4.13'deki hata metrikleri bu değerlendirmeleri desteklemekte olup ANN modelinin en düşük MSE, RMSE ve MAE değerlerine ve en yüksek R^2 katsayısına ulaştığı; LSTM'in oldukça sınırlı bir doğruluk sunduğu; ARIMA'nın ise negatif R^2 değeriyle çözünürlüğün artmasıyla performans kaybının daha da belirginleştiği görülmektedir.

4.2.3 1 Mart-25 Mayıs 2024 tarihine ait sonuçlar


4.2.3.1 1 Dakikalık zaman çözünürlüğü sonuçları



Şekil 4.31: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil 4.32: ANN modeli tahmin-gözlem karşılaştırması.




Şekil 4.33: LSTM modeli tahmin-gözlem karşılaştırması.

Çizelge 4.14: 23–25 Mayıs 2024 (1 dakika) – model karşılaştırması.


Model	MSE	RMSE	MAE	R^2
ANN	0.762339	0.873120	0.561050	0.920951
LSTM	1.447883	1.203280	0.862361	0.849866
ARIMA	8.103503	2.846665	2.253644	0.159728

1 Mart–25 Mayıs 2024 dönemine ait 1 dakikalık rüzgâr şiddeti tahminleri incelendiğinde, üç modelin performans düzeyleri arasında belirgin farklılıklar ortaya çıkmıştır. Şekil 4.32 ve Şekil 4.33 incelendiğinde, ANN ve LSTM modellerinin hem düşük frekanslı dalgalanmalara hem de ani hız değişimlerine yüksek uyum sağladığı, özellikle de şiddetin arttığı 23 Mayıs ve 24 Mayıs öğle saatlerinde gerçek seriyle neredeyse çakışan tahminler ürettiği görülmektedir. Buna karşılık ARIMA modelinin tahmin eğrisi (Şekil 4.31), yüksek varyanslı yapıyı temsil etmekte açıkça yetersiz kalmış; rüzgâr şiddetindeki ani artışları düzleştirerek gerçek değerlerin oldukça altında tahminler üretmiştir. Çizelge 4.14 sonuçları bu gözlemi desteklemekte olup, ANN modelinin en düşük hata değerlerini ürettiği ve en yüksek R^2 katsayısına ulaştığı; LSTM’nin ise kabul edilebilir ancak daha zayıf bir doğruluk sergilediği görülmektedir. ARIMA modeli ise hem mutlak hata ölçütlerinde hem de determinasyon katsayısında diğer modellerin belirgin biçimde gerisinde kalmıştır. Bu bulgular, incelenen dönemde yapay sinir ağı tabanlı modellerin değişken atmosferik koşulları temsil etmede daha etkin olduğunu ortaya koymaktadır.


4.2.3.2 5 Dakikalık zaman çözünürlüğü sonuçları



Şekil 4.34: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil 4.35: ANN modeli tahmin-gözlem karşılaştırması.




Şekil 4.36: LSTM modeli tahmin-gözlem karşılaştırması.

Çizelge 4.15: 23–25 Mayıs 2024 (5 dakika) – model karşılaştırması.


Model	MSE	RMSE	MAE	R^2
ANN	1.395318	1.181236	0.878041	0.845235
LSTM	2.054247	1.433265	1.058850	0.772148
ARIMA	7.478348	2.734657	2.145690	0.170522

23–25 Mayıs 2024 dönemine ait 5 dakikalık rüzgâr şiddeti tahmin sonuçları incelendiğinde, Şekil 4.34, Şekil 4.35 ve Şekil 4.36 modellerin gözlem serisiyle karşılaştırmalı davranışını ortaya koymaktadır. Çizelge 4.15’te sunulan hata metrikleri, bu dönemde ANN modelinin diğer yöntemlere göre daha tutarlı ve düşük hatalı tahminler ürettiğini göstermektedir. ANN çıktıları, kısa süreli hız değişimlerini ve ani artış–azalış fazlarını gerçeğe oldukça yakın şekilde izleyebilmiş, bu da modelin yüksek zaman çözünürlüğüne etkili biçimde uyum sağladığını göstermektedir. LSTM modeli genel eğilimleri başarıyla yansıtmaya rağmen, özellikle keskin piklerde ANN kadar duyarlı davranamamış ve bazı lokal maksimumları belirgin biçimde yumuşatmıştır. Yine de Çizelge 4.15’teki görece düşük hata değerleri, modelin orta ölçekli varyasyonları temsil etmede yeterli performans sunduğunu göstermektedir. Buna karşılık ARIMA modeli, 5 dakikalık çözünürlükte rüzgâr şiddetinin yüksek değişkenlik içeren yapısına uyum sağlamakta zorlanmış; tahmin eğrisi aşırı düzleşmiş ve gözlem serisinin genlik davranışını yakalayamamıştır. Hem MSE ve RMSE değerlerinin yüksek olması hem de negatif eğimli R^2 katsayısı, bu modelin dönem içerisindeki doğruluk düzeyinin sınırlı kaldığını açıkça ortaya koymaktadır. Genel olarak değerlendirildiğinde, 23–25 Mayıs 2024 süresince ANN modeli 5 dakikalık zaman çözünürlüğünde en başarılı performansı sergilemiş, LSTM kabul edilebilir fakat ikinci düzeyde bir doğruluk sunmuş; ARIMA ise rüzgâr şiddetindeki hızlı dalgalanmaları temsil etmekte yetersiz kalmıştır.


4.2.3.3 10 Dakikalık zaman çözünürlüğü sonuçları



Şekil 4.37: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil 4.38: ANN modeli tahmin-gözlem karşılaştırması.




Şekil 4.39: LSTM modeli tahmin-gözlem karşılaştırması.

Çizelge 4.16: 23–25 Mayıs 2024 (10 dakika) – model karşılaştırması.


Model	MSE	RMSE	MAE	R^2
ANN	1.499826	1.224674	0.916454	0.826998
LSTM	3.296858	1.815725	1.240999	0.619715
ARIMA	8.274803	2.876596	2.079541	0.045520

23–25 Mayıs 2024 dönemine ait 10 dakikalık çözünürlük analizinde, modellerin davranışı belirgin biçimde ayrılmaktadır. Şekillerde de (Şekil 4.37–4.39), görüldüğü üzere ANN modeli, özellikle ani hızlanmalar ve gün içi geçişlerde gerçek zaman serisinin yapısını yüksek doğrulukla yakalamış; hem tepe değerleri hem de çukur noktaları başarılı biçimde takip etmiştir. Bu durum Çizelge 4.16’da da görüldüğü gibi ANN’in MSE, RMSE ve MAE metriklerinde diğer yaklaşımlara göre daha düşük hata üretmesi ve R^2 değerinde yaklaşık 0.83 gibi yüksek bir uyum sağlamasıyla da desteklenmektedir. LSTM modeli, zaman bağımlılığını yakalamada tutarlı olsa da, özellikle pik rüzgâr şiddetlerinde ANN’e göre daha yumuşak tepki vermiş ve genlikleri bir miktar bastırmıştır. Buna rağmen genel eğilimi doğru takip etmiş, hataları ANN’den yüksek olsa da kabul edilebilir bir performans sergilemiştir. ARIMA modeli ise hem ani değişimleri temsil etmekte zorlanmış hem de rüzgâr şiddetinin kısa süreli dalgalanmalarına tepki veremediği için tahmin eğrisi ciddi ölçüde düzleşmiştir. Bu nedenle hem hata metrikleri diğer modellere kıyasla belirgin biçimde yüksek kalmış, hem de R^2 değeri yaklaşık 0.05 seviyesinde oldukça zayıf bir ilişkinin varlığına işaret etmiştir. Genel olarak, bu zaman aralığında ANN modeli kısa vadeli rüzgâr şiddetinin dinamik yapısını en iyi temsil eden yöntem olurken, LSTM makul bir ikinci alternatif sunmuş; ARIMA ise yüksek frekanslı değişimleri yakalamakta yetersiz kalmıştır.


4.2.3.4 30 Dakikalık zaman çözünürlüğü sonuçları



Şekil 4.40: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil 4.41: ANN modeli tahmin-gözlem karşılaştırması.




Şekil 4.42: LSTM modeli tahmin-gözlem karşılaştırması.

Çizelge 4.17: 23–25 Mayıs 2024 (30 dakika) – model karşılaştırması.


Model	MSE	RMSE	MAE	R ²	n
ANN	2.595575	1.611079	1.104754	0.676469	121
LSTM	4.468926	2.113984	1.459289	0.442962	121
ARIMA	7.704506	2.775699	2.020531	0.039656	121

23–25 Mayıs 2024 dönemine ait 30 dakikalık rüzgâr şiddeti tahminleri ve Şekil 4.40–4.42 incelendiğinde, yapay sinir ağı (ANN) modelinin hem genliği hem de zamanlamayı diğer yöntemlere göre daha tutarlı biçimde yakaladığı Çizelge 4.17’de görülmektedir. ANN özellikle ani hız artışlarının yaşandığı zaman aralıklarında gözlem serisine yakın değerler üretmiş ve hata metrikleri açısından en düşük MSE, RMSE ve MAE değerlerine ulaşmıştır. LSTM modeli genel eğilimi doğru şekilde izlese de, pik değerleri bastırma eğilimi göstermiş ve ANN’in gerisinde kalmıştır. ARIMA modeli ise düşük varyanslı ve yumuşatılmış bir tahmin yapısı nedeniyle gerçek rüzgâr değişimlerini temsil etmekte yetersiz kalmış, bu durum özellikle negatif eğilimli R² değeri ile de doğrulanmıştır. Bu sonuçlar, 30 dakikalık çözünürlükte veri odaklı yapay sinir ağı mimarisinin kısa vadeli dalgalanmaları en iyi yakalayan yöntem olduğunu göstermektedir.


4.2.3.5 60 Dakikalık zaman çözünürlüğü sonuçları



Şekil 4.43: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil 4.44: ANN modeli tahmin-gözlem karşılaştırması.



Şekil 4.45: LSTM modeli tahmin-gözlem karşılaştırması.

Çizelge 4.18: 23–25 Mayıs 2024 (60 dakika) – model karşılaştırması.


Model	MSE	RMSE	MAE	R ²
ANN	4.107759	2.026761	1.387953	0.468149
LSTM	4.652387	2.156939	1.577718	0.397634
ARIMA	7.311286	2.703939	1.918564	0.053374

60 dakikalık çözünürlükte elde edilen sonuçlar, veri seyrekliğinin artmasına bağlı olarak tüm modellerin performansında belirgin bir zayıflama olduğunu Şekil 4.43–4.45 ve Çizelge 4.18’de göstermektedir. ANN modeli, MSE ve MAE açısından en düşük hata değerlerini ($MSE = 4.10$, $MAE = 1.38$) üretmiş ve bu nedenle diğer yöntemlere kıyasla daha istikrarlı bir yapı sergilemiştir. LSTM modeli, eğilim değişimlerini kısmen yakalayabilse de özellikle keskin hız artışlarında gecikmeli tepki verdiğiinden hata metriklerinde ANN’nin gerisinde kalmıştır. ARIMA modeli ise doğrusal yapısının bir sonucu olarak hem genliği hem de kısa süreli dalgalanmaları temsil etmede


yetersiz kalmış; düşük R^2 değeri (0.05) bu uyumsuzluğu açıkça ortaya koymuştur. Genel olarak, saatlik veride ANN yaklaşımı görece olarak en güvenilir tahmin performansını sergilerken, LSTM'nin başarısı çözünürlük düştükçe zayıflamış ve ARIMA'nın karmaşık rüzgâr yapısını temsil etme kapasitesi oldukça sınırlı kalmıştır.

4.2.4 1 Eylül-15 Aralık 2024 tarihine ait sonuçlar


4.2.4.1 1 Dakikalık zaman çözünürlüğü sonuçları



Şekil 4.46: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil 4.47: ANN modeli tahmin-gözlem karşılaştırması.




Şekil 4.48: LSTM modeli tahmin-gözlem karşılaştırması.

Çizelge 4.19: 13–15 Aralık 2024 (1 dakika) – model karşılaştırması.


Model	MSE	RMSE	MAE	R^2
ANN	0.490995	0.700710	0.459386	0.890676
LSTM	1.036107	1.017893	0.719477	0.769302
ARIMA	7.073642	2.659632	2.214078	-0.575004

13–15 Aralık 2024 dönemine ait 1 dakikalık rüzgâr şiddetinin tahmin sonuçları Şekil 4.46–4.48’de incelendiğinde, yapay sinir ağı (ANN) modelinin hem hata büyüklükleri hem de korelasyon açısından diğer yaklaşımlara göre belirgin biçimde daha başarılı olduğu görülmektedir. ANN modelinin düşük MSE (0.49) ve MAE (0.46) değerleri ile yüksek R^2 katsayısı ($R^2 = 0.89$), hızlı değişen rüzgâr örüntülerini etkili bir şekilde yakaladığını Çizelge 4.19’da göstermektedir. LSTM modeli kısa süreli dalgalanmaları ANN kadar iyi temsil edemese de, $R^2 = 0.77$ değeri ve orta düzey hataları ile makul bir performans sergilemiştir. Özellikle yerel maksimum ve minimumlara verdiği tepkinin ANN’e kıyasla daha yumuşak olması, ani değişimlerin takibinde sınırlılığa işaret etmektedir. ARIMA modeli ise durağan süreç varsayımına daha bağımlı olduğu için bu dönemdeki yüksek frekanslı değişimi temsil edememiş, tahmin eğrisi gerçek serinin oldukça gerisinde kalmıştır. Yüksek MSE (7.07) ve negatif R^2 değeri, modelin açıklayıcılığının zayıf olduğunu ortaya koymaktadır. Genel olarak değerlendirildiğinde, bu zaman aralığında en iyi performansı gösteren yöntem ANN olurken, LSTM daha ılımlı fakat kabul edilebilir bir doğruluk sağlamış; ARIMA ise kısa aralıklı ve düzensiz rüzgâr paternlerini temsil etmede yetersiz kalmıştır.


4.2.4.2 5 Dakikalık zaman çözünürlüğü sonuçları



Şekil 4.49: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil 4.50: ANN modeli tahmin-gözlem karşılaştırması.




Şekil 4.51: LSTM modeli tahmin-gözlem karşılaştırması.

Çizelge 4.20: 13–15 Aralık 2024 (5 dakika) – model karşılaştırması.


Model	MSE	RMSE	MAE	R ²
ANN	1.059166	1.029158	0.801518	0.738884
LSTM	1.658612	1.287871	0.994064	0.591102
ARIMA	5.087898	2.255637	1.798064	-0.254320

13–15 Aralık 2024 dönemine ait 5 dakikalık rüzgâr serilerinde, yapay sinir ağlarının (ANN) diğer modellere kıyasla daha tutarlı bir performans sergilediği görülmüştür. ANN tahminleri, hem zamansal dalgalanımları hem de kısa süreli rüzgâr şiddetinin değişimlerini başarıyla yakalayarak düşük hata değerleri ($MSE = 1.059$, $RMSE = 1.029$, $MAE = 0.802$) ve yüksek doğruluk katsayısı ($R^2 = 0.739$) sağlamıştır. LSTM modeli, ANN'e göre daha yüksek hata değerlerine sahip olsa da ($MSE = 1.659$, $RMSE = 1.288$) özellikle hızlı değişim dönemlerinde gözlenen tepki yeteneği sayesinde makul bir tahmin doğruluğu sunmuştur. Buna karşın ARIMA modeli, doğrusal yapısı nedeniyle yüksek frekanslı varyasyonu temsil edememiş; hem hata metriklerinde belirgin artış ($MSE = 5.088$, $RMSE = 2.256$) hem de negatif R^2 değeri ile bu periyotta yetersiz kalmıştır. Bu bulgular, kısa vadeli ve yüksek değişkenlik içeren rüzgâr serileri için veri odaklı derin öğrenme yaklaşımlarının daha uygun olduğunu Şekil 4.49–4.51 ve Çizelge 4.20'de göstermektedir.


4.2.4.3 10 Dakikalık zaman çözünürlüğü sonuçları



Şekil 4.52: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil 4.53: ANN modeli tahmin-gözlem karşılaştırması.




Şekil 4.54: LSTM modeli tahmin-gözlem karşılaştırması.

Çizelge 4.21: 13–15 Aralık 2024 (10 dakika) – model karşılaştırması.


Model	MSE	RMSE	MAE	R^2
ANN	1.173578	1.083318	0.845066	0.688119
LSTM	1.889721	1.374671	1.087393	0.497802
ARIMA	5.204566	2.281352	1.779033	-0.383126

13–15 Aralık 2024 dönemine ait 10 dakikalık rüzgâr şiddetleri üzerinde yapılan model karşılaştırması, yapay sinir ağlarının (ANN) bu zaman çözünürlüğünde en başarılı yaklaşım olduğunu şekillerde (Şekil 4.52–4.54) ve Çizelge 4.21’de göstermiştir. ANN modeli, hem düşük hata değerleri ($MSE = 1.174$, $RMSE = 1.083$, $MAE = 0.845$) hem de yüksek doğruluk katsayısı $R^2 = 0.688$ ile gözlenen değişimleri tutarlı biçimde temsil etmiştir. LSTM modeli, ani hız artışlarına verdiği göreceli daha iyi tepkiye rağmen ANN’e kıyasla daha yüksek hata değerleri üretmiş ($MSE = 1.890$, $RMSE = 1.375$) ve orta düzeyde bir $R^2 = 0.498$ değerine sahiptir. ARIMA ise doğrusal varsayımlarının sınırlılığı nedeniyle hem hızlı varyasyonları hem de ani rüzgâr değişimlerini yakalayamamış; yüksek hata metrikleri ($MSE = 5.205$, $RMSE = 2.281$) ve negatif R^2 değeri ile bu periyotta en zayıf performansı sergilemiştir. Sonuç olarak, 10 dakikalık çözünürlükte rüzgâr şiddetinin ayrıntılı dinamiklerini yakalayabilmek için veri odaklı yapay öğrenme modellerinin açık bir üstünlük sunduğu görülmektedir.


4.2.4.4 30 Dakikalık zaman çözünürlüğü sonuçları



Şekil 4.55: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil 4.56: ANN modeli tahmin-gözlem karşılaştırması.




Şekil 4.57: LSTM modeli tahmin-gözlem karşılaştırması.

Çizelge 4.22: 13–15 Aralık 2024 (30 dakika) – model karşılaştırması.


Model	MSE	RMSE	MAE	R^2
ANN	1.422243	1.192578	0.904195	0.554864
LSTM	2.445699	1.563873	1.269903	0.234541
ARIMA	4.704676	2.169026	1.679152	-0.472478

30 dakikalık zaman çözünürlüğünde elde edilen bulgular, yapay sinir ağı (ANN) modelinin diğer iki modele göre daha yüksek tahmin performansı sergilediğini Şekil 4.55–4.57 ve Çizelge 4.22’de göstermektedir. ANN modeli, $MSE=1.422$, $RMSE=1.192$ ve $MAE=0.904$ değerleri ile hem hata metriklerinde en düşük değerlere ulaşmış hem de $R^2 = 0.554$ ile açıklanan varyans oranında en başarılı sonuçları vermiştir. LSTM modeli, ANN’e kıyasla daha yüksek hata değerleri üretmiş ($MSE=2.446$, $MAE=1.270$) ve orta düzeyde bir ilişki yakalamıştır ($R^2 = 0.235$). ARIMA modeli ise doğrusal yapısı gereği yüksek frekanslı değişimleri temsil etmekte yetersiz kalmış, hata metrikleri belirgin biçimde daha yüksek gerçekleşmiş ($MSE=4.705$, $RMSE=2.169$) ve negatif R^2 değeri (-0.472) modelin varyansı açıklamada başarısız olduğunu ortaya koymuştur. Bu sonuçlar, kısa vadeli rüzgâr şiddetindeki hızlı dalgalanmaların modellenmesinde veri odaklı yapay sinir ağı tabanlı yöntemlerin üstün performans gösterdiğini doğrulamaktadır.


4.2.4.5 60 Dakikalık zaman çözünürlüğü sonuçları



Şekil 4.58: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil 4.59: ANN modeli tahmin-gözlem karşılaştırması.



Şekil 4.60: LSTM modeli tahmin-gözlem karşılaştırması.

Çizelge 4.23: 13–15 Aralık 2024 (60 dakika) – model karşılaştırması.


Model	MSE	RMSE	MAE	R^2
ANN	1.627174	1.275607	1.055354	0.436299
LSTM	4.111302	2.027635	1.586140	-0.424275
ARIMA	4.819363	2.195305	1.749173	-0.669568

Şekil 4.58, Şekil 4.59, ve Şekil 4.60 incelendiğinde, 60 dakikalık çözünürlükte en iyi tahmin performansını Yapay Sinir Ağı (ANN) modelinin sağladığı görülmektedir. Çizelge 4.23’te sunulan hata metriklerine göre ANN modeli ($MSE = 1.627$, $RMSE = 1.276$, $MAE = 1.055$, $R^2 = 0.436$) ile hem hata değerlerini düşük tutmuş hem de gözlenen rüzgâr şiddetindeki değişimleri LSTM ve ARIMA’ya göre daha başarılı şekilde yakalamıştır. LSTM modeli orta düzeyde bir performans sergilemiş olup ($MSE = 4.111$, $MAE = 1.586$, $R^2 = -0.424$) özellikle ani rüzgâr değişimlerini yumuşatma eğilimindedir. ARIMA modeli ise doğrusal yapısı gereği rüzgâr şiddetindeki yüksek


frekanslı dalgalanmalara uyum sağlayamamış ve negatif determinasyon katsayısı ($R^2 = -0.669$) ile bu zaman çözünürlüğünde en zayıf performansı göstermiştir. Bu sonuçlar, 60 dakikalık örnekleme aralığında doğrusal olmayan yöntemlerin belirgin şekilde üstünlük sağladığını ortaya koymaktadır.

4.2.5 1 Mart-3 Mayıs 2025 tarihine ait sonuçlar


4.2.5.1 1 Dakikalık zaman çözünürlüğü sonuçları



Şekil 4.61: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil 4.62: ANN modeli tahmin-gözlem karşılaştırması.




Şekil 4.63: LSTM modeli tahmin-gözlem karşılaştırması.

Çizelge 4.24: 1–3 Mayıs 2025 (1 dakika) – model karşılaştırması.


Model	MSE	RMSE	MAE	R ²
ANN	0.697408	0.835110	0.535445	0.912377
LSTM	1.469458	1.212212	0.839932	0.815375
ARIMA	8.923858	2.987283	2.450219	-0.121207

1–3 Mayıs 2025 dönemine ait 1 dakikalık çözünürlükteki rüzgâr şiddeti tahmin sonuçları incelendiğinde, yapay sinir ağı (ANN) modelinin tüm metriklerde en başarılı performansı sergilediği görülmektedir. ANN modeli, MSE=0.6974, RMSE=0.8351 ve MAE=0.5354 değerleri ile hem hatayı en düşük seviyede tutmuş hem de R²=0.9123 ile gerçek değişkenliği en yüksek doğrulukla yakalamıştır. LSTM modeli ANN’e kıyasla daha yüksek hata değerlerine sahip olsa da (MSE=1.4695, RMSE=1.2122, MAE=0.8399), R²=0.8154 ile kısa ölçekli dalgalanmaları büyük ölçüde temsil edebilmiştir. Buna karşılık ARIMA modelinin hem MSE (8.9239) hem RMSE (2.9873) hem de negatif R² değeri (-0.1212) ile bu dönemde zayıf bir performans sergilediği, özellikle hızlı değişim gösteren ani rüzgâr artışlarını yakalayamadığı görülmektedir. Bu sonuçlar, yüksek zaman çözünürlüğünde doğrusal olmayan yapıları yakalayabilen veri odaklı derin öğrenme modellerinin, özellikle ANN mimarisinin, klasik istatistiksel modellere göre belirgin üstünlük sağladığını Şekil 4.61–4.63 ve Çizelge 4.24’te ortaya koymaktadır.


4.2.5.2 5 Dakikalık zaman çözünürlüğü sonuçları



Şekil 4.64: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil 4.65: ANN modeli tahmin-gözlem karşılaştırması.




Şekil 4.66: LSTM modeli tahmin-gözlem karşılaştırması.

Çizelge 4.25: 1–3 Mayıs 2025 (5 dakika) – model karşılaştırması.


Model	MSE	RMSE	MAE	R ²
ANN	3.048749	1.746067	1.184220	0.583280
LSTM	3.231430	1.797618	1.198125	0.558311
ARIMA	7.109153	2.666300	2.063618	0.028282

Şekil 4.64, Şekil 4.65 ve Şekil 4.66’da 1–3 Mayıs 2025 dönemine ait 5 dakikalık çözünürlükte ARIMA, ANN ve LSTM modellerinin gerçek rüzgâr şiddeti ile tahmin değerleri karşılaştırılmaktadır. Şekillerden görüldüğü üzere hem ANN hem de LSTM modelleri ani dalgalanmalar ve kısa süreli pik değerlere yüksek duyarlılık gösterirken, ARIMA modelinin zaman serisi yapısı nedeniyle sinyali aşırı düzleştirdiği ve özellikle hızlı değişim dönemlerini yakalayamadığı açıkça görülmektedir. Çizelge 4.25’te verilen performans metrikleri bu gözlemleri nicel olarak doğrulamaktadır. ANN modeli, MSE=3.05, RMSE=1.75 ve MAE=1.18 değerleri ile en düşük hata performansını göstermiş ve R²=0.583 ile açıklanan varyans oranında LSTM modeline göre daha başarılı olmuştur. LSTM modelinin R² değerinin 0.558 olması, bu modelin de kısa vadeli dalgalanmaları başarılı biçimde yakaladığını göstermektedir. Her iki derin öğrenme modelinin ARIMA’ya kıyasla açık üstünlüğü, ARIMA’nın yüksek hata değerleri (MSE=7.11, RMSE=2.67, MAE=2.06) ve oldukça düşük R² değeri (0.028) ile belirgin hâle gelmektedir. Sonuç olarak, 5 dakikalık zaman çözünürlüğünde ANN ve LSTM modellerinin hem trend hem de yerel varyasyonları yakalama kapasitesinin yüksek olduğu; ARIMA modelinin ise yüksek frekanslı ve hızlı değişen rüzgâr örüntülerinde yetersiz kaldığı doğrulanmıştır.


4.2.5.3 10 Dakikalık zaman çözünürlüğü sonuçları



Şekil 4.67: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil 4.68: ANN modeli tahmin-gözlem karşılaştırması.




Şekil 4.69: LSTM modeli tahmin-gözlem karşılaştırması.

Çizelge 4.26: 1–3 Mayıs 2025 (10 dakika) – model karşılaştırması.


Model	MSE	RMSE	MAE	R ²
LSTM	3.790559	1.946936	1.312150	0.438317
ANN	4.143243	2.035496	1.330621	0.386057
ARIMA	7.210186	2.685179	1.972536	-0.068401

1–3 Mayıs 2025 dönemine ait 10 dakikalık çözünürlükte gerçekleştirilen model karşılaştırması, Şekil 4.67, Şekil 4.68 ve Şekil 4.69’da sunulmaktadır. Bu sonuçlar, LSTM modelinin hem hata metrikleri hem de zaman serisi yapısının izlenmesinde diğer yöntemlere kıyasla daha istikrarlı bir performans sergilediğini Çizelge 4.26’da da göstermektedir. Özellikle LSTM’in RMSE ve MAE değerlerinin ANN’e göre daha düşük olması, modelin kısa vadeli dinamik değişimleri daha başarılı şekilde yakalayabildiğini ortaya koymaktadır. ANN modeli genel eğilimleri takip etmede yeterli görünse de, pik rüzgâr şiddetindeki yer yer gecikmeli tepki vermektedir. ARIMA ise rüzgâr şiddetindeki ani değişimleri temsil etmekte yetersiz kalmış; doğrusal yapısı nedeniyle hem R² değerlerinin düşük kaldığı hem de zaman serisi grafiklerinde gözle görülür bir düzleştirme etkisi yarattığı gözlenmiştir. Bu bulgular, 10 dakikalık zaman çözünürlüğünde veri odaklı derin öğrenme modellerinin kısa vadeli rüzgâr tahmini için daha uygun olduğunu doğrulamaktadır.


4.2.5.4 30 Dakikalık zaman çözünürlüğü sonuçları



Şekil 4.70: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil 4.71: ANN modeli tahmin-gözlem karşılaştırması.



Şekil 4.72: LSTM modeli tahmin-gözlem karşılaştırması.


Çizelge 4.27: 1–3 Mayıs 2025 (30 dakika) – model karşılaştırması.

Model	MSE	RMSE	MAE	R^2
LSTM	3.911741	1.977812	1.452458	0.330376
ANN	4.586247	2.141553	1.565269	0.214912
ARIMA	6.426904	2.535134	1.895809	-0.100177


Şekil 4.70, Şekil 4.71, ve Şekil 4.72 incelendiğinde, 1–3 Mayıs 2025 döneminde 30 dakikalık zaman çözünürlüğünde tüm modellerin rüzgâr şiddetindeki genel eğilimleri yakalayabildiği, ancak doğruluk seviyelerinin belirgin biçimde farklılaştığı görülmektedir. Çizelge 4.27 sonuçlarına göre LSTM modeli ($MSE = 3.91$, $RMSE = 1.97$, $MAE = 1.45$, $R^2 = 0.330$) bu zaman çözünürlüğünde en iyi performansı sergilemiş ve özellikle geçiş dönemlerinde gerçek gözlemleri daha tutarlı takip etmiştir. ANN modeli ($MSE = 4.58$, $RMSE = 2.14$, $MAE = 1.56$, $R^2 = 0.215$) LSTM'ye göre daha yüksek hata değerlerine sahip olmakla birlikte, genel varyasyonları tatmin

edici düzeyde temsil edebilmiştir. ARIMA modeli ise ($MSE = 6.42$, $RMSE = 2.53$, $MAE = 1.89$, $R^2 = -0.100$) rüzgâr şiddetindeki hızlı değişimleri yakalamada yetersiz kalmış; tahminlerinin düşük frekanslı, aşırı düzleştirilmiş bir yapıda kaldığı Şekil 4.70’te açıkça görülmektedir. Bu bulgular, 30 dakikalık çözünürlükte doğrusal olmayan öğrenme kapasitesine sahip derin öğrenme modellerinin özellikle kısa süreli dalgalanmaların temsilde daha başarılı olduğunu göstermektedir.


4.2.5.5 60 Dakikalık zaman çözünürlüğü sonuçları



Şekil 4.73: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil 4.74: ANN modeli tahmin-gözlem karşılaştırması.



Şekil 4.75: LSTM modeli tahmin-gözlem karşılaştırması.

Çizelge 4.28: 1–3 Mayıs 2025 (60 dakika) – model karşılaştırması.

Model	MSE	RMSE	MAE	R^2
ANN	2.401594	1.549708	1.154722	0.497221
LSTM	3.195743	1.787664	1.398515	0.330965
ARIMA	5.482850	2.341549	1.797289	-0.147845

Şekil 4.73, Şekil 4.74, ve Şekil 4.75’te, 1–3 Mayıs 2025 dönemine ait 60 dakikalık rüzgâr şiddeti tahminlerinin modeller arasında belirgin farklılıklar gösterdiği görülmektedir. ANN ve LSTM modelleri, özellikle düşük ve orta şiddetteki rüzgâr değişimlerinde gözlenen zamansal eğilimleri başarıyla yakalayarak gerçek seri ile yüksek derecede uyum sağlamıştır. Buna karşılık ARIMA modelinin tahmin eğrisi, özellikle ani hız değişimlerinin yaşandığı saatlerde gerçek rüzgâr şiddetindeki dalgalanmaları temsil etmekte yetersiz kalmıştır. Model performans metriklerinin karşılaştırıldığı Şekil 4.74’den de görülebileceği üzere, ANN modeli en düşük hata değerlerine ($MSE = 2.40$, $RMSE = 1.55$, $MAE = 1.15$) ve en yüksek doğruluk katsayısına ($R^2 = 0.497$) ulaşarak 60 dakikalık tahminlerde en başarılı model olmuştur. LSTM modeli ikinci sırada yer alırken, ARIMA modeli hem hata büyüklükleri hem de negatif R^2 değeri ile bu zaman çözünürlüğünde zayıf performans sergilediği Çizelge 4.28’de de görülmektedir..

Bu grafiksel değerlendirmeler, rüzgâr enerjisinin enerji sistemi içerisindeki konumunun yalnızca kapasite ve üretim büyüklükleri üzerinden değil, aynı zamanda sistemsel işleyiş, denge mekanizmaları ve planlama süreçleri üzerinden birlikte ele alınması gerektiğini ortaya koymaktadır. Kurulu güç ve üretim dağılımlarının

birlikte değerlendirilmesi, rüzgâr enerjisinin enerji sisteminde statik bir kaynak değil, dinamik bir üretim bileşeni olarak konumlandığını göstermektedir. Bu bağlamda, rüzgâr enerjisinin sistem içindeki rolünün doğru biçimde anlaşılabilmesi, yalnızca mevcut üretim verilerinin incelenmesiyle değil; üretimi belirleyen temel meteorolojik parametrelerin, özellikle rüzgâr şiddetinin öngörülebilirliği üzerinden değerlendirilmesiyle mümkün hâle gelmektedir. Dolayısıyla grafiksel bulgulardan hareketle yapılan bu sistemsel değerlendirme, çalışmanın rüzgâr tahmini boyutuna geçiş için doğal bir zemin oluşturmaktadır.

Rüzgâr şiddetinin kısa vadeli ve yüksek doğrulukla tahmin edilmesi, doğrudan üretilen elektrik enerjisi miktarını ve buna bağlı ekonomik çıktıyı etkileyen temel bir parametre olarak değerlendirilmektedir. Rüzgâr şiddetindeki küçük ölçekli değişimlerin dahi türbin güç eğrisi üzerinden enerji üretimine doğrusal olmayan biçimde yansımaları, tahmin hatalarının üretim planlaması, sistem dengesi ve ekonomik performans üzerinde çarpan etkisi oluşturmalarına neden olmaktadır. Bu bağlamda rüzgâr tahmin doğruluğundaki her iyileşme, yalnızca teknik üretim performansını değil, aynı zamanda piyasa katılımı, gelir öngörülebilirliği, dengesizlik maliyetleri ve işletme kârlılığı üzerinde doğrudan etkiler üretmektedir. Üretilen enerji miktarının daha isabetli öngörülmesi, üretim-tüketim dengesinin daha etkin yönetilmesine olanak sağlarken, aynı zamanda enerji piyasalarında oluşabilecek sapmaların ekonomik karşılığını azaltmakta ve sistem işletmecileri ile üretim şirketleri açısından finansal belirsizlikleri minimize etmektedir. Bu yönüyle rüzgâr şiddeti tahmini, yalnızca meteorolojik bir problem alanı değil; enerji üretimi, sistem işletimi ve ekonomik sürdürülebilirlik arasında köprü kuran bütüncül bir yapısal bileşen olarak değerlendirilmektedir.



5. ÖNERİLER

Bu çalışma kapsamında elde edilen bulgular doğrultusunda, kısa vadeli rüzgâr tahmin modellerinin yalnızca akademik modelleme çalışmaları olarak değil, enerji sistemlerinin planlama ve işletme süreçlerini destekleyebilecek bilimsel altyapılar olarak değerlendirilmesi önerilmektedir. Gelecek çalışmalarda, meteorolojik değişkenlerin yanı sıra şebeke yük verileri, üretim geçmişi, bakım kayıtları ve piyasa göstergeleri gibi çoklu veri kaynaklarının bütünleşik biçimde kullanılması, tahmin modellerinin daha kapsamlı ve temsil gücü yüksek yapılar hâline gelmesine katkı sağlayacaktır.

Modelleme perspektifinden bakıldığında bu tezin temel amacı, operasyonel rüzgâr tahmininde farklı zaman çözünürlüklerinde (1, 5, 10, 30 ve 60 dakika) istatistiksel ve derin öğrenme tabanlı modellerin performanslarını karşılaştırmalı olarak incelemek ve yüksek zamansal çözünürlüklü meteorolojik verilerle kısa vadeli rüzgâr tahmininin doğruluğunu artırmaktır. Bu kapsamda, ARIMA, ANN ve LSTM modelleri Batman Havalimanı'na ait gözlemsel veriler kullanılarak geliştirilmiş, farklı girdi kombinasyonları altında test edilmiş rüzgâr enerjisi ve havacılık operasyonları açısından en uygun tahmin yaklaşımının belirlenmesi hedeflenmiştir.

Enerji sistemleri bağlamında, kısa vadeli rüzgâr tahmin çıktılarının üretim planlaması, sistem işletimi ve dengeleme süreçleriyle bütünleşik biçimde ele alınması, yenilenebilir enerji entegrasyonunun güvenli ve sürdürülebilir biçimde yönetilmesine katkı sağlayacaktır. Bu doğrultuda tahmin modellerinin, gerçek zamanlı izleme sistemleriyle birlikte değerlendirilmesi, sistem geçişlerinin daha öngörülebilir biçimde yönetilmesine olanak tanıyabilecek bir yaklaşım olarak öne çıkmaktadır.

Türkiye elektrik piyasası özelinde değerlendirildiğinde, EPIAŞ tarafından işletilen gün öncesi, gün içi ve dengeleme piyasalarının yapısı dikkate alındığında, üretim tahmin doğruluğunun artmasının piyasa istikrarını destekleyen yapısal bir unsur olduğu görülmektedir. Bu nedenle gelecekteki çalışmalarda, rüzgâr tahmin çıktılarının piyasa mekanizmalarıyla ilişkisini kavramsal ve yapısal düzeyde ele alan disiplinlerarası

arařtırmaların geliřtirilmesi, yenilenebilir enerji entegrasyonunun sistemsel boyutunun daha bütüncül biçimde anlaşılmasına katkı sağlayacaktır.

Bu çalışmada elde edilen bulgular, kısa vadeli rüzgâr tahmininde model performansının hem zaman çözünürlüğüne hem de atmosferik süreçlerin ölçeğine güçlü biçimde bağılı olduğunu ortaya koymaktadır. Özellikle 1 ve 5 dakikalık yüksek çözünürlüklü verilerde ANN ve LSTM modellerinin ARIMA modeline kıyasla daha düşük hata değerleri üretmesi, doğrusal olmayan ve yüksek frekanslı rüzgâr dalgalanmalarının veri tabanlı yaklaşımlar tarafından daha etkin biçimde temsil edilebildiğini göstermektedir. ANN'nin bu çalışmada öne çıkması, uygun gecikme (lag) yapılarının ve seçilen girdi kombinasyonlarının kısa süreli rüzgâr değişkenliğini yakalamada yeterli temsil gücü sağladığına işaret etmektedir. LSTM modeli ise kısa süreli bellek mekanizması sayesinde ani rüzgâr değişimlerini yakalamada başarılı bir model olmuştur. Zaman çözünürlüğü azaldıkça (10-30-60 dk) modeller arasındaki performans farkının belirgin bir şekilde azalması, daha uzun zaman ölçeklerinde rüzgâr serilerinin görece daha kararlı ve doğrusal bir yapıya yöneldiğine işaret etmektedir. Bu bağlamda, operasyonel uygulamalarda tek bir model yaklaşımı yerine zaman çözünürlüğüne ve hâkim meteorolojik koşullara duyarlı model seçimlerinin yapılması önerilmektedir. Ayrıca, özellikle konvektif aktivitenin ve ani rüzgâr şiddeti değişimlerinin beklendiği dönemlerde, veri tabanlı tahmin modellerinin sinoptik haritalar, SHT çıktıları ile radar ve uydu gözlemleriyle birlikte değerlendirilmesi, kısa vadeli rüzgâr tahminlerinin güvenilirliğini ve operasyonel karar destek süreçlerindeki etkinliğini artıracaktır. Bu çalışmaya akademik açıdan bakıldığında çalışmanın, yüksek çözünürlüklü zaman serileri üzerinde geliştirilen kısa vadeli rüzgâr tahmin modelleri için karşılaştırmalı bir bilimsel referans çerçevesi sunduğu değerlendirilmektedir. Gelecek arařtırmalarda, farklı coğrafi bölgelerde, farklı topoğrafik yapılarda ve farklı iklim koşullarında gerçekleştirilecek benzer çalışmalar, model genellenebilirliğinin test edilmesi açısından önemli katkılar sağlayacaktır.

KAYNAKLAR

- [1] **Holton, J.R. ve Hakim, G.J.** (2013). Academic Press, Boston, fifth edition sürüm, <https://www.sciencedirect.com/science/article/pii/B9780123848666000052>.
- [2] **Stull, R.B.** (1988). *An Introduction to Boundary Layer Meteorology*, cilt 13 of *Atmospheric and Oceanographic Sciences Library*, Kluwer Academic Publishers, Dordrecht.
- [3] **Gill, A.E.** (2016). *Atmosphere—ocean dynamics*, Elsevier.
- [4] **Linden, P.** (2004). Air-Sea Interaction. Laws and Mechanisms. By GT CSANADY. Cambridge University Press, 2001. 248 pp. ISBN 0 521 79259 2.£ 60 or 34.95 (paperback), *Journal of Fluid Mechanics*, 502, 374–374.
- [5] **Garratt, J.R.** (1994). The atmospheric boundary layer, *Earth-Science Reviews*, 37(1-2), 89–134.
- [6] **Lorenz, E.N.**, (2017). Deterministic Nonperiodic Flow, **D. Campbell**, (düzenleyen), *Universality in Chaos*, 2nd Edition, Routledge, s.367–378, reprint of the 1963 original paper in *Journal of the Atmospheric Sciences*.
- [7] **Bauer, P., Thorpe, A. ve Brunet, G.** (2015). The Quiet Revolution of Numerical Weather Prediction, *Nature*, 525(7567), 47–55.
- [8] **Belušić, D., Hrastnik, J., Večenaj, v. ve Grisogono, B.** (2013). Wind Regimes in Complex Terrain, *Boundary-Layer Meteorology*, 147, 515–538.
- [9] **Emeis, S.** (2018). *Wind Energy Meteorology: Atmospheric Physics for Wind Power Generation*, Springer.
- [10] **Skamarock, W.C., Klemp, J.B., Dudhia, J., Gill, D.O., Barker, D.M., Wang, W. ve Powers, J.G.** (2005). A Description of the Advanced Research WRF Version 2, **Teknik Rapor NCAR/TN-468+STR**, National Center for Atmospheric Research, Boulder, Colorado.
- [11] **Lynch, P.** (2006). *The Emergence of Numerical Weather Prediction: Richardson's Dream*, Cambridge University Press.
- [12] **Pope, S.B.** (2000). *Turbulent Flows*, Cambridge University Press, Cambridge, UK.
- [13] **Belušić, D., Grisogono, B., Bajić, A. ve Kraljević, L.** (2013). Wind Channeling in Complex Terrain, *Meteorological Applications*, 20(3), 336–345.

- [14] **Ackermann, T.** (2012). *Wind Power in Power Systems*, John Wiley & Sons.
- [15] **International Civil Aviation Organization (ICAO)** (2015). Wind Shear Manual, **Doc. 9817**, ICAO, Montreal, Canada.
- [16] **Panofsky, H.A. ve Dutton, J.A.** (1984). Atmospheric turbulence. Models and methods for engineering applications, *New York: Wiley*.
- [17] **Giebel, G., Brownsword, R., Kariniotakis, G., Denhard, M. ve Draxl, C.** (2011). The State-of-the-Art in Short-Term Prediction of Wind Power: A Literature Overview, **Teknik Rapor**, ANEMOS.plus Project, Risø DTU, Roskilde, Denmark, deliverable D1.2 of the ANEMOS.plus Project.
- [18] **Milligan, M.** (2007). Wind Forecasting Challenges, **Teknik Rapor** NREL/CP-500-42465, National Renewable Energy Laboratory (NREL), Golden, CO, USA, presented at the Utility Wind Integration Group (UWIG) Workshop, 2007.
- [19] **T.C. Enerji ve Tabii Kaynaklar Bakanlığı** (2023). Türkiye Ulusal Enerji Planı 2023–2035, **Teknik Rapor**, Enerji ve Tabii Kaynaklar Bakanlığı, Ankara, Turkey, official Report.
- [20] **Türkiye Rüzgâr Enerjisi Birliği (TÜREB)** (2025). *Türkiye Rüzgâr Enerjisi İstatistik Raporu 2024*, türkiye Rüzgâr Enerjisi İstatistik Raporu verilerinden derlenmiştir.
- [21] **Federal Aviation Administration (FAA)**, (2008). Wind Shear Training Aid, Washington, D.C., USA, technical Training Manual.
- [22] **Lin, Y.L.** (2012). Wind Profile Modeling for Aviation, *Journal of Applied Meteorology and Climatology*, 51(7), 1233–1247.
- [23] **Box, G.E.P., Jenkins, G.M., Reinsel, G.C. ve Ljung, G.M.** (2015). *Time Series Analysis: Forecasting and Control*, John Wiley & Sons.
- [24] **Alexiadis, M.C., Dokopoulos, P.S. ve Sahsamanoglou, H.S.** (1999). Wind Speed Forecasting via ARMA Models, *Wind Engineering*, 23(4), 267–276.
- [25] **Rosenblatt, F.** (1958). The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain, *Psychological Review*, 65(6), 386–408.
- [26] **Rumelhart, D.E., Hinton, G.E. ve Williams, R.J.** (1986). Learning Representations by Back-Propagating Errors, *Nature*, 323, 533–536.
- [27] **Kalogirou, S.A.** (1999). Applications of Artificial Neural Networks in Energy Systems, *Energy Conversion and Management*, 40(10), 1073–1087.
- [28] **Hochreiter, S. ve Schmidhuber, J.** (1997). Long Short-Term Memory, *Neural Computation*, 9(8), 1735–1780.

- [29] **Liu, H., Tian, J. ve Li, C.** (2018). Short-term Wind Speed Forecasting Using LSTM Networks, *Energy Conversion and Management*, 166, 386–395.
- [30] **Zhang, Y., Wang, J., Li, X., Zhao, Y. ve Liu, C.** (2022). A Hybrid CNN–GRU Model for Short-Term Wind Speed Forecasting, *Applied Energy*, 325, 119132.
- [31] **Li, X., Han, Z. ve Zhang, Q.** (2021). Post-Processing Numerical Weather Prediction Wind Forecasts Using Deep Learning, *Energy Reports*, 7, 262–274.
- [32] **Liu, H., Mi, X. ve Li, Y.** (2020). Adaptive LSTM Model for Wind Forecasting, *Energy Conversion and Management*, 210, 112726.
- [33] **Rasp, S. ve Thuerey, N.** (2021). Data-Driven Correction of Numerical Weather Prediction Model Errors Using Deep Learning, *Proceedings of the National Academy of Sciences (PNAS)*, 118(49), e2100766118.
- [34] **Ren, Z., Yu, Y., Teng, L. ve Li, X.** (2021). Short-term Wind Speed Forecasting Using a Hybrid GAN–LSTM Model, *Energy Conversion and Management*, 228, 113647.
- [35] **Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A.N., Kaiser, Ł. ve Polosukhin, I.** (2017). Attention Is All You Need, *Advances in Neural Information Processing Systems (NeurIPS)*, cilt 30.
- [36] **Li, Y., Yu, R., Shahabi, C. ve Liu, Y.** (2020). Spatiotemporal Forecasting Using Graph Neural Networks, *IEEE Transactions on Knowledge and Data Engineering (TKDE)*, 32(11), 2338–2350.
- [37] **Giebel, G.** (2011). *The state-of-the-art in short-term prediction of wind power: A literature overview.*
- [38] **Milligan, M., Holttinen, H., Hodge, B.M., Lew, D., Ortner, A., Pinson, P. ve Sillanpää, S.** (2015). Operating reserves and wind power integration: An international comparison, *Proceedings of the IEEE*, 103(2), 212–220.
- [39] **T.C. Enerji ve Tabii Kaynaklar Bakanlığı** (2022). *2023–2035 Ulusal Enerji Planı.*
- [40] **Türkiye Rüzgâr Enerjisi Birliği (TÜREB)** (2023). *Türkiye Rüzgâr Enerjisi İstatistik Raporu.*
- [41] **Manwell, J., McGowan, J. ve Rogers, A.** (2010). *Wind Energy Explained: Theory, Design and Application*, Wiley.
- [42] **Burton, T., Sharpe, D., Jenkins, N. ve Bossanyi, E.** (2011). *Wind Energy Handbook*, Wiley.
- [43] **Kundur, P.** (1994). *Power System Stability and Control*, McGraw-Hill.

- [44] **ENTSO-E** (2022). *Power System Flexibility and Balancing in High Renewable Energy Systems*.
- [45] **International Energy Agency (IEA)** (2023). *Renewables 2023 – Global Energy Transition Report*.
- [46] **Global Wind Energy Council (GWEC)** (2023). *Global Wind Report 2023*.
- [47] **Wang, H., Chen, X. ve Zhang, P.** (2022). Wind Speed Forecasting Using Improved Generative Adversarial Networks with LSTM, *Energy Conversion and Management*, 253, 115145.
- [48] **Li, H. ve Shi, J.** (2010). Short-term wind speed forecasting using artificial neural networks, *Renewable Energy*, 35(10), 2325–2332.
- [49] **Mohandes, M.A., Rehman, S. ve Halawani, T.O.** (1998). A Neural Networks Approach for Wind Speed Prediction, *Renewable Energy*, 13(3), 345–354.
- [50] **Mohandes, M. ve Rehman, S.** (2004). Short-term wind speed and power prediction using artificial neural networks, *Energy Conversion and Management*, 45(11-12), 1691–1702.
- [51] **Sfetsos, A.** (2000). A Comparison of Various Forecasting Techniques Applied to Mean Hourly Wind Speed Time Series, *Renewable Energy*, 21(1), 23–35.
- [52] **Ghiassi, M., Saidane, D.H. ve Zimbra, H.K.** (2005). A Dynamic Artificial Neural Network Model for Forecasting Short-Term Wind Speed Using 10-Minute Interval Data, *Energy Conversion and Management*, 46(17), 2589–2606.
- [53] **Cadenas, E. ve Rivera, W.** (2007). Short Term Wind Speed Forecasting in La Venta, Oaxaca, Mexico, Using Artificial Neural Networks, *Renewable Energy*, 32(12), 2078–2085.
- [54] **Nguyen, T.H., Phan, D.K. ve Nguyen, D.** (2017). Neural Network Models for Sub-Hourly Wind Speed Forecasting, *Applied Energy*, 190, 1245–1257.
- [55] **Oh, E.H., Yoon, J.Y. ve Lee, S.H.** (2013). Hourly Wind Power Forecasting Using Artificial Neural Networks, *Energy*, 49, 228–237.
- [56] **Zhou, H., Zhang, S., Peng, J., Zhang, S., Li, J., Xiong, H. ve Zhang, W.** (2021). Informer: Beyond Efficient Transformer for Long Sequence Time-Series Forecasting, *Proceedings of the AAAI Conference on Artificial Intelligence*, cilt 35, s.11106–11115.
- [57] **Li, Y., Yu, R., Shahabi, C. ve Liu, Y.** (2020). Graph Neural Network for Spatiotemporal Forecasting, *IEEE Transactions on Knowledge and Data Engineering*.
- [58] **Chow, F.K. ve Street, R.L.** (2003). Numerical Simulation of Turbulence over Complex Terrain, *Journal of the Atmospheric Sciences*, 60(7), 1610–1625.

EKLER

EK A: Modellerde Kullanılan Python Kodları

EK B: Modellerde Kullanılan Meteorolojik Değişkenlerin Çıktıları





EK A: Modellerde Kullanılan Python Kodları

Bu ek bölümünde, ARIMA, ANN ve LSTM modellerinin kurulumu, eğitim süreçleri ve tahmin adımlarında kullanılan Python kodları sunulmaktadır. Kodlar, her model için ayrı alt başlıklar altında düzenlenmiştir.

A.1 ARIMA Modelinde Kullanılan Python Kodları

Bu bölümde, çalışmada kullanılan ARIMA (Autoregressive Integrated Moving Average) modelinin Python ortamında uygulanmasına ilişkin tam kodlar ve kodun temel adımları açıklanmaktadır. Kod yapısı; kütüphanelerin yüklenmesi, model ayarları, yardımcı fonksiyonlar, veri hazırlama, parametre arama, performans değerlendirmesi, sonuçların kaydedilmesi ve grafik üretimi olmak üzere sekiz ana bölüm altında sunulmuştur.

A.1.1 Kütüphanelerin Yüklenmesi

```
1 import warnings
2 warnings.filterwarnings("ignore")
3
4 import numpy as np
5 import pandas as pd
6 import matplotlib.pyplot as plt
7 import statsmodels.api as sm
8 from statsmodels.tsa.statespace.sarimax import SARIMAX
9 from sklearn.metrics import mean_absolute_error, mean_squared_error,
10 r2_score
11 import matplotlib.dates as mdates
12 import locale
```

A.1.2 Model Ayarları ve Parametreler

```
1 INPUT_CSV = "2024_Eylul_Aralik13-15_60dk_BIRLESIK_IMPUTED.csv"
2 TARGET    = "WS2M"
3 RES_MIN   = 60
4
5 TRAIN_START = "2024-09-01 00:00:00"
6 TRAIN_END   = "2024-12-12 23:59:59"
7 TEST_START  = "2024-12-13 00:00:00"
8 TEST_END    = "2024-12-15 23:59:59"
9
10 D_FIXED = 1
11 P_LIST  = [0, 1, 2]
12 Q_LIST  = [0, 1, 2]
13
14 DAY_PERIOD = int(round(24 * 60 / RES_MIN))
15 K_FOURIER  = 6
16 EARLY_STOP_DELTA = 1.0
```

A.1.3 Yardımcı Fonksiyonlar

```
1 def to_float(s: pd.Series) -> pd.Series:
2     s = s.astype(str).str.replace(",", ".", regex=False)
3     num = s.str.extract(r"([-+]?[0-9]*\.?[0-9]+)")[0]
4     return pd.to_numeric(num, errors="coerce")
5
6 def fourier_terms(index: pd.DatetimeIndex, period: int, K: int) ->
7 pd.DataFrame:
8     t = np.arange(len(index), dtype=float)
9     out = {f"sin_{k}": np.sin(2*np.pi*k*t/period) for k in range
10            (1, K+1)}
11     out.update({f"cos_{k}": np.cos(2*np.pi*k*t/period) for k in range
12                (1, K+1)})
13     return pd.DataFrame(out, index=index)
```

A.1.4 Veri Hazırlama

```
1 df = pd.read_csv(INPUT_CSV, parse_dates=["CREATEDATE"]).sort_values
2 ("CREATEDATE").set_index("CREATEDATE")
3
4 y = to_float(df[TARGET]).interpolate(limit_direction="both").
5 ffill().bfill()
6
7 full_idx = pd.date_range(y.index.min(), y.index.max(), freq=f"
8 {RES_MIN}min")
9 y = y.reindex(full_idx).interpolate(limit_direction="both").
10 ffill().bfill()
11
12 train = y.loc[TRAIN_START:TRAIN_END]
13 test = y.loc[TEST_START:TEST_END]
14
15 exog_tr = sm.add_constant(fourier_terms(train.index, DAY_PERIOD,
16 K_FOURIER), has_constant='add')
17 exog_te = sm.add_constant(fourier_terms(test.index, DAY_PERIOD,
18 K_FOURIER), has_constant='add')
```

A.1.5 Parametre Araması

```
1 best_aic, best_order, best_model = np.inf, None, None
2 for p in P_LIST:
3     for q in Q_LIST:
4         order = (p, D_FIXED, q)
5         try:
6             m = SARIMAX(train, order=order, exog=exog_tr,
7                          simple_differencing=False,
8                          enforce_stationarity=False,
9                          enforce_invertibility=False).fit(dispatch=False)
10
11             if m.aic < best_aic:
12                 best_aic, best_order, best_model = m.aic, order, m
13         except:
14             continue
```


A.1.6 Tahmin ve Performans Değerlendirmesi

```
1 fc = best_model.get_forecast(steps=len(test), exog=exog_te)
2 y_pred = pd.Series(pd.to_numeric(fc.predicted_mean, errors="coerce"),
3 index=test.index)
4
5 mae = mean_absolute_error(test, y_pred)
6 rmse = np.sqrt(mean_squared_error(test, y_pred))
7 r2 = r2_score(test, y_pred)
```

A.1.7 Sonuçların Kaydedilmesi

```
1 res = pd.DataFrame({"Gercek": test, "ARIMA_Tahmin": y_pred},
2 index=test.index)
3 res.to_csv("ARIMA_results_60DK_2024_Aralik13-15.csv")
4 res.to_excel("ARIMA_results_60DK_2024_Aralik13-15.xlsx")
```

A.1.8 Grafik Üretimi

```
1 plt.figure(figsize=(18,5))
2 plt.plot(res.index, res["Gercek"].rolling(2).median(), label="Gercek")
3 plt.plot(res.index, res["ARIMA_Tahmin"].rolling(2).median(),
4 label="ARIMA Tahmin")
5 plt.title("ARIMA Modeli Gercek ve Tahmin Kiyaslama (60 Dakika)")
6 plt.ylabel("WS2M (m/s)")
7 plt.legend()
8 plt.grid(True, linestyle="--", alpha=0.5)
9 plt.tight_layout()
10 plt.savefig("ARIMA_60DK_2024_Aralik13-15_Grafik.png", dpi=200)
11 plt.show()
```

A.2 ANN Modelinde Kullanılan Python Kodları

Bu ekte, çalışmada kullanılan ANN (Artificial Neural Networks) modelinin Python uygulamasına yönelik kodlar sunulmaktadır. Kod; veri hazırlama, ölçeklendirme, sekans (lag) oluşturma, modelin kurulumu, tahmin, performans metrikleri, çıktıların kaydedilmesi ve grafik üretimi olmak üzere sekiz bölümde verilmiştir.

A.2.1 Veri Setinin Yüklenmesi ve Temizlenmesi

```
1 PREF_60MIN = "2024_Eylul_Aralik13-15_60dk_BIRLESIK_IMPUTED.csv"
2 INPUT_CSV = PREF_60MIN
3 TARGET = "WS2M"
4
5 TRAIN_START = "2024-09-01 00:00:00"
6 TRAIN_END = "2024-12-12 23:59:59"
7 TEST_START = "2024-12-13 00:00:00"
8 TEST_END = "2024-12-15 23:59:59"
9
10 LAG_STEPS = 12
11 EPOCHS = 30
```

```

12 BATCH      = 64
13
14 df = pd.read_csv(INPUT_CSV, parse_dates=["CREATEDATE"])
15 df = df.dropna(subset=["CREATEDATE"]).set_index("CREATEDATE").
16 sort_index()
17
18 data = df[[TARGET]].copy()
19 data[TARGET] = pd.to_numeric(data[TARGET], errors="coerce")
20 data = data.interpolate(method="time").ffill().bfill()

```

A.2.2 Veri Ölçeklendirme

```

1 train = data.loc[TRAIN_START:TRAIN_END].copy()
2 test  = data.loc[TEST_START:TEST_END].copy()
3
4 scaler = MinMaxScaler()
5 train_s = scaler.fit_transform(train.values)
6 test_s  = scaler.transform(test.values)

```

A.2.3 Sekans (Lag) Yapısının Oluşturulması

```

1 def create_dataset(series_2d, lag=10):
2     X, y = [], []
3     s = series_2d[:, 0]
4     for i in range(len(s) - lag):
5         X.append(s[i:i+lag])
6         y.append(s[i+lag])
7     return np.array(X), np.array(y)
8
9 X_train, y_train = create_dataset(train_s, lag=LAG_STEPS)
10 X_test, y_test  = create_dataset(test_s, lag=LAG_STEPS)

```

A.2.4 ANN Modelinin Kurulumu ve Eğitilmesi

```

1 model = Sequential([
2     Dense(64, activation="relu", input_shape=(LAG_STEPS,)),
3     Dense(32, activation="relu"),
4     Dense(1)
5 ])
6 model.compile(optimizer="adam", loss="mse")
7 model.fit(X_train, y_train, epochs=EPOCHS, batch_size=BATCH,
8         verbose=1, validation_split=0.1)

```

A.2.5 Tahmin ve Ters Ölçeklendirme

```

1 y_pred_s = model.predict(X_test, verbose=0)
2 y_test_inv = scaler.inverse_transform(y_test.reshape(-1,1)).flatten()
3 y_pred_inv = scaler.inverse_transform(y_pred_s).flatten()
4
5 test_index = test.index[LAG_STEPS:]
6
7 results = pd.DataFrame({

```

```

8     "Gercek": y_test_inv,
9     "Tahmin": y_pred_inv
10 }, index=test_index)

```

A.2.6 Performans Metrikleri

```

1 mae = mean_absolute_error(results["Gercek"], results["Tahmin"])
2 rmse = np.sqrt(mean_squared_error(results["Gercek"], results
3 ["Tahmin"]))
4 r2 = r2_score(results["Gercek"], results["Tahmin"])

```

A.2.7 Sonuçların Kaydedilmesi

```

1 pred_series = results["Tahmin"].rename("Tahmin")
2 pred_series.to_csv("ANN_tahmin_60DK_2024_Aralik13-15_lookback12.csv")
3 results.to_csv("ANN_results_60DK_2024_Aralik13-15_lookback12.csv")

```

A.2.8 Grafik Üretimi

```

1 plt.figure(figsize=(18,5))
2 plt.plot(results.index, results["Gercek"], label="Gercek")
3 plt.plot(results.index, results["Tahmin"], label="ANN Tahmin")
4 plt.title("ANN Modeli Gercek ve Tahmin Kiyaslamasi (60 dk)")
5 plt.ylabel("WS2M (m/s)")
6 plt.legend()
7 plt.grid(True, linestyle="--")
8 plt.tight_layout()
9 plt.show()

```

A.3 LSTM Modelinde Kullanılan Python Kodları

Bu ekte, çalışmada kullanılan LSTM (Long Short-Term Memory) modeline ait Python kodları sunulmaktadır. Kod; yardımcı fonksiyonlar, veri setinin yüklenmesi, eğitim süreci, sekans oluşturma, model kurulumu ve eğitimi, tahmin, performans değerlendirme, sonuçların kaydedilmesi ve grafik üretimi olmak üzere sekiz bölüm altında verilmiştir.

A.3.1 Yardımcı Fonksiyonlar

```

1 PREF_60MIN    = "2024_Eylul_Aralik13-15_60dk_BIRLESIK_IMPUTED.csv"
2 TARGET        = "WS2M"
3
4 TRAIN_START   = "2024-09-01 00:00:00"
5 TRAIN_END     = "2024-12-12 23:59:59"
6 TEST_START    = "2024-12-13 00:00:00"
7 TEST_END      = "2024-12-15 23:59:59"
8
9 LOOKBACK      = 12
10 EPOCHS        = 40
11 BATCH_SIZE    = 64
12 VAL_SPLIT     = 0.12

```

```

13 PATIENCE      = 6
14
15 def safe_num(s: pd.Series) -> pd.Series:
16     s = pd.to_numeric(s, errors="coerce")
17     return s.interpolate("time").ffill().bfill()
18
19 def add_time_features(idx: pd.DatetimeIndex) -> pd.DataFrame:
20     hour = idx.hour.values
21     dow  = idx.dayofweek.values
22     tf = pd.DataFrame(index=idx)
23     tf["tod_sin"] = np.sin(2*np.pi * hour / 24.0)
24     tf["tod_cos"] = np.cos(2*np.pi * hour / 24.0)
25     tf["dow_sin"] = np.sin(2*np.pi * dow / 7.0)
26     tf["dow_cos"] = np.cos(2*np.pi * dow / 7.0)
27     return tf
28
29 def make_sequences(X: np.ndarray, y: np.ndarray, lookback: int):
30     S, T = [], []
31     for i in range(lookback, len(X)):
32         S.append(X[i-lookback:i, :])
33         T.append(y[i])
34     return np.array(S), np.array(T)

```

A.3.2 Veri Setinin Yüklenmesi

```

1 df = load_60min().sort_index()
2
3 need = ["WS2M", "WD2M", "TEMP", "HUMID", "QNH", "INSTRAIN"]
4 for c in need:
5     if c not in df.columns: df[c] = np.nan
6     df[c] = safe_num(df[c])
7
8 ang = (df["WD2M"] % 360.0).astype(float)
9 df["WD2M_sin_raw"] = np.sin(np.deg2rad(ang))
10 df["WD2M_cos_raw"] = np.cos(np.deg2rad(ang))
11
12 df = pd.concat([df, add_time_features(df.index)], axis=1)
13
14 shift_cols = ["WS2M", "TEMP", "HUMID", "QNH", "INSTRAIN", "WD2M_sin_raw",
15 "WD2M_cos_raw"]
16 for c in shift_cols:
17     df[c+"_lag1"] = df[c].shift(1)
18
19 FEATS = [
20     "WS2M_lag1", "TEMP_lag1", "HUMID_lag1", "QNH_lag1", "INSTRAIN_lag1",
21     "WD2M_sin_raw_lag1", "WD2M_cos_raw_lag1",
22     "tod_sin", "tod_cos", "dow_sin", "dow_cos"
23 ]
24 df["TARGET"] = df["WS2M"]
25
26 data = df[FEATS + ["TARGET"]].dropna()

```

A.3.3 Eğitim-Test Ayrımı ve Ölçeklendirme

```
1 train = data.loc[TRAIN_START:TRAIN_END].copy()
2 test = data.loc[TEST_START:TEST_END].copy()
3
4 X_train_df, y_train = train[FEATS], train["TARGET"].values
5 X_test_df, y_test = test[FEATS], test["TARGET"].values
6
7 x_scaler = MinMaxScaler().fit(X_train_df.values)
8 X_train_s = x_scaler.transform(X_train_df.values)
9 X_test_s = x_scaler.transform(X_test_df.values)
10
11 y_scaler = MinMaxScaler().fit(y_train.reshape(-1,1))
12 y_train_s = y_scaler.transform(y_train.reshape(-1,1)).reshape(-1)
```

A.3.4 Lookback Sekanslarının Oluşturulması

```
1 X_train_seq, y_train_seq = make_sequences(X_train_s, y_train_s,
2 LOOKBACK)
3 X_test_seq, y_test_seq = make_sequences(X_test_s, y_test,
4 LOOKBACK)
5 n_steps, n_feats = X_train_seq.shape[1], X_train_seq.shape[2]
```

A.3.5 LSTM Modelinin Kurulumu ve Eğitimi

```
1 model = Sequential([
2     Input(shape=(n_steps, n_feats)),
3     LSTM(128, return_sequences=True),
4     Dropout(0.2),
5     LSTM(64),
6     Dropout(0.1),
7     Dense(1)
8 ])
9 model.compile(optimizer="adam", loss="mse")
10
11 es = EarlyStopping(monitor="val_loss", patience=PATIENCE,
12
13 restore_best_weights=True, verbose=1)
14 rlr = ReduceLROnPlateau(monitor="val_loss", factor=0.5,
15 patience=max(2, PATIENCE//2), min_lr=1e-5, verbose=1)
16
17 model.fit(
18     X_train_seq, y_train_seq,
19     epochs=EPOCHS, batch_size=BATCH_SIZE,
20     validation_split=VAL_SPLIT,
21     callbacks=[es, rlr],
22     verbose=1
23 )
```

A.3.6 Tahmin ve Performans Metrikleri

```
1 y_pred_scaled = model.predict(X_test_seq, verbose=0).
2 reshape(-1)
3 y_pred = y_scaler.inverse_transform(y_pred_scaled.reshape(-1,1)).
4 reshape(-1)
5
6 test_index = X_test_df.index[LOOKBACK:]
7 n = min(len(test_index), len(y_test_seq), len(y_pred))
8 test_index = test_index[:n]
9 y_true = y_test_seq[:n]
10 y_pred = y_pred[:n]
11
12 mae = mean_absolute_error(y_true, y_pred)
13 rmse = np.sqrt(mean_squared_error(y_true, y_pred))
14 r2 = r2_score(y_true, y_pred)
```

A.3.7 Sonuçların Kaydedilmesi

```
1 out_csv = f"LSTM_results_60DK_2024_Aralik13-15_lookback{LOOKBACK}.
2 csv"
3 out_xlsx = out_csv.replace(".csv", ".xlsx")
4 pd.DataFrame({"Gercek": y_true, "Tahmin": y_pred}, index=test_index).
5 to_csv(out_csv)
```

A.3.8 Grafik Üretimi


```
1 res_plot = pd.DataFrame({"Gercek": y_true, "Tahmin": y_pred},
2 index=test_index)
3 res_plot["Gercek_smooth"] = res_plot["Gercek"].
4 rolling(2, min_periods=1).median()
5 res_plot["Tahmin_smooth"] = res_plot["Tahmin"].
6 rolling(2, min_periods=1).median()
7
8 plt.figure(figsize=(18,5))
9 plt.plot(res_plot.index, res_plot["Gercek_smooth"],
10 label="Gercek")
11 plt.plot(res_plot.index, res_plot["Tahmin_smooth"],
12 label="LSTM Tahmin")
13 plt.title("LSTM Modeli Gercek ve Tahmin Kiyaslamasi (60 dk)")
14 plt.ylabel("WS2M (m/s)")
15 plt.legend()
16 plt.grid(True)
17 plt.tight_layout()
18 plt.show()
```

EK B


B.1 2 Şubat-12 Nisan 2023 Tarihine Ait Çıktılar

B.1.1 Yalnızca Rüzgar Girdileri


B.1.1.1 1 Dakikalık Veriler Kullanılan Çıktılar



Şekil B.1: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil B.2: ANN modeli tahmin-gözlem karşılaştırması.




Şekil B.3: LSTM modeli tahmin-gözlem karşılaştırması.


Çizelge B.1: Modellere ait hata metriklerinin karşılaştırılması.

Model	MSE	RMSE	MAE	R ²
ARIMA	9.809280	3.131977	2.342993	-0.173391
ANN	0.772904	0.879150	0.623524	0.907545
LSTM	0.605414	0.778083	0.519290	0.927580


B.1.1.2 5 Dakikalık Veriler Kullanılan Çıktılar



Şekil B.4: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil B.5: ANN modeli tahmin-gözlem karşılaştırması.




Şekil B.6: LSTM modeli tahmin-gözlem karşılaştırması.


Çizelge B.2: Modellere ait hata metriklerinin karşılaştırılması.

Model	MSE	RMSE	MAE	R^2
ARIMA	11.420788	3.379466	2.532451	-0.455927
ANN	1.391981	1.179822	0.892129	0.822550
LSTM	1.388730	1.178444	0.884066	0.822964


B.1.1.3 10 Dakikalık Veriler Kullanılan Çıktılar



Şekil B.7: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil B.8: ANN modeli tahmin-gözlem karşılaştırması.




Şekil B.9: LSTM modeli tahmin-gözlem karşılaştırması.


Çizelge B.3: Modellere ait hata metriklerinin karşılaştırılması.

Model	MSE	RMSE	MAE	R ²
ARIMA	10.060937	3.171898	2.355560	-0.357651
ANN	1.669575	1.292120	1.003088	0.774703
LSTM	1.675574	1.294440	1.000008	0.773893


B.1.1.4 30 Dakikalık Veriler Kullanılan Çıktılar



Şekil B.10: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil B.11: ANN modeli tahmin-gözlem karşılaştırması.




Şekil B.12: LSTM modeli tahmin-gözlem karşılaştırması.


Çizelge B.4: Modellere ait hata metriklerinin karşılaştırılması.

Model	MSE	RMSE	MAE	R ²
ARIMA	6.947562	2.635823	1.953514	-0.067329
ANN	2.208325	1.486043	1.137958	0.660743
LSTM	2.260179	1.503389	1.151945	0.652777


B.1.1.5 60 Dakikalık Veriler Kullanılan Çıktılar



Şekil B.13: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil B.14: ANN modeli tahmin-gözlem karşılaştırması.




Şekil B.15: LSTM modeli tahmin-gözlem karşılaştırması.

Çizelge B.5: Modellere ait hata metriklerinin karşılaştırılması.


Model	MSE	RMSE	MAE	R ²
ARIMA	6.467888	2.543204	1.861236	-0.077838
ANN	3.382870	1.839258	1.395223	0.436263
LSTM	3.321535	1.822508	1.396706	0.446484

B.1.2 Rüzgâr & Sıcaklık Girdileri


B.1.2.1 1 Dakikalık Veriler Kullanılan Çıktılar



Şekil B.16: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil B.17: ANN modeli tahmin-gözlem karşılaştırması.




Şekil B.18: LSTM modeli tahmin-gözlem karşılaştırması.


Çizelge B.6: Modellere ait hata metriklerinin karşılaştırılması.

Model	MSE	RMSE	MAE	R ²
ANN	0.796416	0.892421	0.657508	0.904732
LSTM	1.224951	1.106775	0.825252	0.853471
ARIMA	12.920835	3.594556	2.664601	-0.545596


B.1.2.2 5 Dakikalık Veriler Kullanılan Çıktılar



Şekil B.19: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil B.20: ANN modeli tahmin-gözlem karşılaştırması.




Şekil B.21: LSTM modeli tahmin-gözlem karşılaştırması.


Çizelge B.7: Modellere ait hata metriklerinin karşılaştırılması.

Model	MSE	RMSE	MAE	R ²
LSTM	1.390018	1.178990	0.888108	0.822800
ANN	1.416644	1.190229	0.902973	0.819406
ARIMA	11.484772	3.388919	2.560667	-0.464083


B.1.2.3 10 Dakikalık Veriler Kullanılan Çıktılar



Şekil B.22: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil B.23: ANN modeli tahmin-gözlem karşılaştırması.




Şekil B.24: LSTM modeli tahmin-gözlem karşılaştırması.


Çizelge B.8: Modellere ait hata metriklerinin karşılaştırılması.

Model	MSE	RMSE	MAE	R ²
ANN	1.666251	1.290834	0.996037	0.775151
LSTM	1.707003	1.306523	1.008078	0.769652
ARIMA	10.437450	3.230704	2.446010	-0.408458


B.1.2.4 30 Dakikalık Veriler Kullanılan Çıktılar



Şekil B.25: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil B.26: ANN modeli tahmin-gözlem karşılaştırması.




Şekil B.27: LSTM modeli tahmin-gözlem karşılaştırması.


Çizelge B.9: Modellere ait hata metriklerinin karşılaştırılması.

Model	MSE	RMSE	MAE	R ²
ANN	2.200165	1.483295	1.141364	0.661997
LSTM	2.949982	1.717551	1.355791	0.546805
ARIMA	8.053995	2.837956	2.114654	-0.237306


B.1.2.5 60 Dakikalık Veriler Kullanılan Çıktılar



Şekil B.28: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil B.29: ANN modeli tahmin-gözlem karşılaştırması.




Şekil B.30: LSTM modeli tahmin-gözlem karşılaştırması.

Çizelge B.10: Modellere ait hata metriklerinin karşılaştırılması.


Model	MSE	RMSE	MAE	R ²
ANN	3.251846	1.803287	1.391449	0.458098
LSTM	3.259087	1.805294	1.385677	0.456891
ARIMA	6.441173	2.537947	1.857010	-0.073386

B.1.3 Rüzgâr & Sıcaklık & Basınç Girdileri


B.1.3.1 1 Dakikalık Veriler Kullanılan Çıktılar



Şekil B.31: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil B.32: ANN modeli tahmin-gözlem karşılaştırması.




Şekil B.33: LSTM modeli tahmin-gözlem karşılaştırması.


Çizelge B.11: Modellere ait hata metriklerinin karşılaştırılması.

Model	MSE	RMSE	MAE	R ²
LSTM	0.609730	0.780852	0.524770	0.927064
ANN	1.919172	1.385342	1.063342	0.770428
ARIMA	13.599141	3.687701	2.733698	-0.626735


B.1.3.2 5 Dakikalık Veriler Kullanılan Çıktılar



Şekil B.34: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil B.35: ANN modeli tahmin-gözlem karşılaştırması.




Şekil B.36: LSTM modeli tahmin-gözlem karşılaştırması.


Çizelge B.12: Modellere ait hata metriklerinin karşılaştırılması.

Model	MSE	RMSE	MAE	R^2	n
LSTM	1.387451	1.177901	0.886131	0.823127	
ANN	1.483351	1.217929	0.919472	0.810902	
ARIMA	11.484772	3.388919	2.560667	-0.464083	


B.1.3.3 10 Dakikalık Veriler Kullanılan Çıktılar



Şekil B.37: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil B.38: ANN modeli tahmin-gözlem karşılaştırması.




Şekil B.39: LSTM modeli tahmin-gözlem karşılaştırması.


Çizelge B.13: Modellere ait hata metriklerinin karşılaştırılması.

Model	MSE	RMSE	MAE	R ²
ANN	1.665702	1.290621	1.002461	0.775226
LSTM	1.690177	1.300068	1.003862	0.771923
ARIMA	10.437450	3.230704	2.440610	-0.408458


B.1.3.4 30 Dakikalık Veriler Kullanılan Çıktılar



Şekil B.40: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil B.41: ANN modeli tahmin-gözlem karşılaştırması.




Şekil B.42: LSTM modeli tahmin-gözlem karşılaştırması.


Çizelge B.14: Modellere ait hata metriklerinin karşılaştırılması.

Model	MSE	RMSE	MAE	R ²
ANN	2.340860	1.529987	1.180453	0.640382
LSTM	3.091226	1.758188	1.387770	0.525106
ARIMA	6.947562	2.635823	1.953514	-0.067329


B.1.3.5 60 Dakikalık Veriler Kullanılan Çıktılar



Şekil B.43: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil B.44: ANN modeli tahmin-gözlem karşılaştırması.



Şekil B.45: LSTM modeli tahmin-gözlem karşılaştırması.


Çizelge B.15: Modellere ait hata metriklerinin karşılaştırılması.

Model	MSE	RMSE	MAE	R ²
ANN	2.340860	1.529987	1.180453	0.640382
LSTM	3.091226	1.758188	1.387770	0.525106
ARIMA	6.947562	2.635823	1.953514	-0.067329


B.2 1 Eylül-20 Kasım 2023 Tarihine Ait Çıktılar

B.2.1 Yalnızca Rüzgar Girdileri


B.2.1.1 1 Dakikalık Veriler Kullanılan Çıktılar



Şekil B.46: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil B.47: ANN modeli tahmin-gözlem karşılaştırması.




Şekil B.48: LSTM modeli tahmin-gözlem karşılaştırması.


Çizelge B.16: Modellere ait hata metriklerinin karşılaştırılması.

Model	MSE	RMSE	MAE	R^2
ARIMA	62.665426	7.916150	6.330734	-1.746971
ANN	1.623576	1.274196	0.816682	0.928830
LSTM	1.788001	1.337162	0.788545	0.921622


B.2.1.2 5 Dakikalık Veriler Kullanılan Çıktılar



Şekil B.49: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil B.50: ANN modeli tahmin-gözlem karşılaştırması.




Şekil B.51: LSTM modeli tahmin-gözlem karşılaştırması.


Çizelge B.17: Modellere ait hata metriklerinin karşılaştırılması.

Model	MSE	RMSE	MAE	R ²
ARIMA	61.211897	7.823803	6.275026	-1.778597
ANN	1.789309	1.337651	0.960104	0.918778
LSTM	1.518956	1.232459	0.894947	0.931050


B.2.1.3 10 Dakikalık Veriler Kullanılan Çıktılar



Şekil B.52: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil B.53: ANN modeli tahmin-gözlem karşılaştırması.




Şekil B.54: LSTM modeli tahmin-gözlem karşılaştırması.


Çizelge B.18: Modellere ait hata metriklerinin karşılaştırılması.

Model	MSE	RMSE	MAE	R ²
ARIMA	44.114656	6.641886	4.932596	-1.039638
ANN	2.076121	1.440875	1.056352	0.904011
LSTM	1.819757	1.348984	0.977695	0.915864


B.2.1.4 30 Dakikalık Veriler Kullanılan Çıktılar



Şekil B.55: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil B.56: ANN modeli tahmin-gözlem karşılaştırması.




Şekil B.57: LSTM modeli tahmin-gözlem karşılaştırması.


Çizelge B.19: Modellere ait hata metriklerinin karşılaştırılması.

Model	MSE	RMSE	MAE	R ²
ARIMA	40.504551	6.364319	4.658788	-0.959620
ANN	3.190333	1.786150	1.321307	0.845651
LSTM	2.617554	1.617886	1.191429	0.873362


B.2.1.5 60 Dakikalık Veriler Kullanılan Çıktılar



Şekil B.58: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil B.59: ANN modeli tahmin-gözlem karşılaştırması.




Şekil B.60: LSTM modeli tahmin-gözlem karşılaştırması.

Çizelge B.20: Modellere ait hata metriklerinin karşılaştırılması.


Model	MSE	RMSE	MAE	R ²
ARIMA	39.904871	6.317030	4.607340	-0.986621
ANN	5.294922	2.301070	1.706203	0.736398
LSTM	4.496093	2.120399	1.583116	0.776167

B.2.2 Rüzgâr & Sıcaklık Girdileri


B.2.2.1 1 Dakikalık Veriler Kullanılan Çıktılar



Şekil B.61: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil B.62: ANN modeli tahmin-gözlem karşılaştırması.




Şekil B.63: LSTM modeli tahmin-gözlem karşılaştırması.


Çizelge B.21: Modellere ait hata metriklerinin karşılaştırılması.

Model	MSE	RMSE	MAE	R ²
LSTM	1.123703	1.060048	0.605178	0.950742
ANN	1.281173	1.131889	0.673038	0.943839
ARIMA	80.991347	8.999519	7.369214	-2.550298


B.2.2.2 5 Dakikalık Veriler Kullanılan Çıktılar



Şekil B.64: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil B.65: ANN modeli tahmin-gözlem karşılaştırması.




Şekil B.66: LSTM modeli tahmin-gözlem karşılaştırması.


Çizelge B.22: Modellere ait hata metriklerinin karşılaştırılması.

Model	MSE	RMSE	MAE	R ²
LSTM	3.574370	1.890600	1.329452	0.839662
ANN	4.281078	2.069077	1.441707	0.807961
ARIMA	48.853339	6.989516	5.240825	-1.191447


B.2.2.3 10 Dakikalık Veriler Kullanılan Çıktılar



Şekil B.67: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil B.68: ANN modeli tahmin-gözlem karşılaştırması.




Şekil B.69: LSTM modeli tahmin-gözlem karşılaştırması.


Çizelge B.23: Modellere ait hata metriklerinin karşılaştırılması.

Model	MSE	RMSE	MAE	R ²
LSTM	4.883157	2.209787	1.592172	0.780576
ANN	5.468759	2.338538	1.646427	0.754262
ARIMA	41.692910	6.457005	4.488909	-0.873466


B.2.2.4 30 Dakikalık Veriler Kullanılan Çıktılar



Şekil B.70: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil B.71: ANN modeli tahmin-gözlem karşılaştırması.




Şekil B.72: LSTM modeli tahmin-gözlem karşılaştırması.


Çizelge B.24: Modellere ait hata metriklerinin karşılaştırılması.

Model	MSE	RMSE	MAE	R ²
LSTM	8.573917	2.928125	2.198451	0.626956
ANN	18.157798	4.261197	3.050776	0.209970
ARIMA	42.048230	6.484461	4.472298	-0.829483


B.2.2.5 60 Dakikalık Veriler Kullanılan Çıktılar



Şekil B.73: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil B.74: ANN modeli tahmin-gözlem karşılaştırması.




Şekil B.75: LSTM modeli tahmin-gözlem karşılaştırması.

Çizelge B.25: Modellere ait hata metriklerinin karşılaştırılması.


Model	MSE	RMSE	MAE	R ²
LSTM	10.654073	3.264058	2.321707	0.462620
ANN	15.284229	3.909505	2.926518	0.229080
ARIMA	38.399049	6.196697	4.472055	-0.936807

B.2.3 Rüzgâr & Sıcaklık & Basınç Girdileri


B.2.3.1 1 Dakikalık Veriler Kullanılan Çıktılar



Şekil B.76: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil B.77: ANN modeli tahmin-gözlem karşılaştırması.




Şekil B.78: LSTM modeli tahmin-gözlem karşılaştırması.


Çizelge B.26: Modellere ait hata metriklerinin karşılaştırılması.

Model	MSE	RMSE	MAE	R ²
LSTM	1.007944	1.003964	0.595394	0.955457
ANN	1.183061	1.087686	0.642224	0.947718
ARIMA	82.097826	9.060785	7.465471	-2.628057


B.2.3.2 5 Dakikalık Veriler Kullanılan Çıktılar



Şekil B.79: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil B.80: ANN modeli tahmin-gözlem karşılaştırması.




Şekil B.81: LSTM modeli tahmin-gözlem karşılaştırması.


Çizelge B.27: Modellere ait hata metriklerinin karşılaştırılması.

Model	MSE	RMSE	MAE	R ²
LSTM	2.986099	1.728033	1.218318	0.864936
ANN	3.841491	1.959972	1.364079	0.826246
ARIMA	68.001026	8.246273	6.710188	-2.075751


B.2.3.3 10 Dakikalık Veriler Kullanılan Çıktılar



Şekil B.82: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil B.83: ANN modeli tahmin-gözlem karşılaştırması.




Şekil B.84: LSTM modeli tahmin-gözlem karşılaştırması.


Çizelge B.28: Modellere ait hata metriklerinin karşılaştırılması.

Model	MSE	RMSE	MAE	R ²
LSTM	3.858091	1.964202	1.415059	0.825160
ANN	6.940850	2.634549	1.871982	0.685457
ARIMA	42.180047	6.494617	4.536561	-0.911502


B.2.3.4 30 Dakikalık Veriler Kullanılan Çıktılar



Şekil B.85: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil B.86: ANN modeli tahmin-gözlem karşılaştırması.




Şekil B.87: LSTM modeli tahmin-gözlem karşılaştırması.


Çizelge B.29: Modellere ait hata metriklerinin karşılaştırılması.

Model	MSE	RMSE	MAE	R ²
LSTM	8.113974	2.848504	2.051442	0.645277
ANN	21.093765	4.592795	3.231370	0.077831
ARIMA	42.339111	6.506851	4.497722	-0.850964


B.2.3.5 60 Dakikalık Veriler Kullanılan Çıktılar



Şekil B.88: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil B.89: ANN modeli tahmin-gözlem karşılaştırması.



Şekil B.90: LSTM modeli tahmin-gözlem karşılaştırması.


Çizelge B.30: Modellere ait hata metriklerinin karşılaştırılması.

Model	MSE	RMSE	MAE	R ²
LSTM	10.832938	3.291343	2.343825	0.453598
ANN	14.133050	3.759395	2.831179	0.287144
ARIMA	38.399049	6.196697	4.472055	-0.936807


B.3 1 Mart-25 Mayıs 2024 Tarihine Ait Çıktılar

B.3.1 Yalnızca Rüzgar Girdileri


B.3.1.1 1 Dakikalık Veriler Kullanılan Çıktılar



Şekil B.91: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil B.92: ANN modeli tahmin-gözlem karşılaştırması.




Şekil B.93: LSTM modeli tahmin-gözlem karşılaştırması.


Çizelge B.31: Modellere ait hata metriklerinin karşılaştırılması.

Model	MSE	RMSE	MAE	R ²
LSTM	1.487694	1.219710	0.871672	0.845737
ANN	1.605091	1.266922	0.879932	0.833564
ARIMA	8.108340	2.847515	2.253013	0.159227


B.3.1.2 5 Dakikalık Veriler Kullanılan Çıktılar



Şekil B.94: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil B.95: ANN modeli tahmin-gözlem karşılaştırması.




Şekil B.96: LSTM modeli tahmin-gözlem karşılaştırması.


Çizelge B.32: Modellere ait hata metriklerinin karşılaştırılması.

Model	MSE	RMSE	MAE	R ²
ANN	1.433189	1.197159	0.887378	0.841035
LSTM	2.132730	1.460387	1.076183	0.763443
ARIMA	7.459512	2.731211	2.166049	0.172611


B.3.1.3 10 Dakikalık Veriler Kullanılan Çıktılar



Şekil B.97: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil B.98: ANN modeli tahmin-gözlem karşılaştırması.




Şekil B.99: LSTM modeli tahmin-gözlem karşılaştırması.


Çizelge B.33: Modellere ait hata metriklerinin karşılaştırılması.

Model	MSE	RMSE	MAE	R ²
ANN	1.634295	1.278396	0.940996	0.811488
LSTM	2.800761	1.673547	1.171120	0.676939
ARIMA	8.277906	2.877135	2.075931	0.045162


B.3.1.4 30 Dakikalık Veriler Kullanılan Çıktılar



Şekil B.100: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil B.101: ANN modeli tahmin-gözlem karşılaştırması.




Şekil B.102: LSTM modeli tahmin-gözlem karşılaştırması.


Çizelge B.34: Modellere ait hata metriklerinin karşılaştırılması.

Model	MSE	RMSE	MAE	R ²
LSTM	5.283343	2.298552	1.792423	0.650259
ANN	5.724373	2.392566	1.913045	0.621064
ARIMA	20.961926	4.578420	3.511426	-0.387614


B.3.1.5 60 Dakikalık Veriler Kullanılan Çıktılar



Şekil B.103: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil B.104: ANN modeli tahmin-gözlem karşılaştırması.




Şekil B.105: LSTM modeli tahmin-gözlem karşılaştırması.

Çizelge B.35: Modellere ait hata metriklerinin karşılaştırılması.


Model	MSE	RMSE	MAE	R ²
ARIMA	15.123219	3.888858	2.770215	-0.174516
ANN	4.343095	2.084009	1.532436	0.662702
LSTM	4.100686	2.025015	1.466612	0.681528

B.3.2 Rüzgâr & Sıcaklık & Basınç Girdileri


B.3.2.1 1 Dakikalık Veriler Kullanılan Çıktılar



Şekil B.106: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil B.107: ANN modeli tahmin-gözlem karşılaştırması.




Şekil B.108: LSTM modeli tahmin-gözlem karşılaştırması.


Çizelge B.36: Modellere ait hata metriklerinin karşılaştırılması.

Model	MSE	RMSE	MAE	R ²
LSTM	0.779858	0.883096	0.564834	0.919135
ANN	1.452638	1.205254	0.834606	0.849372
ARIMA	8.174808	2.859162	2.340457	0.152335


B.3.2.2 5 Dakikalık Veriler Kullanılan Çıktılar



Şekil B.109: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil B.110: ANN modeli tahmin-gözlem karşılaştırması.




Şekil B.111: LSTM modeli tahmin-gözlem karşılaştırması.


Çizelge B.37: Modellere ait hata metriklerinin karşılaştırılması.

Model	MSE	RMSE	MAE	R ²
LSTM	1.377904	1.173841	0.864704	0.847167
ANN	1.417512	1.190593	0.872453	0.842773
ARIMA	10.033730	3.167606	2.318266	-0.112914


B.3.2.3 10 Dakikalık Veriler Kullanılan Çıktılar



Şekil B.112: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil B.113: ANN modeli tahmin-gözlem karşılaştırması.




Şekil B.114: LSTM modeli tahmin-gözlem karşılaştırması.


Çizelge B.38: Modellere ait hata metriklerinin karşılaştırılması.

Model	MSE	RMSE	MAE	R ²	n
LSTM	1.545927	1.243353	0.929955	0.821681	
ANN	1.611854	1.269588	0.924486	0.814076	
ARIMA	11.464515	3.385929	2.446744	-0.322406	


B.3.2.4 30 Dakikalık Veriler Kullanılan Çıktılar



Şekil B.115: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil B.116: ANN modeli tahmin-gözlem karşılaştırması.




Şekil B.117: LSTM modeli tahmin-gözlem karşılaştırması.


Çizelge B.39: Modellere ait hata metriklerinin karşılaştırılması.

Model	MSE	RMSE	MAE	R ²	n
ANN	5.014052	2.239208	1.673536	0.589985	
LSTM	5.268811	2.295389	1.771154	0.569152	
ARIMA	19.662126	4.434200	3.264935	-0.607835	


B.3.2.5 60 Dakikalık Veriler Kullanılan Çıktılar



Şekil B.118: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil B.119: ANN modeli tahmin-gözlem karşılaştırması.




Şekil B.120: LSTM modeli tahmin-gözlem karşılaştırması.

Çizelge B.40: Modellere ait hata metriklerinin karşılaştırılması.


Model	MSE	RMSE	MAE	R ²	n
ANN	5.563487	2.358704	1.829936	0.542879	
LSTM	6.293163	2.508618	1.998558	0.482925	
ARIMA	16.040935	4.005114	2.964621	-0.317996	

B.3.3 Rüzgâr & Sıcaklık & Basınç Girdileri


B.3.3.1 1 Dakikalık Veriler Kullanılan Çıktılar



Şekil B.121: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil B.122: ANN modeli tahmin-gözlem karşılaştırması.




Şekil B.123: LSTM modeli tahmin-gözlem karşılaştırması.


Çizelge B.41: Modellere ait hata metriklerinin karşılaştırılması.

Model	MSE	RMSE	MAE	R ²
LSTM	1.147142	1.071047	0.800395	0.863410
ANN	1.811999	1.346105	0.987764	0.784245
ARIMA	10.237208	3.199564	2.338069	-0.218944


B.3.3.2 5 Dakikalık Veriler Kullanılan Çıktılar



Şekil B.124: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil B.125: ANN modeli tahmin-gözlem karşılaştırması.




Şekil B.126: LSTM modeli tahmin-gözlem karşılaştırması.


Çizelge B.42: Modellere ait hata metriklerinin karşılaştırılması.

Model	MSE	RMSE	MAE	R ²	n
LSTM	1.113724	1.055331	0.769856	0.868446	
ANN	1.350620	1.162162	0.848515	0.840464	
ARIMA	10.944946	3.308315	2.406598	-0.292824	


B.3.3.3 10 Dakikalık Veriler Kullanılan Çıktılar



Şekil B.127: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil B.128: ANN modeli tahmin-gözlem karşılaştırması.




Şekil B.129: LSTM modeli tahmin-gözlem karşılaştırması.


Çizelge B.43: Modellere ait hata metriklerinin karşılaştırılması.

Model	MSE	RMSE	MAE	R ²
ANN	1.535775	1.239264	0.914708	0.816859
LSTM	1.552505	1.245996	0.915835	0.814864
ARIMA	10.752802	3.279147	2.365271	-0.282273


B.3.3.4 30 Dakikalık Veriler Kullanılan Çıktılar



Şekil B.130: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil B.131: ANN modeli tahmin-gözlem karşılaştırması.




Şekil B.132: LSTM modeli tahmin-gözlem karşılaştırması.


Çizelge B.44: Modellere ait hata metriklerinin karşılaştırılması.

Model	MSE	RMSE	MAE	R ²
LSTM	5.283343	2.298552	1.792423	0.650259
ANN	5.724373	2.392566	1.913045	0.621064
ARIMA	20.961926	4.578420	3.511426	-0.387614


B.3.3.5 60 Dakikalık Veriler Kullanılan Çıktılar



Şekil B.133: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil B.134: ANN modeli tahmin-gözlem karşılaştırması.



Şekil B.135: LSTM modeli tahmin-gözlem karşılaştırması.


Çizelge B.45: Modellere ait hata metriklerinin karşılaştırılması.

Model	MSE	RMSE	MAE	R ²
ANN	6.232637	2.496525	2.019764	0.580416
LSTM	9.645262	3.105682	2.493332	0.350676
ARIMA	20.460241	4.523300	3.427178	-0.377393


B.4 1 Eylül-15 Aralık 2024 Tarihine Ait Çıktılar

B.4.1 Yalnızca Rüzgar Girdileri


B.4.1.1 1 Dakikalık Veriler Kullanılan Çıktılar



Şekil B.136: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil B.137: ANN modeli tahmin-gözlem karşılaştırması.




Şekil B.138: LSTM modeli tahmin-gözlem karşılaştırması.


Çizelge B.46: Modellere ait hata metriklerinin karşılaştırılması.

Model	MSE	RMSE	MAE	R ²
ARIMA	6.614064	2.571782	2.148266	-0.475686
ANN	0.539433	0.734461	0.500841	0.879645
LSTM	0.524952	0.724535	0.479921	0.882876


B.4.1.2 5 Dakikalık Veriler Kullanılan Çıktılar



Şekil B.139: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil B.140: ANN modeli tahmin-gözlem karşılaştırması.




Şekil B.141: LSTM modeli tahmin-gözlem karşılaştırması.


Çizelge B.47: Modellere ait hata metriklerinin karşılaştırılması.

Model	MSE	RMSE	MAE	R ²
ARIMA	4.218696	2.053946	1.735680	-0.041776
ANN	1.075917	1.037264	0.799079	0.734310
LSTM	1.068709	1.033784	0.805960	0.736090


B.4.1.3 10 Dakikalık Veriler Kullanılan Çıktılar



Şekil B.142: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil B.143: ANN modeli tahmin-gözlem karşılaştırması.




Şekil B.144: LSTM modeli tahmin-gözlem karşılaştırması.


Çizelge B.48: Modellere ait hata metriklerinin karşılaştırılması.

Model	MSE	RMSE	MAE	R ²
ARIMA	5.139561	2.267060	1.768836	-0.367112
ANN	1.236876	1.112149	0.893000	0.670994
LSTM	1.194327	1.092853	0.844350	0.682312


B.4.1.4 30 Dakikalık Veriler Kullanılan Çıktılar



Şekil B.145: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil B.146: ANN modeli tahmin-gözlem karşılaştırması.




Şekil B.147: LSTM modeli tahmin-gözlem karşılaştırması.


Çizelge B.49: Modellere ait hata metriklerinin karşılaştırılması.

Model	MSE	RMSE	MAE	R ²
ARIMA	4.357052	2.087355	1.631157	-0.358826
ANN	1.400651	1.183491	0.937422	0.563181
LSTM	1.400181	1.183292	0.939098	0.563328


B.4.1.5 60 Dakikalık Veriler Kullanılan Çıktılar



Şekil B.148: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil B.149: ANN modeli tahmin-gözlem karşılaştırması.




Şekil B.150: LSTM modeli tahmin-gözlem karşılaştırması.

Çizelge B.50: Modellere ait hata metriklerinin karşılaştırılması.


Model	MSE	RMSE	MAE	R ²
ARIMA	4.053229	2.013263	1.556827	-0.422665
ANN	1.576067	1.255415	1.026521	0.446807
LSTM	1.561755	1.249702	1.022421	0.451831

B.4.2 Rüzgâr & Sıcaklık Girdileri


B.4.2.1 1 Dakikalık Veriler Kullanılan Çıktılar



Şekil B.151: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil B.152: ANN modeli tahmin-gözlem karşılaştırması.




Şekil B.153: LSTM modeli tahmin-gözlem karşılaştırması.


Çizelge B.51: Modellere ait hata metriklerinin karşılaştırılması.

Model	MSE	RMSE	MAE	R ²
LSTM	0.492403	0.701715	0.440943	0.890362
ANN	1.111462	1.054259	0.802621	0.752524
ARIMA	4.592060	2.142909	1.802262	-0.022460


B.4.2.2 5 Dakikalık Veriler Kullanılan Çıktılar



Şekil B.154: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil B.155: ANN modeli tahmin-gözlem karşılaştırması.




Şekil B.156: LSTM modeli tahmin-gözlem karşılaştırması.


Çizelge B.52: Modellere ait hata metriklerinin karşılaştırılması.

Model	MSE	RMSE	MAE	R ²
LSTM	1.735118	1.317239	1.037176	0.618758
ANN	1.889163	1.374468	1.077514	0.584911
ARIMA	6.236994	2.497398	1.993588	-0.370400


B.4.2.3 10 Dakikalık Veriler Kullanılan Çıktılar



Şekil B.157: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil B.158: ANN modeli tahmin-gözlem karşılaştırması.




Şekil B.159: LSTM modeli tahmin-gözlem karşılaştırması.


Çizelge B.53: Modellere ait hata metriklerinin karşılaştırılması.

Model	MSE	RMSE	MAE	R ²
LSTM	2.321213	1.523553	1.211708	0.502379
ANN	2.662018	1.631569	1.278517	0.429317
ARIMA	5.873860	2.423605	1.933996	-0.259237


B.4.2.4 30 Dakikalık Veriler Kullanılan Çıktılar



Şekil B.160: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil B.161: ANN modeli tahmin-gözlem karşılaştırması.




Şekil B.162: LSTM modeli tahmin-gözlem karşılaştırması.


Çizelge B.54: Modellere ait hata metriklerinin karşılaştırılması.

Model	MSE	RMSE	MAE	R ²
LSTM	3.707155	1.925397	1.527057	0.309639
ANN	3.781443	1.944593	1.571863	0.295805
ARIMA	6.761544	2.600297	2.050218	-0.259162


B.4.2.5 60 Dakikalık Veriler Kullanılan Çıktılar



Şekil B.163: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil B.164: ANN modeli tahmin-gözlem karşılaştırması.




Şekil B.165: LSTM modeli tahmin-gözlem karşılaştırması.

Çizelge B.55: Modellere ait hata metriklerinin karşılaştırılması.


Model	MSE	RMSE	MAE	R ²
LSTM	4.950562	2.224986	1.760362	0.056419
ANN	4.624280	2.150414	1.701597	0.118608
ARIMA	6.430075	2.535759	1.971016	-0.225578

B.4.3 Rüzgâr & Sıcaklık & Basınç Girdileri


B.4.3.1 1 Dakikalık Veriler Kullanılan Çıktılar



Şekil B.166: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil B.167: ANN modeli tahmin-gözlem karşılaştırması.




Şekil B.168: LSTM modeli tahmin-gözlem karşılaştırması.


Çizelge B.56: Modellere ait hata metriklerinin karşılaştırılması.

Model	MSE	RMSE	MAE	R ²
LSTM	1.194327	1.092853	0.844350	0.682312
ANN	1.236876	1.112149	0.893000	0.670994
ARIMA	5.139561	2.267060	1.768836	-0.367112


B.4.3.2 5 Dakikalık Veriler Kullanılan Çıktılar



Şekil B.169: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil B.170: ANN modeli tahmin-gözlem karşılaştırması.




Şekil B.171: LSTM modeli tahmin-gözlem karşılaştırması.


Çizelge B.57: Modellere ait hata metriklerinin karşılaştırılması.

Model	MSE	RMSE	MAE	R^2
LSTM	1.494622	1.222548	0.944364	0.648066
ANN	1.691940	1.300746	0.998104	0.601605
ARIMA	4.738307	2.176765	1.834820	-0.115713


B.4.3.3 10 Dakikalık Veriler Kullanılan Çıktılar



Şekil B.172: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil B.173: ANN modeli tahmin-gözlem karşılaştırması.




Şekil B.174: LSTM modeli tahmin-gözlem karşılaştırması.


Çizelge B.58: Modellere ait hata metriklerinin karşılaştırılması.

Model	MSE	RMSE	MAE	R ²
LSTM	2.482262	1.575520	1.242976	0.503483
ANN	2.790364	1.670438	1.296479	0.441855
ARIMA	7.905630	2.811695	2.276318	-0.581330


B.4.3.4 30 Dakikalık Veriler Kullanılan Çıktılar



Şekil B.175: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil B.176: ANN modeli tahmin-gözlem karşılaştırması.




Şekil B.177: LSTM modeli tahmin-gözlem karşılaştırması.


Çizelge B.59: Modellere ait hata metriklerinin karşılaştırılması.

Model	MSE	RMSE	MAE	R ²
LSTM	4.211818	2.052271	1.727570	0.287424
ANN	4.347670	2.085107	1.695492	0.264439
ARIMA	8.059595	2.838943	2.274081	-0.363562


B.4.3.5 60 Dakikalık Veriler Kullanılan Çıktılar



Şekil B.178: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil B.179: ANN modeli tahmin-gözlem karşılaştırması.



Şekil B.180: LSTM modeli tahmin-gözlem karşılaştırması.


Çizelge B.60: Modellere ait hata metriklerinin karşılaştırılması.

Model	MSE	RMSE	MAE	R ²
LSTM	2.373560	1.540636	1.174424	0.226866
ANN	3.221828	1.794945	1.372123	-0.049438
ARIMA	5.001677	2.236443	1.805340	-0.629183


B.5 1 Mart-3 Mayıs 2025 Tarihine Ait Çıktılar

B.5.1 Yalnızca Rüzgar Girdileri


B.5.1.1 1 Dakikalık Veriler Kullanılan Çıktılar



Şekil B.181: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil B.182: ANN modeli tahmin-gözlem karşılaştırması.




Şekil B.183: LSTM modeli tahmin-gözlem karşılaştırması.


Çizelge B.61: Modellere ait hata metriklerinin karşılaştırılması.

Model	MSE	RMSE	MAE	R ²
LSTM	0.711656	0.843597	0.516644	0.910115
ANN	0.729697	0.854223	0.545715	0.907837
ARIMA	8.911811	2.985266	2.451660	-0.125594


B.5.1.2 5 Dakikalık Veriler Kullanılan Çıktılar



Şekil B.184: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil B.185: ANN modeli tahmin-gözlem karşılaştırması.




Şekil B.186: LSTM modeli tahmin-gözlem karşılaştırması.


Çizelge B.62: Modellere ait hata metriklerinin karşılaştırılması.

Model	MSE	RMSE	MAE	R^2
LSTM	1.921709	1.386257	0.948606	0.738919
ANN	1.879669	1.371010	0.941898	0.744631
ARIMA	7.139349	2.671956	2.066652	0.030057


B.5.1.3 10 Dakikalık Veriler Kullanılan Çıktılar



Şekil B.187: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil B.188: ANN modeli tahmin-gözlem karşılaştırması.




Şekil B.189: LSTM modeli tahmin-gözlem karşılaştırması.


Çizelge B.63: Modellere ait hata metriklerinin karşılaştırılması.

Model	MSE	RMSE	MAE	R ²
LSTM	2.586304	1.608199	1.053601	0.621576
ANN	2.613281	1.616564	1.068673	0.617629
ARIMA	7.306229	2.703004	1.983471	-0.069035


B.5.1.4 30 Dakikalık Veriler Kullanılan Çıktılar



Şekil B.190: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil B.191: ANN modeli tahmin-gözlem karşılaştırması.




Şekil B.192: LSTM modeli tahmin-gözlem karşılaştırması.


Çizelge B.64: Modellere ait hata metriklerinin karşılaştırılması.

Model	MSE	RMSE	MAE	R ²
LSTM	3.410028	1.846626	1.209160	0.425248
ANN	3.425862	1.850908	1.211382	0.422579
ARIMA	6.541019	2.557542	1.905345	-0.102474


B.5.1.5 60 Dakikalık Veriler Kullanılan Çıktılar



Şekil B.193: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil B.194: ANN modeli tahmin-gözlem karşılaştırması.




Şekil B.195: LSTM modeli tahmin-gözlem karşılaştırması.

Çizelge B.65: Modellere ait hata metriklerinin karşılaştırılması.


Model	MSE	RMSE	MAE	R ²
LSTM	2.467594	1.570858	1.181521	0.483404
ANN	2.405271	1.550894	1.163653	0.496452
ARIMA	5.482850	2.341549	1.797289	-0.147845

B.5.2 Rüzgâr & Sıcaklık Girdileri


B.5.2.1 1 Dakikalık Veriler Kullanılan Çıktılar



Şekil B.196: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil B.197: ANN modeli tahmin-gözlem karşılaştırması.




Şekil B.198: LSTM modeli tahmin-gözlem karşılaştırması.


Çizelge B.66: Modellere ait hata metriklerinin karşılaştırılması.

Model	MSE	RMSE	MAE	R ²
LSTM	0.700139	0.836743	0.527977	0.912023
ANN	0.750683	0.866420	0.577287	0.905672
ARIMA	8.426974	2.902925	2.307012	-0.058904


B.5.2.2 5 Dakikalık Veriler Kullanılan Çıktılar



Şekil B.199: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil B.200: ANN modeli tahmin-gözlem karşılaştırması.




Şekil B.201: LSTM modeli tahmin-gözlem karşılaştırması.


Çizelge B.67: Modellere ait hata metriklerinin karşılaştırılması.

Model	MSE	RMSE	MAE	R ²
LSTM	1.905616	1.380441	0.947773	0.744855
ANN	1.941191	1.393266	0.953667	0.740092
ARIMA	7.591641	2.755293	2.110217	-0.016454


B.5.2.3 10 Dakikalık Veriler Kullanılan Çıktılar



Şekil B.202: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil B.203: ANN modeli tahmin-gözlem karşılaştırması.




Şekil B.204: LSTM modeli tahmin-gözlem karşılaştırması.


Çizelge B.68: Modellere ait hata metriklerinin karşılaştırılması.

Model	MSE	RMSE	MAE	R ²
LSTM	2.748509	1.657863	1.089796	0.623740
ANN	2.791543	1.670791	1.111976	0.617849
ARIMA	8.378881	2.894630	2.138830	-0.147034


B.5.2.4 30 Dakikalık Veriler Kullanılan Çıktılar



Şekil B.205: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil B.206: ANN modeli tahmin-gözlem karşılaştırması.




Şekil B.207: LSTM modeli tahmin-gözlem karşılaştırması.


Çizelge B.69: Modellere ait hata metriklerinin karşılaştırılması.

Model	MSE	RMSE	MAE	R ²
LSTM	1.570765	1.253302	1.038794	0.461521
ANN	1.157056	1.075666	0.887146	0.603346
ARIMA	2.545843	1.595570	1.271775	0.127252


B.5.2.5 60 Dakikalık Veriler Kullanılan Çıktılar



Şekil B.208: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil B.209: ANN modeli tahmin-gözlem karşılaştırması.




Şekil B.210: LSTM modeli tahmin-gözlem karşılaştırması.

Çizelge B.70: Modellere ait hata metriklerinin karşılaştırılması.


Model	MSE	RMSE	MAE	R ²
LSTM	2.332842	1.527364	1.291262	0.256067
ANN	1.370284	1.170591	0.905381	0.563023
ARIMA	3.728199	1.930854	1.472893	-0.188905

B.5.3 Rüzgâr & Sıcaklık & Basınç Girdileri


B.5.3.1 1 Dakikalık Veriler Kullanılan Çıktılar



Şekil B.211: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil B.212: ANN modeli tahmin-gözlem karşılaştırması.




Şekil B.213: LSTM modeli tahmin-gözlem karşılaştırması.


Çizelge B.71: Modellere ait hata metriklerinin karşılaştırılması.

Model	MSE	RMSE	MAE	R ²
LSTM	0.700139	0.836743	0.527977	0.912023
ANN	0.750683	0.866420	0.577287	0.905672
ARIMA	8.921682	2.986918	2.449430	-0.121067


B.5.3.2 5 Dakikalık Veriler Kullanılan Çıktılar



Şekil B.214: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil B.215: ANN modeli tahmin-gözlem karşılaştırması.




Şekil B.216: LSTM modeli tahmin-gözlem karşılaştırması.


Çizelge B.72: Modellere ait hata metriklerinin karşılaştırılması.

Model	MSE	RMSE	MAE	R ²
LSTM	1.599151	1.264575	0.870782	0.798378
ANN	1.605366	1.267030	0.876980	0.797595
ARIMA	9.452378	3.074472	2.251459	-0.191761


B.5.3.3 10 Dakikalık Veriler Kullanılan Çıktılar



Şekil B.217: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil B.218: ANN modeli tahmin-gözlem karşılaştırması.




Şekil B.219: LSTM modeli tahmin-gözlem karşılaştırması.


Çizelge B.73: Modellere ait hata metriklerinin karşılaştırılması.

Model	MSE	RMSE	MAE	R ²
LSTM	2.599043	1.612155	1.053772	0.620929
ANN	3.774654	1.942847	1.328275	0.449466
ARIMA	7.613582	2.759272	2.031341	-0.110443


B.5.3.4 30 Dakikalık Veriler Kullanılan Çıktılar



Şekil B.220: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil B.221: ANN modeli tahmin-gözlem karşılaştırması.




Şekil B.222: LSTM modeli tahmin-gözlem karşılaştırması.


Çizelge B.74: Modellere ait hata metriklerinin karşılaştırılması.

Model	MSE	RMSE	MAE	R ²
LSTM	4.776215	2.185455	1.712389	0.299879
ANN	2.203326	1.484360	1.113960	0.677026
ARIMA	7.654409	2.766660	2.105347	-0.122020


B.5.3.5 60 Dakikalık Veriler Kullanılan Çıktılar



Şekil B.223: ARIMA modeli tahmin-gözlem karşılaştırması.



Şekil B.224: ANN modeli tahmin-gözlem karşılaştırması.



Şekil B.225: LSTM modeli tahmin-gözlem karşılaştırması.

Çizelge B.75: Modellere ait hata metriklerinin karşılaştırılması.

Model	MSE	RMSE	MAE	R ²
LSTM	3.565474	1.888246	1.470472	0.246222
ANN	2.168914	1.472723	1.120564	0.541469
ARIMA	5.253467	2.292044	1.676843	-0.110637



ÖZGEÇMİŞ

Ad-Soyad: İlayda KELKİTLİ BAŞARAN

ÖĞRENİM DURUMU:

- **Lisans:** 2021, İstanbul Teknik Üniversitesi, Uçak ve Uzay Bilimleri Fakültesi, Meteoroloji Mühendisliği

MESLEKİ DENEYİMLER:

- 2019-2020 yılları arasında Altınay Havacılık ve İleri Teknolojilerinde uzun dönem stajyer olarak çalıştım.
- 2021 yılında UL Solutions'ta uzun dönem stajyer olarak çalıştım.
- 2022 yılından beri Meteoroloji Genel Müdürlüğü'nde çalışmaktayım.

YÜKSEK LİSANS TEZİNDEN TÜRETİLEN YAYINLAR VE SUNUMLAR:

Kelkitli Başaran, İ., 2025. Derin Öğrenme ve İstatistiksel Modellerle Operasyonel Rüzgâr Enerjisi Tahmini: Batman İçin LSTM, ANN ve ARIMA Uygulaması. *1. Havacılık Meteorolojisi 360° Sempozyumu ve Çalıştayı*, 24–26 Kasım 2025, İstanbul, Türkiye.