



T.C.

TOKAT GAZİOSMANPAŞA ÜNİVERSİTESİ

LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

YÜKSEK LİSANS PROGRAMI

**DERİN ÖĞRENME YÖNTEMLERİ İLE TOKAT İLİNE AİT İKLİM
VERİLERİNİN TAHMİN EDİLMESİ**

YÜKSEK LİSANS TEZİ

Cebrail BATMAZ

Danışman: Doç. Dr. Özkan İNİK

TOKAT- 2025

ETİK SÖZLEŞME

Tokat Gaziosmanpaşa Üniversitesi Lisansüstü Eğitim Enstitüsü tez yazım kılavuzuna göre Doç. Dr. Özkan İNİK danışmanlığında hazırlamış olduğum “Derin Öğrenme Yöntemleri ile Tokat İline Ait İklim Verilerinin Tahmin Edilmesi ” adlı Yüksek Lisans tezinin bilimsel etik değerlere ve kurallara uygun, özgün bir çalışma olduğunu, aksinin tespit edilmesi halinde her türlü yasal yaptırımını kabul edeceğimi beyan ederim.

.../08/2025

Cebrail BATMAZ

JÜRİ KABUL VE ONAY

Cebrail BATMAZ tarafından hazırlanan “**Derin Öğrenme Yöntemleri ile Tokat İline Ait İklim Verilerinin Tahmin Edilmesi**” adlı tez çalışmasının savunma sınavı 15.08.2025 tarihinde yapılmış olup aşağıda verilen Jüri tarafından Oy Birliği ile Tokat Gaziosmanpaşa Üniversitesi Lisansüstü Eğitim Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı’nda Yüksek Lisans Tezi olarak kabul edilmiştir.

Jüri Üyeleri (Unvanı, Adı Soyadı)

İmzası

Üye (Başkan) : Doç. Dr. Özkan İNİK

.....

Üye : Dr. Öğr. Üyesi Ali AKDAĞ

.....

Üye : Dr. Öğr. Üyesi Arif Cem TOPUZ

.....

ONAY

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

Lisansüstü Eğitim Enstitüsü Müdürü

ÖNSÖZ

Bu çalışmanın tez konusunun belirlenmesinden itibaren tüm aşamalarında, değerli görüşleriyle yol gösteren, sabırla yönlendiren ve hiçbir desteğini esirgemeyen saygıdeğer danışmanım Doç. Dr. Özkan İNİK hocama en derin şükranlarımı sunarım.

Çalışmanın temelini oluşturan meteorolojik verileri sağlamadaki katkılarından dolayı Tokat Meteoroloji Müdürlüğü'ne ve çalışanlarına içten teşekkürlerimi sunarım.

Hayatım boyunca en büyük desteği olan, beni her koşulda yüreklendiren ve bu günlere gelmemi sağlayan sevgili anneme ve babama; sabır, anlayış ve sınırsız desteğiyle her daim yanımda olan biricik eşime ve bu zorlu süreçte en büyük motivasyonum ve yaşam enerjim olan oğlum Ömer Faruk 'a minnettarlığımı ifade etmek isterim.

Cebrail BATMAZ

TOKAT-2025

ÖZET

DERİN ÖĞRENME YÖNTEMLERİ İLE TOKAT İLINE AİT İKLİM VERİLERİNİN TAHMİN EDİLMESİ

Batmaz, Cebail

Yüksek Lisans, Bilgisayar Mühendisliği Anabilim Dalı

Tez Danışmanı: Doç. Dr. Özkan İnik

Ağustos 2025, xii+ 96 sayfa

Bu tez çalışmasında, Tokat iline ait 25 yıllık detaylı meteorolojik veriler kullanılarak farklı zaman ölçeklerinde (günlük, haftalık ve aylık) sıcaklık tahmini yapan derin öğrenme modelleri geliştirilmiştir. Zaman serisi verilerinin karmaşık yapısını öğrenmek ve geleceğe yönelik öngörülerde bulunmak amacıyla LSTM (Uzun Kısa Süreli Bellek), GRU (Kapı Kontrollü Tekrarlayan Birim) ve BiLSTM (Çift Yönlü LSTM) gibi gelişmiş tekrarlayan sinir ağı mimarileri kullanılmıştır. Modelleme süreci boyunca veri ön işleme, eksik veri tamamlama, normalizasyon ve özellik seçimi gibi adımlar dikkatle yürütülmüştür. Eksik veriler doğrusal interpolasyon ve hareketli ortalama gibi tekniklerle tamamlanmış, model girişinde kullanılacak değişkenler doluluk oranı ve istatistiksel tutarlılık temelinde belirlenmiştir. Deneysel çalışmalarda her bir model farklı mimari yapı, giriş değişkeni kombinasyonu ve zaman adımı senaryoları ile eğitilmiş; performansları RMSE (Kök Ortalama Kare Hata), MAE (Ortalama Mutlak Hata) ve R^2 (Açıklık Katsayısı) gibi istatistiksel ölçütlerle değerlendirilmiştir. Zaman ölçekleri arasında yapılan karşılaştırmalarda, günlük tahminlerde hata oranlarının görece yüksek olduğu, haftalık tahminlerde daha dengeli sonuçlara ulaşıldığı, aylık tahminlerde ise en düşük hata değerlerinin elde edildiği belirlenmiştir. Nitekim aylık tahminler için geliştirilen 10 farklı LSTM+GRU tabanlı modellerde RMSE değerinin 4,96 – 1,92 aralığında değerler üreterek 2'nin altına düştüğü, günlük tahminlerde ise geliştirilen 5 farklı LSTM+GRU tabanlı modellerde RMSE değerinin 7,93 – 4,21 aralığında kaldığı gözlemlenmiştir. Son aşamada saatlik sıcaklık, saatlik aktüel basınç, mevcut kar kalınlığı, saatlik nispi nem, saatlik ortalama rüzgar, saatlik rüzgar yönü (derece), saatlik rüzgar hızı (m/s), meteorolojik verilerinin her birinin tahmini için BiLSTM modeli geliştirilmiş ve bu modelin genel doğruluk düzeyinin günlük tahmin yapan LSTM+GRU tabanlı modellere kıyasla daha düşük olduğu görülmüştür.

Bu çalışma, farklı derin öğrenme mimarilerinin meteorolojik zaman serileri üzerindeki etkinliğini sistematik bir şekilde incelemekte ve Türkiye'deki yerel iklim verileriyle uzun vadeli tahminler yapılabileceğini göstermektedir. Elde edilen bulgular, iklim modellemesi, erken uyarı sistemleri ve sürdürülebilir çevresel planlama alanlarında gelecekte yapılacak çalışmalara ışık tutabilecek niteliktedir.

Anahtar Kelimeler: Zaman Serisi, Derin Öğrenme, LSTM, GRU, BiLSTM, İklim Modelleme, Meteorolojik Veri

ABSTRACT
**PREDICTION OF CLIMATE DATA FOR TOKAT PROVINCE USING DEEP
LEARNING METHODS**

Batmaz, Cebail
Master's Thesis, Department of Computer Engineering
Advisor: Assoc. Prof. Dr. Özkan İnik
August 2025, xii+ 96 Pages

In this thesis, deep learning models were developed to predict temperature at different time scales (daily, weekly, and monthly) using 25 years of detailed meteorological data from Tokat, Turkey. Advanced recurrent neural network architectures such as LSTM (Long Short-Term Memory), GRU (Gated Recurrent Unit), and BiLSTM (Bidirectional LSTM) were employed to capture the complex structure of time series data and to generate future forecasts. Throughout the modeling process, data preprocessing, missing value imputation, normalization, and feature selection were carefully conducted. Missing data were completed using linear interpolation and moving average techniques, while the input features were determined based on data completeness ratios and statistical consistency. In the experimental studies, each model was trained with different architectural designs, input feature combinations, and time-step scenarios; their performances were evaluated using statistical metrics such as RMSE (Root Mean Squared Error), MAE (Mean Absolute Error), and R^2 (Coefficient of Determination). Comparative analyses across time scales revealed that daily forecasts exhibited relatively higher error rates, weekly forecasts achieved more balanced results, while monthly forecasts yielded the lowest error values. Specifically, for monthly forecasts, ten different LSTM+GRU-based models produced RMSE values in the range of 4.96–1.92, with some results falling below 2, whereas for daily forecasts, five different LSTM+GRU-based models yielded RMSE values between 7.93 and 4.21. In the final stage, a BiLSTM model was developed to predict each of the meteorological variables—hourly temperature, hourly actual pressure, snow depth, hourly relative humidity, hourly mean wind, hourly wind direction (degree), and hourly wind speed (m/s)—and it was observed that the overall accuracy level of this model was lower compared to the daily LSTM+GRU-based models.

This study systematically investigates the effectiveness of different deep learning architectures on meteorological time series and demonstrates that long-term forecasts can be achieved using local climate data from Turkey. The findings provide valuable insights for future research in climate modeling, early warning systems, and sustainable environmental planning.

Keywords: Time Series, Deep Learning, LSTM, GRU, BiLSTM, Climate Modeling, Meteorological Data

İÇİNDEKİLER

ETİK SÖZLEŞME.....	i
JÜRİ KABUL VE ONAY	ii
ÖNSÖZ	iii
ÖZET	iv
ABSTRACT.....	v
İÇİNDEKİLER	vi
TABLolar LİSTESİ	ix
ŞEKİL LİSTESİ.....	x
KISALTMALAR	xii
1. GİRİŞ	1
1.1. Tezin Amacı ve Önemi.....	1
1.2. Tezin Organizasyonu.....	2
2. KAYNAK TARAMASI	3
3. MATERYAL ve METODLAR.....	6
3.1. Yapay Zekâ.....	6
3.2. Makine Öğrenimi	11
3.2.1. Denetimli öğrenme.....	11
3.2.2. Denetimsiz öğrenme	12
3.2.3. Pekiştirmeli öğrenme	12
3.3. Derin Öğrenme.....	12
3.3.1. Yapay sinir ağları	14
3.3.2. Evrişimli sınır ağları (CNN - Convolutional Neural Networks).....	15
3.3.3. Tekrarlayan sinir ağları (RNN - Recurrent Neural Networks).....	17
3.3.4. Uzun kısa süreli bellek (LSTM - Long Short-Term Memory)	19
3.4. Meteorolojik Veriler	21
4. DENEYSEL ÇALIŞMALAR	24
4.1. Performans Ölçütleri	24
4.2. Verilerin Ön İşlenmesi	25
4.3. Eksik Veri Giderme Yöntemleri.....	26

4.4. Sayısal Dönüşüm ve Veri Tipi Uyarlaması	28
4.5. Modelleme Dışı Bırakma	28
4.6. Modelleme Süreci ve Aşamaları	29
4.6.1. Model 1 – Temel LSTM yapısı ile günlük sıcaklık tahmini	30
4.6.2. Model 2 – 2 Katmanlı LSTM ile kısa vadeli sıcaklık tahmini (12 Zaman Adımı)	32
4.6.3. Model 3 – LSTM+GRU ile kısa vadeli sıcaklık tahmini (12 Zaman Adımı)	34
4.6.4. Model 4 – Geliştirilmiş LSTM+GRU melez yapı ile kısa vadeli sıcaklık tahmini (12 Zaman Adımı)	36
4.6.5. Model 5 – Mevsimsel bilgi eklenmiş LSTM+GRU ile kısa vadeli sıcaklık tahmini (24 Zaman Adımı)	38
4.6.6. Model 6 – Haftalık ortalama sıcaklık tahmini (LSTM, 4 Haftalık Girdi) ...	40
4.6.7. Model 7 – Haftalık ortalama sıcaklık tahmini (LSTM+GRU, 4 Haftalık Girdi)	42
4.6.8. Model 8 – Derin LSTM+GRU ile haftalık ortalama sıcaklık tahmini (4 Hafta → 1 Hafta)	44
4.6.9. Model 9 – Haftalık ortalama sıcaklık tahmini (Derin LSTM+GRU + Batch Normalization, 4 hafta → 1 hafta)	46
4.6.10. Model 10 – Haftalık ortalama sıcaklık tahmini (LSTM, Lookback=10 hafta → 1 hafta)	48
4.6.11. Model 11 – Aylık ortalama sıcaklık tahmini (Çoklu Girdi, Lookback=10). ...	50
4.6.12. Model 12 — LSTM+GRU (Lookback=10) ile çok değişkenli aylık ortalama sıcaklık tahmini	52
4.6.13. Model 13 – Aylık ortalama sıcaklık tahmini (3 Girdi, Tek Adım LSTM; Lookback=1)	54
4.6.14. Model 14 – Aylık ortalama sıcaklık tahmini (LSTM + GRU, 3 Girdi, Tek Adım)	56
4.6.15. Model 15 – Aylık ortalama sıcaklık tahmini (24 Aylık Girdi, LSTM+GRU)	58
4.6.16. Model 16 – Aylık ortalama sıcaklık tahmini (12 Aylık Girdi, LSTM Lite)	60
4.6.17. Model 17 – Aylık ortalama sıcaklık tahmini (24 Aylık Girdi, LSTM+GRU, Mevsimsellik)	62
4.6.18. Model 18 – 2 Katmanlı LSTM + Dropout ile aylık sıcaklık tahmini (12 Zaman Adımı)	64

4.6.19. Model 19 – 12 Aylık girdi ile aylık sıcaklık tahmini (LSTM+GRU)	66
4.6.20. Model 20 – Aylık ortalama sıcaklık tahmini (LSTM + GRU, 12 Aylık Girdi)	68
4.6.21. Tez Kapsamında geliştirilen modellerin tablolar halinde karşılaştırılması (Günlük, Haftalık ve Aylık Bazlı).....	70
4.6.22. Model 21 – Tüm meteorolojik değişkenler için BiLSTM tabanlı tahmin modeli.....	76
5. TARTIŞMA.....	87
6. SONUÇ ve ÖNERİLER.....	89
KAYNAKLAR	91



TABLolar LİSTESİ

Tablo 4.2. Meteoroloji M¼d¼rl¼ğ¼nden alınan verilerin doluluk oranı	29
Tablo 4.3. G¼nl¼k tahmin modelleri (Model 1 – Model 5 arası).....	70
Tablo 4.4. Haftalık tahmin modelleri (Model 6 – Model 10 arası).....	71
Tablo 4.5. Aylık tahmin modelleri (Model 11 – Model 20 arası)	72
Tablo 4.6 Model 20'ye ait 2019 yılının gerçek sıcaklık ve tahmin edilen sıcaklık değeri	73
Tablo 4.7 Model 20'ye ait 2020 yılının gerçek sıcaklık ve tahmin edilen sıcaklık değeri	74
Tablo 4.8 Model 20'ye ait 2021 yılının gerçek sıcaklık ve tahmin edilen sıcaklık değeri	74
Tablo 4.9 Model 20'ye ait 2022 yılının gerçek sıcaklık ve tahmin edilen sıcaklık değeri	75
Tablo 4.10 Model 20'ye ait 2023 yılının gerçek sıcaklık ve tahmin edilen sıcaklık değeri	75
Tablo 4.11 Model 21'nin her bir hedef değeri için test seti üzerindeki başarımlarını	85

ŞEKİL LİSTESİ

Şekil 3.1. Yapay zekâ zaman çizelgesi.....	9
Şekil 3.2. Yapay zekâ, makine öğrenmesi ve derin öğrenme yöntemlerinin hiyerarşik sınıflandırması	10
Şekil 3.3. Biyolojik sinir hücresi	14
(Ersoy, 2022).....	14
Şekil 3.4. Biyolojik sinir hücresinin matematiksel modellemesi.....	15
(Ersoy, 2022).....	15
Şekil 3.5. RNN yapısı	19
Şekil 3.6. LSTM ağının mimarisi	20
(Mienye ve ark., 2006).....	20
Şekil 4.4. Model 1 eğitim süreci RMSE ve Loss eğrileri	31
Şekil 4.5. Model 1 gerçek ve tahmin edilen sıcaklık değerlerinin karşılaştırması (Hareketli ortalama uygulanmış)	32
Şekil 4.6. Model 2 eğitim süreci RMSE ve Loss eğrileri	33
Şekil 4.7. Model 2 gerçek ve tahmin edilen sıcaklık değerlerinin karşılaştırması (Hareketli Ortalama Uygulanmış).....	34
Şekil 4.8. Model 3 eğitim süreci RMSE ve Loss eğrileri	35
Modelin Değerlendirilmesi	35
Şekil 4.9. Model 3 gerçek ve tahmin edilen sıcaklık değerlerinin karşılaştırması (Hareketli Ortalama Uygulanmış).....	36
Şekil 4.10. Model 4 eğitim süreci RMSE ve Loss eğrileri	37
Şekil 4.11. Model 4 gerçek ve tahmin edilen sıcaklık değerlerinin karşılaştırması (Hareketli Ortalama Uygulanmış)	38
Şekil 4.12. Model 5 eğitim süreci: RMSE ve Loss eğrileri	39
Şekil 4.13. Model 5 gerçek ve tahmin edilen sıcaklık değerlerinin karşılaştırması (Hareketli Ortalama Uygulanmış)	40
Şekil 4.14. Model 6 eğitim süreci RMSE ve Loss eğrileri	41
Şekil 4.15. Model 6 haftalık gerçek ve tahmin edilen sıcaklık değerlerinin karşılaştırması	42
Şekil 4.16. Model 7 eğitim süreci RMSE ve Loss eğrileri	43
Şekil 4.17. Model 7 haftalık gerçek ve tahmin edilen sıcaklık değerlerinin karşılaştırması	44
Şekil 4.18. Model 8 eğitim süreci RMSE ve Loss eğrileri (Validation dahil)	45
Modelin Değerlendirilmesi	45
Şekil 4.19. Model 8 gerçek ve tahmin edilen haftalık ortalama sıcaklık değerleri.....	46
Şekil 4.20. Model 9 eğitim süreci RMSE ve Loss eğrileri (Validation dâhil)	47
Şekil 4.21. Model 9 gerçek ve tahmin edilen haftalık ortalama sıcaklık değerleri.....	48
Şekil 4.22. Model 10 eğitim süreci RMSE ve Loss eğrileri (Validation dâhil)	49
Şekil 4.23. Model 10 gerçek ve tahmin edilen haftalık ortalama sıcaklık değerleri.....	50
Şekil 4.24. Model 11 eğitim süreci RMSE ve Loss eğrileri (Validation dâhil)	51

<u>Modelin Değerlendirilmesi</u>	51
Şekil 4.25. Model 11 gerçek ve tahmin edilen aylık ortalama sıcaklık değerleri	52
Şekil 4.26. Model 12 eğitim süreci RMSE ve Loss eğrileri (Validation dâhil)	53
Şekil 4.27. Model 12 gerçek ve tahmin edilen aylık ortalama sıcaklık değerleri	54
Şekil 4.28. Model 13 eğitim süreci RMSE ve Loss eğrileri	55
Şekil 4.29. Model 13 gerçek ve tahmin edilen aylık ortalama sıcaklık değerleri	56
Şekil 4.30. Model 14 eğitim süreci RMSE ve Loss eğrileri (Validation: N/A)	57
Şekil 4.31. Model 14 gerçek ve tahmin edilen aylık ortalama sıcaklık değerleri	58
Şekil 4.32. Model 15 eğitim süreci RMSE ve Loss eğrileri (Validation izleme ile)	59
Şekil 4.33. Model 15 gerçek ve tahmin edilen aylık ortalama sıcaklık değerleri	60
Şekil 4.34. Model 16 eğitim süreci RMSE ve Loss eğrileri (Validation: N/A)	61
Şekil 4.35. Model 16 gerçek ve tahmin edilen aylık ortalama sıcaklık değerleri	62
Şekil 4.36. Model 17 eğitim süreci RMSE ve Loss eğrileri (Validation izleme ile)	63
Şekil 4.37. Model 17 gerçek ve tahmin edilen aylık ortalama sıcaklık değerleri	64
Şekil 4.38. Model 18 eğitim süreci RMSE ve Loss eğrileri (Validation: N/A)	65
Şekil 4.39. Model 18 gerçek ve tahmin edilen aylık ortalama sıcaklık değerleri	66
Şekil 4.40. Model 19 eğitim süreci RMSE ve Loss eğrileri (Validation: N/A)	67
Şekil 4.41. Model 19 gerçek ve tahmin edilen aylık ortalama sıcaklık değerleri	68
Şekil 4.42. Model 20 eğitim süreci RMSE ve Loss eğrileri (Validation: N/A)	69
Şekil 4.43. Model 20 gerçek ve tahmin edilen aylık ortalama sıcaklık değerleri	70

KISALTMALAR

Kısaltma	Açıklama
AGI	Artificial General Intelligence (Genel Yapay Zekâ)
AI	Artificial Intelligence (Yapay Zekâ)
ANN	Artificial Neural Network (Yapay Sinir Ağı)
BiLSTM	Bidirectional Long Short-Term Memory (Çift Yönlü LSTM)
CNN	Convolutional Neural Network (Evrışimli Sinir Ağı)
CPU	Central Processing Unit (Merkezi İşlem Birimi)
DL	Deep Learning (Derin Öğrenme)
GAN	Generative Adversarial Networks (Üretici Çekişmeli Ağlar)
GRU	Gated Recurrent Unit (Kapılı Tekrarlayan Birim)
GPU	Graphics Processing Unit (Grafik İşlem Birimi)
LSTM	Long Short-Term Memory (Uzun Kısa Süreli Bellek Ağı)
MAE	Mean Absolute Error (Ortalama Mutlak Hata)
ML	Machine Learning (Makine Öğrenmesi)
MSE	Mean Squared Error (Ortalama Kare Hata)
NLP	Natural Language Processing (Doğal Dil İşleme)
R^2	Coefficient of Determination (Açıklama Katsayısı)
RMSE	Root Mean Squared Error (Kök Ortalama Kare Hata)
RNN	Recurrent Neural Network (Tekrarlayan Sinir Ağı)
Z-score	Standart Skor Normalizasyonu

1. GİRİŞ

1.1. Tezin Amacı ve Önemi

İklim tahmini, insanlık için büyük bir öneme sahiptir. Günümüzde meteoroloji kurumları, radar ve uydu sistemlerinden elde edilen verilerle birlikte hava kütlelerinin hareketlerini doğrudan gözlemleyerek kısa vadeli hava tahminlerini yüksek doğruluk oranlarıyla gerçekleştirebilmektedir. Ancak bireyler ve kurumlar uzun vadeli planlamalar yaparken; afetlere dayanıklı şehirlerin inşası, sürdürülebilir sanayi gelişimi, enerji yönetimi, su kaynaklarının etkin kullanımı gibi stratejik alanlarda karar alırken iklim tahminlerine ihtiyaç duyulmaktadır.

Doğru ve zamanında yapılacak iklim tahminleri birçok sektörde kritik avantajlar sunmaktadır. Tarım sektörü bu alanların başında gelmektedir. Çiftçiler, doğru zamanda ve doğru türde ürün ekimi konusunda daha isabetli kararlar alabilir. Aşırı sıcaklıklar veya don olayları gibi ekstrem hava koşullarının önceden tahmin edilmesi, tarımda kayıpların azaltılmasını sağlar. Ayrıca sıcaklık ve yağış değişkenliğine bağlı bitki hastalıklarının önceden öngörülebilmesi, pestisit kullanımını en aza indirerek çevresel sürdürülebilirliğe katkı sunar.

Benzer şekilde enerji sektörü de iklim tahminlerinden büyük ölçüde yararlanır. Özellikle mevsimsel sapmaların bilinmesi, yazın serinleme ve kışın ısınma için gerekli enerji talebinin öngörülmesini mümkün kılar. Bu öngörüler, yalnızca tüketim tahminleri açısından değil; güneş ve rüzgâr gibi yenilenebilir enerji kaynaklarının planlanmasında da stratejik fayda sağlar. Böylelikle enerji yönetimi için daha doğru eylem planları geliştirilebilir.

Su yönetimi açısından da iklim öngörülerini hayati önem taşır. Aşırı kurak geçmesi muhtemel dönemler önceden tahmin edildiğinde, su kaynaklarının daha verimli kullanılmasına yönelik önlemler alınabilir. Ters durumda, aşırı yağış ve sel riski taşıyan yıllar için taşkınlara karşı altyapı güçlendirmesi gibi önleyici stratejiler geliştirilebilir.

Tüm bu nedenlerle iklim tahmini, yalnızca hava olaylarını öngörmeye yönelik bir faaliyet değil; aynı zamanda sürdürülebilir kalkınma, çevre yönetimi, verimli tarım uygulamaları ve su kaynaklarının korunması gibi pek çok alanda karar destek sistemi olarak işlev görmektedir. Bu çalışma, uzun vadeli sıcaklık tahminleri yapabilen bir modelin geliştirilmesi amacıyla gerçekleştirilmiştir ve bu doğrultuda derin öğrenme tabanlı yöntemlerden faydalanılmıştır.

1.2. Tezin Organizasyonu

Bu tez beş bölümden oluşmaktadır. Birinci bölüm, iklim tahminlerinin toplumsal ve sektörel önemini vurgulayan bir giriş bölümü niteliğindedir. Aynı zamanda çalışmanın amacı, kapsamı ve kullanılan yöntem hakkında genel bir çerçeve sunmaktadır. İkinci bölüm, iklim tahmini, derin öğrenme ve zaman serisi analizi ile ilgili literatürde yer alan çalışmaları inceleyerek araştırmanın kuramsal temelini oluşturmaktadır. Üçüncü bölüm, tezde kullanılmak üzere Meteoroloji müdürlüğünden alınan meteorolojik verileri, veri ön işleme süreçlerini, eksik veri tamamlama stratejilerini detaylı bir şekilde açıklamaktadır. Ayrıca bu bölümde Yapay Zekâ, Makine Öğrenmesi, Derin Öğrenme ve Derin Öğrenme modelleri hakkında bilgiler ve birbiri ile olan ilişkilerinden bahsedilmiştir. Dördüncü bölüm, oluşturulan derin öğrenme modellerini ve bu modellerin eğitim/test performanslarını sistematik bir şekilde sunmaktadır. Model karşılaştırmaları ve başarı ölçütleri bu bölümde ayrıntılı olarak ele alınmaktadır. Beşinci ve son bölüm ise genel bir değerlendirme yapmakta; çalışmanın bulgularını özetlemekte ve öneriler sunmaktadır.

2. KAYNAK TARAMASI

Turgut ve ark. (2019) yaptıkları çalışmada kendi geliştirdikleri bir sistemle 5 gün boyunca rüzgâr hızı ve yön sensörü, nem sensörü, sıcaklık sensörü aracılığıyla anlık olarak bu sensörlerden gelen 48003 adet veriyi veri tabanına kaydetmekte. Ardından kaydettikleri bu veriyi yapay sinir ağı modelleri (YSA), K-Nearest Neighbors (K-NN) ve Random Forest (RF) algoritmaları ile sırası ile %74, %85 ve %87 doğruluk oranı ile tahmin ettiklerini belirtmişlerdir. En doğru tahmini %87 ile RF algoritması ile elde etmişlerdir.

Zhang ve ark. (2020) CRNN (Convolutional Recurrent Neural Network) adını verdikleri bir model geliştirmişlerdir. Bu model, hem Convolutional Neural Networks (CNN) hem de Recurrent Neural Networks (RNN) kullanılmaktadır. Bu sinir ağı, sıcaklık değişiminin hem zamansal hem de mekansal korelasyonlarını tarihsel verilere dayalı olarak öğrenmek için tasarlanmıştır. Çalışmada, Çin anakarası için 1952'den 2018'e kadar olan günlük sıcaklık verileri, önerilen CRNN modelinin performansını değerlendirmek için eğitim verisi olarak kullanılmıştır. Elde edilen sonuçlar, bu modelin sıcaklık tahminlerini yaklaşık olarak 0,907°C'lik bir hata ile gerçekleştirebildiğini göstermektedir.

Sevinç ve ark. (2021) T.C. Meteoroloji Genel Müdürlüğü Meteorolojik Veri Bilgi Sunum ve Satış Sistemi'nden (MEVBİS) alınan 2014-2020 yılları arasındaki hava sıcaklığı verileri kullanılarak Diyarbakır ili için sıcaklık tahmini çalışmışlar. 2271 adet veri ile LSTM ve ARIMA da geliştirdikleri modeli eğitmişler ve RMSE değerlerini sırası ile 1.859 ve 1.946 olarak bulmuşlardır.

Mehr ve ark. (2022) Ankara'nın Nallıhan ve Beypazarı ilçelerine yönelik meteorolojik kuraklık tahmini için CNN-LSTM'den oluşan hibrit bir model geliştirmişler. Geliştirilen modellenin Ankara ilinin iki ilçesine ait üç aylık (SPEI-3) ve altı aylık (SPEI-6) kuraklık tahmin etmek için kullanmışlardır. Geliştirilen modeli diğer istatistiki yöntemler ve genetik programlama ile kıyasladıklarında LSTM-CNN'in diğer yöntemlerden daha doğru sonuçlar verdiğini ortaya koymuşlardır.

Kumaş ve ark. (2020) Antalya ilinin 2000- 2016 yılları arasındaki aylık ortalama buhar basıncı ve aylık ortalama nisbi nem verilerini kullanarak yapay sinir ağları ile aylık ortalama sıcaklık tahmini yapmışlardır. Meteoroloji Genel Müdürlüğünden Alınan verinin %70 eğitim, %15 doğrulama ve %15 test için kullanmışlardır. YSA ile yapılan tahminde Logistic Sigmoid fonksiyonunu kullanmışlar ve en iyi sonucu LM11 algoritmasında elde etmişlerdir. Yapılan çalışmadaki sonuçlara göre tüm değerler 0,990'dan büyük görünmekte. Değerlerin 1'e yakın olmasıyla YSA modeli ile gerçek değerlerin çok fazla benzerlik gösterdiğini görmekteyiz.

Suleman ve ark. (2022) iklim değişikliğini tespit etmek için önemli bir gösterge olan yüzey sıcaklığının tahmin edilmesine yönelik bir derin öğrenme modeli olan "Uzamsal

Özellik Dikkati Uzun Kısa Süreli Bellek (SFA-LSTM)" modelini öneriyor. Bu model, birden fazla meteorolojik özelliğin uzamsal ve zamansal ilişkilerini doğru bir şekilde yakalayarak sıcaklık tahmini yapmayı amaçlıyor. SFA-LSTM modeli, geçmiş verilerden elde edilen önemli uzamsal ve zamansal bilgileri kullanarak tahminler yapıyor. Model, encoder-decoder mimarisi ile inşa edilmiştir; burada LSTM katmanları, verilerdeki zamansal bağımlılıkları öğrenirken, uzamsal özellik ilişkileri decoder aşamasında ele alınıyor. SFA-LSTM, en önemli zaman dilimlerini ve hava değişkenlerini öğrenerek sıcaklık tahmini yapıyor. Ayrıca, modelin doğruluğu, gözlemlenen verilerle karşılaştırıldığında mevcut modellerle kıyaslandığında en yüksek seviyede kalmakta ve uzamsal özelliklerin yorumlanabilirliğini artırmaktadır.

Özkaya S. ve ark (2022) hava durumu tahmini amacıyla yapay sinir ağları (YSA) kullanarak geliştirilen bir çok katmanlı algılayıcı (ÇKA) modelinin LabVIEW yazılımı içerisinde uygulamasını incelemektedir. Çalışmada, Türkiye'nin Konya iline ait 45 günlük meteorolojik veriler (nem, basınç, sıcaklık, çiğ noktası ve görüş mesafesi) kullanılarak sinir ağı eğitimi gerçekleştirilmiş ve modelin tahmin performansı değerlendirilmiştir. Geliştirilen LabVIEW arayüzü sinir ağı parametrelerinin (nöron sayısı, öğrenme katsayısı, momentum ve başlangıç ağırlıkları) esnek bir şekilde ayarlanmasına olanak tanımaktadır. Elde edilen sonuçlar doğrultusunda, modelin tahmin başarı oranı %73,33 olarak belirlenmiştir. Bu bulgular, yapay sinir ağlarının hava durumu tahmini gibi karmaşık problemlerde etkili bir çözüm aracı olarak kullanılabileceğini göstermektedir.

Cebeci (2019) çalışmasında İstanbul Balabanaga İstasyonu'ndan alınan 2017 yılına ait saatlik meteorolojik veriler kullanılmıştır. Veriler, bulutluluk oranı, çiy noktası, nem, basınç, rüzgar yönü ve sıcaklık gibi özellikleri içermektedir. Ön işleme aşamasında One Hot Encoding ve min-max normalizasyonu uygulanmış, ardından Recursive Feature Elimination ile veri boyutu azaltılarak Çok Katmanlı Algılayıcılar ile eğitim gerçekleştirmiştir. Derin öğrenme yöntemleri arasında Long Short-Term Memory (LSTM) ve Gated Recurrent Unit (GRU) gibi modeller kullanmıştır. Cebeci'nin yaptığı çalışmada LSTM, geri yayılım sırasında daha iyi sonuçlar verirken, GRU da benzer bir mekanizmaya sahiptir. Modelleme sürecinde, ilk olarak Auto Regressive Moving Average (ARMA) kullanmış, ancak lineer sonuçlar vermesi nedeniyle en düşük performansı göstermiştir. Support Vector Regression (SVR) hem çok boyutlu hem de tek boyutlu veri setlerinde daha iyi sonuçlar elde etmiştir. Çok Katmanlı Algılayıcılar, tek boyutlu veri setinde SVR'den daha başarılı olmuştur. Stacked Denoising AutoEncoders ile hata azaltımı sağlamıştır. Cebeci çalışmasında, LSTM modeli çok boyutlu veri setinde en iyi sonuçları verirken, tek boyutlu veri setinde Recursive Feature Elimination ile başarı artırmıştır. Modellerin sonuçlarını, belirli ağırlıklarla birleştirerek hava durumu tahminleri yapmış ve hata oranı 0.6'nın altına düşürmüştür.

Hayati ve ark. (2007), İran'ın batısındaki Kermanshah kenti için sıcaklık tahmini yapmak amacıyla çok katmanlı algılayıcıya (Multi-Layered Perceptron) dayalı yapay sinir ağlarını incelediler. 1996-2006 yıllarına ait meteorolojik verileri eğitim ve test aşamalarında

kullanarak, ağın minimum hata ile çalıştığını ve kısa vadeli sıcaklık tahminleri için uygun bir yöntem olduğunu belirlediler. Diğer bir çalışmada, Dombayci ve Gölçü (2009), Denizli'nin günlük ortalama sıcaklığını tahmin etmek için bir Yapay Sinir Ağı (YSA) modeli geliştirdiler. Bu çalışmada, Devlet Meteoroloji Müdürlüğü'ne ait 2003-2005 yılları verilerini eğitim verisi olarak ve 2006 yılı verilerini test verisi olarak kullandılar. Farklı algoritmalar ve nöron sayıları deneyerek, ağın performansını korelasyon (R^2) ve Kök Ortalama Kare Hata (RMSE) değerleri üzerinden değerlendirdiler ve YSA yaklaşımının sıcaklık tahmininde güvenilir bir yöntem olduğunu vurguladılar.

Bilgili ve ark. (2009) Türkiye'nin herhangi bir noktasındaki ölçüm istasyonlarına dayalı olarak uzun vadeli aylık sıcaklık ve yağış miktarı tahmini yapmak amacıyla bir Yapay Sinir Ağı (YSA) modeli geliştirmişlerdir. Modelin eğitimi için Devlet Meteoroloji Müdürlüğü'nün 1975-2006 yılları arasındaki 59 istasyon verisini kullanmışlar ve modelin performansını değerlendirmek için 17 istasyon verisini test verisi olarak kullanmışlardır. Oluşturdukları YSA modeli, enlem, boylam, yükseklik ve zaman gibi giriş parametrelerini kullanarak uzun vadeli hava sıcaklığı ve yağış miktarını tahmin etmektedir. Gerçek değerlerle modelin tahmin sonuçlarını karşılaştırmışlar ve modelin hatalarının kabul edilebilir düzeyde olduğunu belirtmişlerdir.

Bu kapsamlı literatür incelendiğinde, pek çok çalışmanın belirli bir coğrafi bölge, kısa süreli veri setleri veya tek bir yapay zekâ mimarisi üzerinden gerçekleştirildiği görülmektedir. Ayrıca, zaman ölçekleri çoğunlukla günlük veya aylık tahminlerle sınırlı kalmış, çoklu ölçekli bir yaklaşım sistematik olarak ele alınmamıştır. Bu tez çalışması, 28 yıllık uzun dönemli meteorolojik verilerden yararlanarak Tokat ili için günlük, haftalık ve aylık sıcaklık tahminlerini derin öğrenme yöntemleriyle kapsamlı biçimde incelemesiyle literatüre katkı sunmaktadır. Çalışmada farklı mimariler (LSTM, GRU, BiLSTM) karşılaştırmalı olarak değerlendirilmiş, ayrıca veri doluluk oranlarına dayalı esnek bir ön işleme yöntemi uygulanmıştır. Bu yönüyle çalışma, hem çok ölçekli tahmin yaklaşımı hem de mimari çeşitliliği birlikte ele almasıyla literatürdeki benzer araştırmalardan ayrılmakta ve iklim tahminleri için daha bütüncül bir yöntemsel çerçeve önermektedir.

3. MATERYAL ve METODLAR

Bu bölümde yapay zekâ ve makine öğrenmesi yöntemlerinin teorik temelleri ile çalışmada kullanılan meteorolojik veri seti ele alınacaktır.

3.1.Yapay Zekâ

Günümüz yaşamında bilgisayarlar ve bilgisayar sistemleri hayatın vazgeçilmez bir parçası haline gelmiştir. Elimizdeki cep telefonlarından, kullandığımız arabalardan, mutfakta kullandığımız birçok elektronik eşya bilgisayar sistemleri ile çalışmaktadır. İş dünyasından kamu işlerine, çevre ve sağlık organizasyonlarından askeri sistemlere kadar hemen hemen her alanda bilgisayarlardan faydalanılmak olağan hale gelmiştir. Bunun aksini bile düşünmek teknolojinin nimetlerini hiçe saymak olarak görülmektedir. Teknolojinin gelişmesi izlendiğinde önceleri sadece elektronik veri transferi yapmak ve karmaşık hesaplamaları gerçekleştirme üzere geliştirilen bilgisayarların zaman içerisinde büyük miktarlardaki verileri filtreleyerek özetleyebilen ve mevcut bilgileri kullanarak olaylar hakkında yorumlar yapabilen nitelikler kazandığı görülmektedir. Günümüzde ise bilgisayarlar hem olaylar hakkında karar verebilmekte hem de olaylar arasındaki ilişkileri öğrenebilmektedir. Matematiksel olarak formülasyonu kurulamayan ve çözülmesi mümkün olmayan problemler sezgisel yöntemler yolu ile bilgisayarlar tarafından çözülebilmektedir. Bilgisayarı bu özelliklerle donatan ve yeteneklerinin gelişmesini sağlayan çalışmalar “yapay zekâ çalışmaları” olarak bilinmektedir.

Yapay zekânın tarihi Alan Turing ile başladı diyebiliriz. Alan Turing “Makineler düşünebilir mi?” sorusu yapay zekâ sürecinin başlangıcı sayılabilir. Daha sonrasında 1956 yılındaki Dartmouth Yapay Zekâ Yaz Araştırma Projesi yapay zekânın kurucu olayı kabul edilir (Lewis, 2014). Bu dönemdeki yapay zekâ araştırmaları daha çok mantıksal akıl yürütme, oyun teorisi ve dil işleme gibi alanlarda olmuştur. 1960’ların sonlarına doğru gelindiğinde, yapay zekâ alanında kaydedilen ilerlemeler hem araştırmacılar hem de kamuoyu tarafından büyük bir ilgiyle karşılandı. Ancak beklentiler hızla yükselirken, teknolojik sınırlamalar nedeniyle ilerleme yavaşladı. Fonların kesilmesi ve toplumun ilgisinin azalması, araştırmaların yavaşlamasına neden olmuştur. Yapay zekâ kışı olarak adlandırılan duraklama dönemine girilmiş oldu. Bununla birlikte, bu dönem aynı zamanda yapay zekâ araştırmalarına daha odaklanmış bir yaklaşıma yol açarak gelecekteki ilerlemeler için zemin hazırlamış aynı zamanda düşünce ve yaratıcılık gibi insan zihninin doğasına dair daha derin sorgulamaların doğmasına sebep olmuştur (Elamin, 2024).

Yapay Zekâ ilk Kışı’nın ardından 1980’lerde yeni bir yaklaşım olan uzman sistemler devreye girdi. Uzman sistemler, daha çok tıp ve mühendislik başta olmak üzere belirli bir

alanın uzmanlarının bilgilerini kural tabanlı sistemlere aktarmaya dayanıyordu. Bu sistemler, uzmanların bilgilerinden türetilen geniş bir kurallar kümesi kullanarak insan uzmanlığını simüle etmek için tasarlanmıştır. Örneğin, tıp alanında geliştirilen MYCIN, bulaşıcı hastalıkları teşhis ve tedavi etmekte kullanıldı (Buchanan ve Shortliffe, 1984). Bu sistemler, insan uzmanların bilgi birikimini bilgisayarlara aktarma fikrini hayata geçirerek, yapay zekânın pratikte uygulanabilirliğini göstermiştir. Uzman sistemlerin başarısı sayesinde sanayi, sağlık ve finans gibi sektörlerde yapay zekâ uygulamalarına olan ilgi yeniden canlandı. Bütün bunlarla beraber uzman sistemler ölçeklenebilirlik, esnek olmama ve yeni verilerden öğrenmeme gibi çeşitli zorluklarla karşılaştı

1980'lerin sonlarına doğru yapay zekâ alanında yeni gelişmeler yaşanmaya başladı. Bu gelişmelerin çoğu veri işleme kapasitelerindeki artış, algoritmaların iyileştirilmesi ve bilgisayar donanımlarındaki gelişmeler sayesinde mümkün oldu. 1997 de IBM'in geliştirdiği Deep Blue adlı bilgisayar dünya satranç şampiyonu Gary Kasparov'u yenerek büyük bir dönüm noktasına imza attı. Bu gelişme, yapay zekâ sistemlerinin karmaşık ve dinamik ortamlarda etkili sonuçlar üretebileceğini ortaya koymuştur. Aynı dönemde internetin yaygınlaşması ve büyük veri kavramının ortaya çıkması Yapay zekâ araştırmalarına yeni bir ivme kazandırdı.

2000'lerin başında yapay zekâ büyük bir yeniden doğuş sürecine girdi. Bu hızlanış bir dizi temel faktörün bir araya gelmesi ile mümkün oldu. İnternetin yaygınlaşması ile birlikte her gün devasa büyüklükte veri setleri oluşmaya başladı. Bu devasa veri havuzları makinelerin öğrenme kapasitelerini arttırdı ve daha karmaşık algoritmaların geliştirilmesine zemin hazırladı. 2000'li yılların başında, veri analizi ve işleme gücündeki ilerlemeler, yapay zekâ uygulamalarının daha etkili bir şekilde işlemeyi öğrenebilmesini sağladı. Örneğin, büyük verinin yanı sıra, paralel işleme kapasitesine sahip grafik işleme birimleri (GPU'lar) gibi donanımlar, derin öğrenme algoritmalarının uygulanmasında devrim yarattı.

2010'lar Yapay zekânın altın çağı olarak kabul edilebilir. Bu dönemde derin öğrenme, makine öğrenimi ve doğal dil işleme gibi alanlarda büyük ilerlemeler kaydedildi. 2012'de AlexNet adlı derin öğrenme modeli görsel tanıma yarışmasında çığır açan sonuçlar elde etti ve bu derin öğrenmeye olan ilginin kat kat artmasını sağladı. Aynı dönemde Google, Facebook ve Amazon gibi teknoloji devleri yapay zekâ teknolojilerini ürünlerine entegre etmeye başladı. 2016'da Google Deepmind'ın Alpha Go programı yıllarca en karmaşık bilgisayar programlarının bile erişemeyeceği bir oyun olarak kabul edilen Go oyununun dünya şampiyonu Güney Koreli sporcu Lee Se-dol'u yenerek başka bir tarihi başarıya imza attı. Bu sonuç, yapay zekâ sistemlerinin stratejik karar verme gerektiren karmaşık oyunlarda dahi insan performansını aşabildiğini göstermiştir. 2018 yılında doğal dil işleme (NLP) alanında önemli bir sıçrama yaşanmıştır. Google tarafından geliştirilen BERT (Bidirectional Encoder Representations from Transformers) modeli, dil anlama görevlerinde insan seviyesine yaklaşan performans sergilemiştir. BERT'in iki yönlü dikkat mekanizması sayesinde, metindeki bağlam daha derinlemesine kavranabilmiş ve


bu, metin sınıflandırma, soru-cevap sistemleri ve duygu analizi gibi birçok NLP uygulamasında yeni standartları belirlemiştir (Devlin ve ark., 2019). Yapay zekânın üretici (generative) modelleri de 2014 sonrası hızlı bir şekilde ilerlemiştir. Özellikle Generative Adversarial Networks (GANs) kullanılarak, fotoğraf gerçekçiliğinde görüntüler, sesler ve hatta video içerikler üretmek mümkün hale gelmiştir. GAN'ların geliştirilmesiyle, yalnızca var olan verileri analiz eden değil, aynı zamanda yeni ve yaratıcı içerikler de üretebilen yapay zekâ sistemleri ortaya çıkmıştır (Goodfellow ve ark., 2014).


2020'li yıllara gelindiğinde, büyük dil modelleri (Large Language Models, LLMs) öne çıkmıştır. OpenAI tarafından geliştirilen GPT-3 modeli, 175 milyar parametresiyle, önceki modellerden çok daha geniş bir bilgi ve dil üretim kapasitesine sahip olmuştur. GPT-3, makale yazma, şiir oluşturma, program kodu üretme gibi karmaşık dil görevlerinde etkileyici sonuçlar ortaya koymuş ve genel amaçlı yapay zekâ (AGI) tartışmalarını yeniden alevlendirmiştir (Brown ve ark., 2020).

2021 yılında OpenAI tarafından duyurulan Codex modeli, yapay zekânın programlama yeteneklerinde yeni bir sayfa açmıştır. GitHub Copilot gibi uygulamalarda kullanılan Codex, doğal dilde verilen komutları yazılım koduna dönüştürebilmiş ve yazılımcıların üretkenliğini önemli ölçüde artırmıştır (Chen ve ark., 2021). Bu gelişme, yapay zekânın yalnızca veriyi işleyen değil, aynı zamanda yeni araçlar geliştiren bir teknoloji haline gelmesinin önünü açmıştır (Pearce ve ark., 2022). 2022 yılında, OpenAI'nin geliştirdiği ChatGPT ve DALL•E 2 modelleri geniş kitlelerle buluşmuş ve yapay zekânın toplumun her kesimine ulaşmasını sağlamıştır. ChatGPT, kullanıcılarla doğal diyaloglar kurabilen bir sohbet modeli olarak dil işleme alanında yeni bir standart belirlerken; DALL•E 2, verilen metinsel açıklamalardan özgün görseller üreterek yapay zekânın yaratıcı kapasitelerini gözler önüne sermiştir (OpenAI, 2022a; OpenAI, 2022b). Bu modeller, eğitimden sanata, müşteri hizmetlerinden içerik üretimine kadar pek çok alanda yaygın şekilde kullanılmaya başlanmıştır (Bommasani ve ark., 2022).

2024 yılında çok modlu modellerde (multimodal AI) büyük ilerlemeler kaydedilmiştir. OpenAI tarafından tanıtılan GPT-4 ve Google DeepMind tarafından geliştirilen Gemini gibi modeller, yalnızca metni değil; görsel, ses ve video verilerini de anlayabilmekte ve çapraz modalite analizleri yapabilmektedir (OpenAI, 2024; Google DeepMind, 2024). Bu gelişme sayesinde yapay zekâ, daha bütüncül anlayışa sahip sistemler geliştirerek karmaşık görevleri yerine getirebilecek yetkinliğe ulaşmıştır (Li ve ark., 2024). 2025 yılına geldiğimizde, yapay zekâ sistemleri daha özerk ve özelleştirilmiş hale gelmiştir. Özellikle küçük ve verimli modellerin (small language models) geliştirilmesiyle, cihaz üzerinde çalışan yapay zekâ çözümleri yaygınlaşmıştır (Zhang ve ark., 2025). Bu durum, veri gizliliği, düşük enerji tüketimi ve daha hızlı işlem süreleri açısından önemli avantajlar sunmuş, yapay zekânın kenar bilişim (edge computing) ortamlarında da etkin bir şekilde kullanılmasını sağlamıştır (Wang ve ark., 2025). Aynı dönemde kuantum bilgisayarlar ile yapay zekânın birleşimi üzerine yürütülen çalışmalar da hız kazanmıştır

Yapay zekânın tarihsel gelişimine ilişkin bir zaman çizelgesi Şekil 3.1'de sunulmaktadır. Şekil 3.2 ise yapay zekâ, makine öğrenmesi ve derin öğrenme arasındaki hiyerarşik ilişkiyi şematize etmektedir.





Şekil 3.2. Yapay zekâ, makine öğrenmesi ve derin öğrenme yöntemlerinin hiyerarşik sınıflandırması

3.2.Makine Öğrenimi

Makine öğrenmesi, bilgisayar bilimleri ve istatistik alanlarının kesişiminde yer alan bir disiplin olup, makinelerin belirli görevleri yerine getirmek için deneyimden öğrenmesine olanak tanır. Makine öğrenimi bilgisayar sistemlerinin açık bir şekilde programlanmaksızın deneyim yoluyla öğrenmesini sağlayan bir yapay zekâ alt dalıdır. Bu teknoloji, belirli bir görevi yerine getirmek için sistemin geçmiş verilerden kalıpları tanımasını ve bu kalıpları gelecekteki kararlarında kullanmasını mümkün kılar. Alanın temelleri 1950’li yıllara dayansa da, istatistik, bilişim gücü ve büyük veri alanlarındaki gelişmeler sayesinde özellikle 2000’li yıllardan sonra önemli ilerlemeler kaydedilmiştir (Jordan ve Mitchell, 2015). Bu teknoloji, denetimli ve denetimsiz öğrenme gibi alt alanları içerir; denetimli öğrenmede sistem, etiketlenmiş verilerle eğitilirken, denetimsiz öğrenmede ise sistem, etiketsiz verilerden örüntüleri tanımaya çalışır. Makine öğrenmesi uygulamaları her sektörde sağlam bir temel oluşturarak, sağlık, finans, otomotiv ve e-ticaret gibi alanlarda devrim niteliğinde gelişmelere yol açmıştır. Örneğin makine öğrenmesi sayesinde, sağlık verilerinden hastalık tahminleri yapılabilmekte ve finansal sistemlerde dolandırıcılık tespiti daha etkili hale getirilebilmektedir. Ayrıca, derin öğrenme gibi daha gelişmiş makine öğrenme teknikleri, büyük veri setleri üzerinde karmaşık özellikler ve ilişkiler tanımlama yeteneğiyle dikkat çekmektedir. Genel olarak, makine öğrenmesi, veri odaklı karar verme süreçlerini iyileştirerek insan hayatının birçok yönünü dönüştürme potansiyeline sahiptir.

3.2.1. Denetimli öğrenme

Denetimli öğrenme, her örnek veriye karşılık gelen bir hedef ya da etiketin (label) bulunduğu veri kümeleri ile eğitilen modelleri ifade eder. Modelin amacı, bu etiketli verilerden öğrenerek daha önce görülmemiş örnekler üzerinde doğru tahminlerde bulunabilmektir. Bu tür algoritmalarda giriş-çıkış ilişkisi matematiksel olarak modellenir. Denetimli öğrenme, regresyon ve sınıflandırma olmak üzere iki ana alt kategoriye ayrılır. Regresyon problemleri sayısal sonuçları tahmin ederken (örneğin: ev fiyatı tahmini), sınıflandırma problemleri verileri belirli kategorilere ayırır (örneğin: e-postaların spam olup olmadığını belirleme).

Bu yöntemlerde sıkça kullanılan algoritmalar arasında doğrusal regresyon, karar ağaçları, destek vektör makineleri (SVM), k-en yakın komşu (k-NN) ve yapay sinir ağları bulunmaktadır. Etiketli veri gereksinimi, bu yöntemin temel kısıtlarından biridir; zira etiketleme işlemi zaman alıcı ve maliyetli olabilir (Bishop, 2006).

3.2.2. Denetimsiz öğrenme

Denetimsiz öğrenme, yalnızca giriş verisinin mevcut olduğu, yani verilerin etiketlenmediği durumlar için geliştirilmiş bir öğrenme yöntemidir. Bu model türü, veri içerisindeki gizli yapıları, benzerlikleri, grupları ya da dağılımı öğrenmeye çalışır. En yaygın kullanım alanı kümeleme (clustering) ve boyut indirgeme (dimensionality reduction) işlemleridir.

Kümeleme algoritmaları (örneğin: K-means, DBSCAN, hiyerarşik kümeleme), benzer özelliklere sahip verileri gruplar. Bu teknikler, pazarlama alanında müşteri segmentasyonu, biyoinformatikte gen ifade analizi ya da sosyal ağ analizlerinde sıkça kullanılır. Boyut indirgeme teknikleri ise (örneğin: PCA - Principal Component Analysis, t-SNE) özellikle yüksek boyutlu veri setlerinin daha anlamlı biçimde görselleştirilmesi ve analiz edilebilir hale getirilmesi amacıyla kullanılır (Hastie ve ark., 2009).

3.2.3. Pekiştirmeli öğrenme

Pekiştirmeli öğrenme, bir ajanın (agent), bir ortam (environment) içinde çeşitli eylemler (actions) gerçekleştirerek ödül (reward) sinyalleri aracılığıyla öğrenmesini temel alan bir öğrenme paradigmasıdır. Bu yöntem, öğrenme sürecinin deneme-yanılma yoluyla gerçekleştiği ve amacın uzun vadede maksimum ödül elde etmek olduğu senaryolarda kullanılır.

Ajan, eylemlerinin sonucunda ortamdan bir ödül ya da ceza alır ve bu geri bildirimlere dayanarak politikalarını (policy) günceller. Pekiştirmeli öğrenme, Markov Karar Süreçleri (MDP) gibi matematiksel temellere dayanır. Bu yöntem, oyun teorisi, robot kontrolü, trafik sinyal optimizasyonu, portföy yönetimi ve özellikle son yıllarda AlphaGo ve OpenAI Five gibi stratejik oyun oynayan yapay zekâ sistemlerinde çığır açıcı başarılar sağlamıştır (Sutton, Barto, 2018).

3.3. Derin Öğrenme

Derin öğrenme (deep learning), makine öğrenmesinin bir alt dalı olarak, çok katmanlı yapay sinir ağları aracılığıyla verilen özellik çıkarımı ve öğrenme süreçlerini otomatikleştiren bir yöntemdir. Yapay sinir ağları, bilgiyi işleyen birbirine bağlı düğümlerden veya nöronlardan oluşur. Derin öğrenme, bu kavramı, birden fazla katmana sahip derin sinir ağlarını kullanarak genişletir ve karmaşık ilişkileri modellemelerini ve verilerden üst düzey özellikler çıkarmalarını sağlar.

Geleneksel makine öğrenmesi yöntemleri, verilerden anlamlı özelliklerin çıkarılması için büyük ölçüde insan mühendisliğine ihtiyaç duyar. Örneğin, bir görüntü sınıflandırma problemi için uzmanlar, kenar algılama veya renk histogramları gibi belirli özellikleri manuel olarak tasarlamak zorundadır. Bu süreç hem zaman alıcıdır hem de uzmanlık gerektirir bu durum makine öğrenmesinin ham veriyi doğrudan işleyememesine ve ön işlem adımlarına bağımlı kalmasına neden olur.

Buna karşılık derin öğrenme, özellik çıkarım sürecini tamamen otomatikleştirir. Evrişimli Sinir Ağları (ESA) gibi derin öğrenme modelleri, ham veriyi (örneğin piksel değerlerini) doğrudan alır ve katmanlar arasında hiyerarşik bir şekilde işler. İlk katmanlar kenar ve doku gibi basit özellikleri öğrenirken, derin katmanlar nesne parçaları veya bütünsel yapılar gibi daha karmaşık özellikleri keşfeder, bu hiyerarşik öğrenme sayesinde derin modeller, uzman müdahalesi olmadan verinin doğal yapısını anlamlandırabilir. Bu yetenek, özellikle görüntü, ses ve metin gibi yapılandırılmamış verilerde devrim niteliğinde başarılar sağlamıştır (İnik ve Ülker, 2017).

Derin öğrenme, tıbbi görüntüleme ve teşhis sistemlerinde önemli bir rol oynamaktadır. Örneğin, manyetik rezonans görüntüleme (MRI), bilgisayarlı tomografi (CT) ve röntgen gibi görüntülerin analizinde evrişimli sinir ağları (CNN'ler) kullanılarak tümör tespiti, anomali belirleme ve hastalık teşhisi yapılabilmektedir (Litjens ve ark., 2017). Ayrıca, elektronik sağlık kayıtlarının (EHR) analizinde tekrarlayan sinir ağları (RNN'ler) ve uzun-kısa vadeli bellek (LSTM) modelleri, hastalık ilerlemesinin tahmin edilmesi ve kişiselleştirilmiş tedavi planlarının oluşturulması için kullanılmaktadır (Miotto ve ark., 2016). Derin öğrenme, özellikle otonom sürüş teknolojilerinde kritik bir bileşendir. Derin sinir ağları, araçların çevrelerini algılaması, yayaları ve diğer araçları tanıması, trafik işaretlerini yorumlaması ve güvenli rotalar planlaması için kullanılmaktadır (Bojarski ve ark., 2016). Benzer şekilde, endüstriyel robotlar, derin pekiştirmeli öğrenme (deep reinforcement learning) yöntemleriyle karmaşık montaj ve taşıma görevlerini öğrenebilmektedir (Levine ve ark., 2016).

Derin öğrenme, dil modelleri ve konuşma işleme sistemlerinde büyük atılımlar sağlamıştır. Transformer tabanlı modeller (örneğin, BERT, GPT, T5), metin çevirisi, duygu analizi, soru-cevap sistemleri ve otomatik özetleme gibi görevlerde insan seviyesine yakın performans göstermektedir (Devlin ve ark., 2019). Ses tanıma sistemleri (örneğin, Siri, Alexa) ise derin öğrenme sayesinde daha yüksek doğrulukla çalışabilmekte ve farklı aksanları daha iyi anlayabilmektedir (Amodei ve ark., 2016). Finansal piyasalarda derin öğrenme, hisse senedi fiyat tahmini, risk analizi ve dolandırıcılık tespiti gibi alanlarda kullanılmaktadır. Örneğin, zaman serisi analizinde LSTM ağları, piyasa trendlerini tahmin etmek için yaygın olarak uygulanmaktadır (Fischer ve Krauss, 2018). Ayrıca, kredi skorlama sistemleri ve anormal işlem tespiti gibi alanlarda derin öğrenme modelleri, geleneksel istatistiksel yöntemlere kıyasla daha yüksek başarı oranları sunmaktadır (West ve Bhattacharya, 2016).


3.3.1. Yapay sinir ağıları

Derin Öğrenme bir yapay sinir ağıının çok sayıda gizli katmana sahip olduğu durumları ifade eder. Bu yüzden derin kelimesi kullanılmıştır. Yapay sinir ağıları ise beyindeki nöronlardan esinlenerek geliştirilmiş matematiksel modellerdir.

Biyolojik nöronlar, vücuttaki bilgiyi elektriksel ve kimyasal yollarla işleyen özelleşmiş hücrelerdir. Şekil 3.3. de yapısı verilen biyolojik sinir hücresinin temel bileşenleri şunlardır:

- Dendritler: Diğer nöronlardan gelen sinyalleri toplar.
- Hücre gövdesi (soma): Toplanan sinyalleri entegre eder.
- Akson: İşlenen sinyali diğer nöronlara iletir.
- Sinapslar: Nöronlar arasındaki bağlantı noktalarıdır.


Biyolojik nöronlar, belirli bir eşik değeri aşan sinyaller aldıklarında aksiyon potansiyeli oluşturur ve bu sinyali akson boyunca iletirler (Kandel ve ark., 2000). Öğrenme süreci ise sinaptik plastisite prensibine dayanır. Özellikle "Hebb Kuralı" ("Birlikte ateşleyen nöronlar, bağ kurar") biyolojik öğrenmenin temel taşıdır (Hebb, 1949).



Şekil 3.3. Biyolojik sinir hücresi

(Ersoy, 2022)

Aşağıda Şekil 3.4'te biyolojik sinir hücresinin matematiksel modellemesi yer almaktadır.



Şekil 3.4. Biyolojik sinir hücresinin matematiksel modellemesi

(Ersoy, 2022)

Yapay nöronlar, biyolojik nöronların basitleştirilmiş matematiksel modelleridir. Bir yapay nöronun temel işlevi, giriş sinyallerini ağırlıkları ile çarparak toplamak ve bu toplamı bir aktivasyon fonksiyonuna sokarak çıktı üretmektir.

$$y = f \left(\sum_{i=1}^n w_i x_i + b \right) \quad (1)$$

Burada x_i giriş değerleri, w_i ağırlıklar, b bias terimi ve f aktivasyon fonksiyonudur (Goodfellow ve ark., 2016).

Beyinde öğrenme, sinapslar arasındaki bağ kuvvetlerinin zamana ve deneyime bağlı olarak değişmesiyle gerçekleşir. Bu değişimler, öğrenmenin kalıcılığını ve adaptasyonunu sağlar (Gerstner ve Kistler, 2002). Uzun Süreli Potansiyasyon (LTP) ve Uzun Süreli Depresyon (LTD) gibi biyolojik mekanizmalar, sinaptik ağırlıkların güçlenmesi ya da zayıflamasıyla öğrenmeyi düzenler.

3.3.2. Evrişimli sınır ağları (CNN - Convolutional Neural Networks)

Evrişimli Sinir Ağları (Convolutional Neural Networks – CNN), özellikle görüntü işleme, nesne tanıma ve sınıflandırma gibi görevlerde yüksek başarı sağlayan derin öğrenme mimarileridir. Geleneksel çok katmanlı algılayıcılardan (MLP) farklı olarak CNN’ler, verilerdeki mekânsal yapıyı koruyarak yerel öznitelikleri doğrudan öğrenebilir. Bu

özelliği sayesinde, parametre sayısını azaltarak hem hesaplama verimliliği sağlar hem de genelleme kabiliyetini artırır. CNN'lerin başarısı, katmanlar arası hiyerarşik bilgi işleme yapısından kaynaklanmaktadır. (LeCun Y ve ark., 2015 ; İnik, Ö. 2020)

Girdi Katmanı

Girdi katmanı, CNN'in ilk bileşenidir ve dış ortamdan gelen ham veriyi ağına içine alır. Görüntü işleme uygulamalarında bu veri genellikle yükseklik, genişlik ve kanal sayısı (RGB) ile temsil edilen üç boyutlu bir matris şeklindedir (Goodfellow ve ark., 2016, s. 327). Girdi katmanında öğrenme işlemi gerçekleşmez; veriler doğrudan evrişim katmanına aktarılır (İnik, 2020, s. 87).

Evrişim Katmanı (Convolutional Layer)

Evrişim katmanı, CNN'in en temel yapı taşıdır. Bu katmanda, görüntü üzerinde kayan sabit boyutlu çekirdekler (kernel ya da filtreler) kullanılarak yerel özellikler çıkarılır. Her filtre görüntü üzerinde dolaşarak belirli bir özniteliği (kenar, doku, renk gradyanı vb.) tespit etmeye çalışır. Filtre ile görüntü arasındaki çarpma işlemi sonucunda bir özellik haritası (feature map) elde edilir. Birden fazla filtre kullanılarak, aynı görüntüden farklı özellikler aynı anda öğrenilebilir. (Gu, J ve ark., 2018).

Aktivasyon Fonksiyonu Katmanı (ReLU)

Evrişim katmanından sonra genellikle doğrultulmuş lineer birim (ReLU) gibi bir aktivasyon fonksiyonu uygulanır. ReLU fonksiyonu negatif değerleri sıfıra eşitleyerek doğrusal olmayanlık kazandırır ve modelin karmaşık örüntüleri öğrenmesini kolaylaştırır. Bu katman, evrişim sonucu elde edilen özellik haritasına uygulanır ve doğrusal olmayan örüntüleri tanımlamada büyük rol oynar. (Nair, V., ve Hinton, G. E., 2010).

Havuzlama Katmanı (Pooling Layer)

Havuzlama katmanı, evrişim ve aktivasyon işlemleri sonrasında elde edilen özellik haritalarının boyutunu küçültmek ve modelin hesaplama yükünü azaltmak amacıyla kullanılır. En yaygın kullanılan yöntem maksimum havuzlama (max pooling) olup, belirli bir bölgedeki en büyük değeri seçerek öznitelikleri yoğunlaştırır. Bu katman, aynı zamanda küçük uzamsal kaymalara karşı modelin dayanıklılığını artırır. (Sermanet, P ve ark., (2013).

Tam Bağlantılı Katman (Fully Connected Layer)

CNN'in son kısmında yer alan tam bağlantılı (fully connected) katmanlar, evrişim ve havuzlama katmanlarından elde edilen öznitelikleri düzleştirir (flatten) ve sınıflandırma görevini yerine getirir. Bu katman klasik yapay sinir ağına benzer şekilde çalışır ve tüm nöronlar birbirine bağlanır. Genellikle bu katmanın sonunda softmax aktivasyonu ile çıktı sınıfları arasında olasılık dağılımı hesaplanır. (Krizhevsky, A., ve ark. 2012)

Dropout ve Normalizasyon Katmanları (Opsiyonel)

Bazı CNN mimarilerinde, aşırı öğrenmeyi (overfitting) önlemek amacıyla dropout ve batch normalization gibi teknik katmanlar da yer alır. Dropout, eğitim sırasında rastgele nöronları devre dışı bırakarak öğrenme sürecinde genelleme kapasitesini artırır. Batch normalization ise verinin dağılımını dengeleyerek eğitim süresini kısaltır ve daha kararlı bir öğrenme sağlar. (Srivastava ve ark., 2014)

Evrişimli Sinir Ağları, derin öğrenmenin görsel veriler üzerindeki en güçlü temsilcilerinden biridir. Her bir katman, veri üzerinden anlamlı öznitelikler çıkararak daha üst düzey temsiller üretir. CNN'lerin başarısı, katmanlar arasında gerçekleştirilen çok katmanlı ve parametre optimize edilmiş bilgi işleme yapısından kaynaklanmaktadır. (Rawat, ark. 2017) Özellikle modern bilgisayarla görme uygulamalarında standart hâline gelmiş olan CNN mimarileri, hâlen aktif bir araştırma alanı olarak gelişimini sürdürmektedir. (İnik, 2020. s. 111.)

3.3.3. Tekrarlayan sinir ağları (RNN - Recurrent Neural Networks)

Tekrarlayan Sinir Ağları (Recurrent Neural Networks - RNN), ardışık veri işleme için tasarlanmış bir derin öğrenme mimarisidir. Zaman serileri, doğal dil işleme (NLP) ve konuşma tanıma gibi görevlerde yaygın olarak kullanılmaktadır. RNN'lerin temel avantajı, önceki zaman adımlarından gelen bilgileri saklayabilen içsel bir hafızaya (hidden state) sahip olmalarıdır (Goodfellow, ve ark. 2016). Bu nedenle doğal dil işleme, zaman serisi tahmini ve video analiz gibi alanlarda yaygın olarak kullanılmaktadır. Ancak, RNN'ler uzun bağımlılık sorununa yatkındır; yani, zaman içinde uzak olayların etkisini öğrenmede zorluk yaşarlar. Bu sorunun üstesinden gelmek için, Uzun-Kısa Süreli Bellek (LSTM) hücreleri geliştirilmiştir. LSTM, özellikle bellek hücreleri ve kapı mekanizmaları kullanarak, bilginin gerektiğinde hatırlanmasını veya unutulmasını sağlayarak uzun süreli bağımlılıkları daha etkili bir şekilde öğrenir. RNN ve LSTM, derin öğrenme çerçevesinde önemli bir yer tutar; çünkü bu yapıların öğrenme süreçleri, geri yayılım algoritmaları ile optimize edilerek modelin performansı artırılmaya çalışılır. Ayrıca, RNN ve LSTM mimarileri birçok farklı varyasyon ve gelişmiş modeller

zenginleştirilmiş, bu sayede daha karmaşık veri ilişkilerinin öğrenilmesine olanak tanınmıştır.

Tekrarlayan Sinir Ağları (RNN), 1980'lerin ortalarından itibaren gelişmeye başlamış bir yapay zekâ modeli olarak bilinir. 1986 yılında Rumelhart, Hinton ve Williams tarafından önerilen geri yayılım algoritması (Backpropagation) ile birlikte, sinir ağlarının eğitimi daha verimli hale getirilmiştir. 1990'ların başında, RNN'lerin sıralı verilerle çalışma yetenekleri keşfedildi ve bu durumu daha iyi yönetebilmek için bazı mimari geliştirmeler yapıldı. 1997 yılında Hochreiter ve Schmidhuber, RNN'lerin en önemli hüsrانlarından biri olan uzun bağımlılık problemini ele alarak, Uzun-Kısa Süreli Bellek (LSTM) hücrelerini tanıttılar. Bu yenilik, sıralı verilerdeki bilgilerin daha uzun süre saklanmasına olanak sağladı. Özellikle doğal dil işleme ve ses tanıma gibi alanlarda önemli başarılar elde edilmesine katkıda bulundu. 2000'li yıllarda, daha iyi hesaplama güçleri ve daha büyük veri setleri ile daha karmaşık RNN mimarileri geliştirilmeye başlandı.

Standart Tekrarlayan Sinir Ağları (Recurrent Neural Networks - RNN'ler), geleneksel ileri beslemeli ağların aksine, RNN'ler bir "bellek" mekanizmasına sahiptir, çünkü önceki zaman adımlarından gelen bilgileri saklayabilir ve sonraki işlemlerde kullanabilirler. Bu özellik, RNN'leri doğal dil işleme (NLP), konuşma tanıma ve zaman serisi tahmini gibi alanlarda etkili kılar (Goodfellow, ve ark. 2016).

RNN mimarisi, her zaman adımında bir giriş vektörü x_t , bir gizli durum h_t ve bir çıktı y_t üretir. İleri beslemeli sinir ağlarının aksine, RNN'ler Şekil 3.5'te gösterildiği gibi tekrarlayan bağlantılara sahiptir ve bu da bilginin ağlar içinde dönmesine izin verir. Gizli durum, hem mevcut girdiyi hem de bir önceki gizli durumu dikkate alarak güncellenir.


Her bir zaman adımında t 'de, x_t girdisi alınır ve ağırlık matrisi W_{xh} ile çarpılarak gizli katmana iletilir. Gizli durum h_t , bir önceki zaman adımındaki gizli durum h_{t-1} ve mevcut girdi x_t kullanılarak hesaplanır. Matematiksel olarak

$$h_t = \sigma(W_{xh}x_t + W_{hh}h_{t-1} + b_h). \quad (2)$$

Burada σ aktivasyon fonksiyonu (genellikle tanh veya ReLU), W_{hh} gizli durumlar arası ağırlık matrisi ve b_h bias terimidir. Gizli katmandan gelen bilgi h_t , bir başka ağırlık matrisi W_{hy} ile çarpılarak çıkış y_t üretilir:

$$y_t = \text{softmax}(W_{hy}h_t + b_y) \quad (3)$$

Bu yapı sayesinde ağ, kısa vadeli bağımlılıkları öğrenebilir. Ancak RNN'ler uzun vadeli bağımlılıkları öğrenmekte zorluk yaşar. Özellikle "geri yayılım boyunca zaman" (backpropagation through time - BPTT) algoritması ile eğilirken, gradyanların sıfıra yaklaşması (vanishing gradient) veya aşırı büyümesi (exploding gradient) gibi problemler ortaya çıkabilir (Bengio, ve ark. 1994).



Şekil 3.5. RNN yapısı

(Jitani, 2020)

RNN'lerin temelleri 1980'li yıllara dayanmakta olup, Paul Werbos tarafından önerilen geri yayılım (BPTT) algoritması bu mimarinin öğrenme sürecini mümkün kılmıştır. Ancak, geri yayılım sırasında gradyanların üstel olarak büyüdüğü veya küçüldüğü kaybolan gradyan problemi nedeniyle eğitilmesi zor olan bu ağlar uzun yıllar sınırlı başarıyla kullanılmıştır. 1997 yılında Hochreiter ve Schmidhuber'in geliştirdiği Uzun Kısa Süreli Bellek (Long Short-Term Memory - LSTM) ağı, RNN'lerin uzun vadeli bağımlılık öğrenememe sorununa çözüm getirmiştir (Hochreiter, ve ark., 1997).

3.3.4. Uzun kısa süreli bellek (LSTM - Long Short-Term Memory)

Uzun-Kısa Süreli Bellek (LSTM), tekrarlayan sinir ağlarının bir bileşeni olarak, özellikle zaman bağımlı verilerin işlenmesinde etkili bir yapı sunmaktadır. Bu mimari, geleneksel RNN'lerin karşılaştığı uzun bağımlılık problemini çözüme kavuşturmak için 1997 yılında Sepp Hochreiter ve Jürgen Schmidhuber tarafından geliştirilmiştir (Hochreiter, S., & Schmidhuber, J. 1997). LSTM hücreleri, sıradan RNN'lerden farklı olarak, bilgiyi uzun süre boyunca taşıyabilen hücre durumları ve kapı mekanizmaları içerir. Bu kapılar; unutma kapısı (forget gate), giriş kapısı (input gate) ve çıkış kapısıdır (output gate). Bu yapı, hücre durumunun (cell state) üzerinden bilgiyi kontrollü bir biçimde geçirerek uzun vadeli bağlamın korunmasını sağlar (Gers ve ark., 2000).

LSTM güncelleme denklemleri aşağıdaki gibidir:

$$i_t = \sigma(W_{xi}x_t + W_{hi}h_{t-1} + b_i), \quad (4)$$

$$f_t = \sigma(W_{xf}x_t + W_{hf}h_{t-1} + b_f), \quad (5)$$

$$o_t = \sigma(W_{xo}x_t + W_{ho}h_{t-1} + b_o), \quad (6)$$

$$g_t = \tanh(W_{xg}x_t + W_{hg}h_{t-1} + b_g), \quad (7)$$


$$c_t = f_t \odot c_{t-1} + i_t \odot g_t, \quad (8)$$

$$h_t = o_t \odot \tanh(c_t), \quad (9)$$

Burada i_t giriş kapısı, f_t unutma kapısı, o_t çıkış kapısı, g_t hücre girişi, c_t hücre durumu, h_t gizli durum, σ sigmoid fonksiyonu, $\tanh$ hiperbolik tanjant fonksiyonu ve $\odot$ eleman-bilge çarpımını ifade eder (Mienye ve ark., 2006)

Şekil 3.6, bir LSTM hücresinin iç mimarisini ve bu hücrenin uzun vadeli bağımlılıkları yönetmek için kullandığı üç temel geçit mekanizmasını göstermektedir: giriş kapısı (i_t), unutma kapısı (f_t) ve çıkış kapısı (o_t). Bu kapılar, hücre içindeki bilgi akışını kontrol ederek farklı roller üstlenir. Giriş kapısı yeni x_t girdisinin ne kadarının c_t hücre durumuna eklenmesi gerektiğini belirler. Unutma kapısı, bir önceki adımdaki c_{t-1} durumunun ne kadarının korunacağına karar verir. Çıkış kapısı ise, hücre durumu c_t 'nin ne kadarının h_t gizli durumu olarak çıktıya yansıtılacağını ayarlar. Ayrıca g_t , hücre girişi, giriş kapısı tarafından modüle edildikten sonra hücre durumuna eklenen bir aday değer olarak işlev görür. Bu geçit mekanizmaları sayesinde LSTM ağları, bilgiyi seçici bir şekilde hatırlayıp unutulabilir ve geleneksel RNN'lerden daha etkili bir şekilde uzun vadeli bağımlılıkları modelleyebilir. (Mienye ve ark., 2006)

LSTM'deki iç yineleme süreci, hücre durumu c_t aracılığıyla yönetilir. Bu durum, farklı zaman adımları arasında bilgi taşıyan bir "taşıyıcı bant" görevi görerek, ağın uzun diziler boyunca bağlamı korumasını sağlar. Bu mekanizma, LSTM'nin uzun vadeli bağımlılıkları yakalayabilmesine ve belleğini dinamik olarak güncelleyebilmesine olanak tanır. Kapılar ve ilgili girdiler arasındaki eleman-bazlı çarpma işlemleri, hücrenin farklı bileşenleri arasındaki etkileşimlerin sorunsuz ve verimli olmasını sağlar. Böylece LSTM, öğrenme sürecinin kararlılığını korurken karmaşık veri dönüşümlerini gerçekleştirebilir. Ayrıca, her hücre içindeki dahili yineleme sayesinde bilgi, bir zaman adımından diğerine hücre durumu üzerinden aktarılır ve bu da LSTM'nin uzun süreli bağımlılıkları yönetmedeki başarısını artırır. (Mienye ve ark., 2006)



Şekil 3.6. LSTM ağının mimarisi

(Mienye ve ark., 2006)

LSTM'ler, güçlü öğrenme yeteneklerine rağmen bazı sınırlamalara sahiptir. Özellikle, karmaşık yapıları nedeniyle hesaplama maliyetleri yüksektir ve eğitim süreleri uzundur. Ayrıca, aşırı öğrenme (overfitting) riski taşırlar ve hiper parametre ayarlamaları zordur.

3.4.Meteorolojik Veriler

Tez çalışmasında yapılacak olan Tokat ili için hava durumu tahmininde kullanılacak meteorolojik veri Tokat Meteoroloji Müdürlüğünden temin edilmiştir. Veri 1997 - 2024 yılları arasını kapsamakta ve TOKAT/17086 istasyonundan ölçümler yapılmıştır. Tokat Meteoroloji Müdürlüğünden alınan veriler Tablo 3.1’ de verilmiştir.

Tablo 3.1. Saatlik meteorolojik gözlem değişkenleri ve açıklamaları

No	Değişken Adı	Birim	Açıklama
1	Saatlik Aktüel Basınç	hPa	Deniz seviyesine indirgenmiş atmosfer basıncı
2	Saatlik Güneşlenme Süresi	saat	Güneş ışınlarının doğrudan ulaştığı sürenin toplamı
3	Saatlik Küresel Güneş Radyasyonu	watt·saat/m ²	Güneşten gelen toplam enerji miktarı
4	Saatlik Maksimum Nispi Nem	%	Gün içindeki en yüksek bağıl nem oranı
5	Saatlik Maksimum Rüzgar Yönü ve Hızı	° / m/s	Saatlik ölçülen en yüksek rüzgar yönü ve hızı
6	Saatlik Maksimum Sıcaklık	°C	Gün içinde ölçülen en yüksek sıcaklık
7	Saatlik Mevcut Kar Kalınlığı	cm	Yüzeyde biriken kar tabakasının kalınlığı
8	Saatlik Minimum Nispi Nem	%	Gün içindeki en düşük bağıl nem oranı
9	Saatlik Minimum Sıcaklık	°C	Gün içinde ölçülen en düşük sıcaklık
10	Saatlik Nispi Nem	%	Anlık bağıl nem oranı
11	Saatlik Ortalama Rüzgar Hızı	m/s	Saatlik rüzgar hızlarının ortalaması
12	Saatlik Rüzgar Yönü ve Hızı	° / m/s	O saatte hâkim olan rüzgar yönü ve ortalama hızı

Tablo 3.1. (Devamı) Saatlik meteorolojik gözlem değişkenleri ve açıklamaları

No Değişken Adı	Birim	Açıklama
13 Saatlik Sıcaklık	°C	O saate ait anlık sıcaklık ölçümü
14 Saatlik Toplam Küresel Güneş Radyasyonu	watt/m ²	O saatte yüzeye düşen toplam güneş radyasyonu
15 Saatlik Toplam Yağış (OMGİ)	mm (kg/m ²)	O saatte düşen toplam yağış miktarı
16 Saatlik Toprak Üstü Minimum Sıcaklık	°C	Bitki örtüsüne yakın seviyede ölçülen en düşük sıcaklık
17 Saatlik Yatay Görüş Mesafesi	km	Görüş mesafesi; sis, yağmur gibi etkenlere göre değişir

Meteoroloji müdürlüğünden alınan veriler Şekil 3.7’te görüldüğü şekildedir. Şekil 3.7’teki sıcaklık örneği 1997 yılının Aralık ayına ait her günün 24 saatine denk gelen ölçümleri göstermektedir. Tablo 3.1’de sayılmış olan tüm değişkenlere ait veriler, her ay için ayrı ayrı tablolar halinde aynı Şekil 3.7’teki gibidir.

Veri saatlik bazda düzenlenmiş olup tablo formatında sunulmaktadır. Ancak bu veri yapısı, zaman serisi analizi ve derin öğrenme modellerinde doğrudan kullanıma uygun değildir. Verilerin yeniden yapılandırılması, eksik değerlerin kontrolü ve ölçekleme işlemleri yapılmaksızın model eğitimi gerçekleştirilmesi mümkün değildir. Ayrıca modelin çok değişkenli yapısı göz önünde bulundurulduğunda yalnızca sıcaklık içeren bu tablonun genişletilmesi ve diğer meteorolojik değişkenlerle entegre edilmesi gerekmiştir.

Saatlik Sıcaklık (°C)																								
Gün/Saat	0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23
1	2.9	2.0	1.5	0.9	0.7	0.3	0.3	2.3	6.0	6.4	6.9	7.7	8.9	9.6	9.0	8.8	5.4	4.7	3.8	3.3	3.0	2.9	3.5	3.0
2	2.4	1.8	2.3	2.7	2.7	3.0	3.4	3.7	4.1	4.2	4.7	5.4	5.8	5.4	5.1	5.4	5.2	5.3	5.8	5.0	4.9	5.1	5.1	5.4
3	5.4	5.5	5.4	5.5	5.9	5.9	6.1	7.0	10.0	11.0	11.8	11.9	12.3	12.6	11.7	10.9	11.9	12.4	12.0	11.2	11.2	12.0	12.1	12.1
4	12.0	9.7	9.1	9.1	9.6	10.6	11.0	11.6	12.2	11.9	12.2	12.2	12.5	12.5	12.6	12.2	12.1	12.3	11.8	11.2	12.9	10.5	9.4	9.0
5	10.4	9.0	8.5	8.5	8.4	8.4	8.6	8.5	8.9	9.0	10.1	11.6	7.1	8.2	8.2	8.1	7.0	6.5	4.8	3.7	3.1	2.5	2.1	1.7
6	1.4	1.3	1.3	1.0	0.8	0.8	0.7	2.8	4.6	7.5	7.2	8.2	9.0	9.5	8.9	7.8	5.7	4.3	3.5	2.8	2.2	1.9	1.9	1.4
7	1.5	1.5	0.9	1.1	1.2	0.8	1.2	2.8	2.4	3.8	5.4	6.1	6.8	6.8	6.6	6.5	6.6	6.5	8.1	7.8	8.7	9.2	9.5	10.1
8	11.2	11.9	12.7	12.3	12.4	12.5	12.7	13.1	13.9	16.7	17.2	16.1	15.1	15.2	15.5	14.0	15.1	13.4	11.4	10.1	10.5	10.2	9.3	9.1
9	8.8	8.6	8.4	8.3	8.8	8.7	8.6	8.7	8.8	9.5	10.8	11.1	11.7	11.9	11.3	10.3	9.3	8.8	8.0	7.6	7.3	7.0	6.6	6.7
10	6.5	6.3	6.1	5.9	5.7	5.7	5.6	5.6	5.5	5.2	4.9	5.7	5.9	5.5	5.0	4.7	4.3	3.9	3.6	3.2	3.1	2.9	2.6	2.6
11	2.5	2.5	2.5	2.5	2.4	2.4	2.5	2.6	3.0	3.4	3.6	3.8	3.8	3.3	3.3	3.2	3.0	3.0	2.8	2.7	2.7	2.6	2.5	2.4
12	2.2	2.2	2.1	1.5	1.8	1.7	1.7	1.6	1.0	0.8	1.0	1.6	1.7	1.4	1.6	2.0	2.1	2.1	2.2	2.0	2.2	1.9	1.9	1.3
13	0.9	0.5	0.3	0.2	0.0	-0.2	-0.4	-0.6	0.2	0.7	1.1	1.1	1.2	0.9	0.6	-0.2	-0.3	-0.4	-0.8	-1.2	-1.5	-1.4	-1.7	-1.9
14	-2.4	-3.0	-3.6	-4.0	-4.4	-5.0	-4.4	-3.0	-0.9	0.7	1.3	2.7	2.8	2.9	2.7	1.7	1.3	0.7	0.0	-1.9	-2.0	-2.4	-3.3	-3.4
15	-4.0	-4.4	-5.0	-5.0	-5.2	-4.8	-4.2	-1.3	0.8	3.2	2.4	4.0	5.9	6.7	7.1	6.5	6.5	9.0	8.5	9.6	9.6	10.4	10.2	10.6
16	10.3	10.3	10.1	10.4	9.2	10.6	11.0	11.2	11.6	12.5	12.1	12.6	13.0	12.4	12.3	11.7	10.1	10.2	8.7	8.9	8.3	8.1	7.7	7.5
17	7.7	7.4	7.1	6.6	6.1	6.0	6.1	6.2	6.9	7.7	7.8	8.9	8.8	9.2	9.3	8.7	8.2	8.0	7.8	6.4	5.1	4.8	3.9	3.0
18	3.0	2.0	2.3	3.4	3.4	2.6	2.4	2.2	4.2	4.4	6.0	7.5	8.1	8.6	9.0	7.9	10.7	12.2	12.2	12.6	12.7	12.7	9.9	8.8
19	8.2	8.9	10.4	11.3	9.0	9.4	10.3	12.0	9.2	10.9	14.6	15.0	14.3	14.5	14.9	14.1	11.5	13.6	11.0	9.5	9.2	9.4	9.6	10.1
20	9.6	9.8	10.4	10.7	10.3	10.1	8.4	8.4	9.8	12.5	13.6	14.9	14.9	15.0	14.6	13.4	12.9	13.1	12.5	12.5	10.3	9.8	9.1	9.0
21	8.7	8.7	8.4	8.4	8.4	8.3	5.8	5.5	5.4	5.4	4.8	4.5	4.4	4.1	3.4	2.9	2.5	2.0	0.9	0.3	0.1	0.0	0.2	0.4
22	0.2	0.7	0.7	0.7	0.7	0.7	0.8	0.7	1.0	1.4	1.5	1.7	2.1	2.2	2.2	1.9	1.2	0.5	0.7	-0.3	0.0	0.3	0.5	0.6
23	0.6	-0.1	-0.2	-0.3	-1.3	-1.2	0.1	0.7	1.2	1.1	1.5	1.8	2.3	1.9	1.8	1.7	1.6	1.3	1.2	0.7	-0.3	-0.8	-1.2	-1.5
24	-1.5	-1.5	-1.4	-1.4	-1.6	-1.6	-0.9	-0.3	0.2	0.4	0.9	1.9	1.9	2.1	2.2	2.1	2.0	1.7	1.5	0.5	-0.2	-1.1	-2.2	-2.5
25	-2.6	-3.0	-1.3	-1.4	-1.8	-2.9	-1.3	0.4	2.3	2.1	2.5	2.7	2.4	2.8	3.0	2.6	2.3	1.9	1.4	1.3	0.8	0.8	0.9	0.9
26	1.0	1.2	0.6	0.7	0.3	0.2	0.0	0.7	2.5	3.4	4.1	3.8	4.0	4.2	4.0	3.8	3.6	3.6	2.9	2.8	2.5	2.2	2.1	2.1
27	2.0	1.8	2.0	2.1	2.0	1.9	1.8	2.8	3.7	4.5	4.4	5.3	5.1	5.3	3.0	2.3	2.1	2.8	1.5	1.1	1.2	1.1	0.8	1.0
28	1.3	1.3	0.3	0.1	0.1	-0.3	-0.6	2.1	4.3	5.1	4.9	5.1	5.3	5.2	5.0	4.1	3.3	2.8	2.7	2.3	2.0	1.6	1.2	0.7
29	0.3	0.2	0.1	-0.4	0.0	-0.1	-0.1	0.3	1.4	2.1	2.9	3.9	4.2	4.4	4.0	2.9	2.7	2.1	1.8	2.0	1.5	0.7	0.2	0.5
30	0.7	0.9	0.4	-0.4	0.0	0.2	0.5	1.8	2.9	4.1	4.6	6.0	6.2	5.7	4.6	3.7	3.4	2.8	2.3	2.1	2.3	1.7	1.5	1.2
31	1.2	-0.1	0.2	-0.1	-0.8	-1.2	-0.1	2.1	3.9	5.3	5.6	6.9	6.6	6.4	5.7	4.6	3.6	3.1	2.5	1.7	0.7	-0.1	-1.4	-2.5

Şekil 3.7. Meteoroloji müdürlüğünden alınan Tokat ili 1997 yılı Aralık ayı saatlik sıcaklık verisi

4. DENEYSEL ÇALIŞMALAR

Deneysel çalışmada kullanılan donanım ve yazılımlara ait kaynakların bilgileri Tablo 4.1’de verilmiştir.

Tablo 4.1. Kullanılan donanım ve yazılıma ait bilgiler

Eğitim İçin Kullanılan Donanım	Donanım Özellikleri
İşlemci	Intel(R) Core(TM) i5-7500 CPU
İşlemci Hızı	3.40GHz 4 Çekirdek
Ram Kapasitesi	8 GB (Gigabayt)
Grafik Kartı	Intel(R) HD Graphics 630
Eğitim İçin Kullanılan Yazılım	Matlab R2024a 64 Bit

Tez çalışması için Meteoroloji müdürlüğünden veri talep edildi. Meteoroloji müdürlüğü de 1997-2024 yılları arasını kapsayan Tablo 3.1’de değişken isimleri halinde belirtilen meteorolojik değişkenlerinin saatlik ölçüm değerlerini Excel tabloları halinde bize sundular. Tüm meteorolojik değişkenlerin ölçümleri her gün ve düzenli şekilde gerçekleştirilemediğinden dolayı bu Excel dosyasındaki bazı değişkenlerin tabloları büyük boşluklar içermektedir. İlk olarak tabloların boşluk oranları hesaplandı. Hangi veriler ile çalışılacağı kararlaştırıldı ardından seçilen değişkenlerin boş olan kısımları uygun, eksik veri giderme metotları ile dolduruldu. Günlük, haftalık ve aylık tahminler olmak üzere 17 LSTM modeli geliştirildi. Eğitim işlemi için Matlab R2024a programı kullanılmıştır.

4.1.Performans Ölçütleri

Bu çalışmada geliştirilen derin öğrenme modellerinin başarımını değerlendirebilmek amacıyla çeşitli performans ölçütlerinden yararlanılmıştır. Zaman serisi tahmini problemlerinde özellikle hata oranlarını yansıtan istatistiksel metrikler tercih edilmiştir. Kullanılan başlıca ölçütler aşağıda açıklanmıştır:

Ortalama Mutlak Hata (MAE - Mean Absolute Error)

Ortalama mutlak hata, tahmin edilen değerler ile gerçek değerler arasındaki farkların mutlak değerlerinin ortalamasını ifade eder. MAE, tüm hataları eşit önemde kabul eder ve yorumlanması oldukça kolaydır.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (10)$$

Burada y_i , gerçek değerleri, $\hat{y}_i$ ise model tarafından tahmin edilen değerleri temsil eder.

Ortalama Kare Hata (MSE - Mean Squared Error)

Ortalama kare hata, tahmin hatalarının karesinin ortalamasıdır. Büyük hataları daha fazla cezalandırdığı için modele yönelik duyarlılığı yüksektir.

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (11)$$

Kök Ortalama Kare Hata (RMSE - Root Mean Squared Error)

MSE'nin karekökü alınarak elde edilir. Hata birimi, tahmin edilen değişkenle aynı olur. Bu nedenle yorumlanması MSE'ye göre daha sezgiseldir.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (12)$$

Açıklama Katsayısı (R^2 – Coefficient of Determination)

R^2 değeri, modelin bağımlı değişkendeki toplam varyansın ne kadarını açıklayabildiğini gösterir. 1'e yaklaştıkça modelin açıklayıcılığı artar; 0'a yakın ya da negatif değerler ise modelin yeterince açıklayıcı olmadığını gösterir. Özellikle çoklu değişken tahmini yapılan Model 21'in başarımlı analizinde, yalnızca hata miktarları değil, aynı zamanda bu açıklama katsayısı da dikkate alınmıştır.

$$R^2 = 1 - \frac{\sum (y_i - \hat{y}_i)^2}{\sum (y_i - \bar{y})^2} \quad (13)$$

Burada $\bar{y}$, gerçek değerlerin ortalamasını temsil eder.

4.2. Verilerin Ön İşlenmesi

Matlab üzerinden geliştireceğimiz LSTM modelinde bu verileri kullanabilmek için ön işleminden geçirmemiz gerekmektedir. Bu verilerin bu hali ile işlenememesinin 2 temel nedeni vardır. Birincisi şekilsel hali;

Veriler Şekil 3.7'deki hali ile Excel dosyasında sütunlar boyunca saat dilimlerini, satırlar boyunca ise günleri temsil eden iki boyutlu matris biçiminde sunulması, görsel analiz ve manuel inceleme açısından uygun olmakla birlikte, zaman serisi modellerinde kullanılan yapay sinir ağları — özellikle Uzun Kısa Süreli Bellek (LSTM) — için doğrudan kullanılabilir bir veri formatı değildir. LSTM modelleri, zamana bağlı ardışık verileri tek bir zaman damgası (timestamp) ile ilişkilendirilmiş şekilde, yani her gözlem bir satırda olmak üzere sıralı biçimde beklemektedir. Bu nedenle, her bir gün ve saate karşılık gelen sıcaklık verisinin birleştirilerek uzun formata dönüştürülmesi gereklidir. Bu dönüşüm sayesinde modelin zaman bağımlılıklarını etkin bir şekilde öğrenmesi sağlanır

2005). Bu işlem, mevsimsel ve aylık eğilimlerin korunmasını sağlamış, ayrıca mevsimsel olarak değişkenlik gösteren meteorolojik parametrelerde daha tutarlı sonuçlar elde edilmesine imkân vermiştir. Aylık medyan ile yapılan ilk doldurma sonrasında kalan boşluklar için doğrusal interpolasyon uygulanmış ve uç değerler previous-next yöntemi ile tamamlanmıştır.

Doluluk oranı %60'tan düşük olan (boşluk oranı %40'tan yüksek) değişkenler ise modelleme süreci dışında bırakılmıştır. Bu değişkenlerin yüksek orandaki eksiklikleri, istatistiksel doldurma yöntemleriyle bile anlamlı bir şekilde giderilemeyeceğinden, tahmin modellerinde güvenilirlik sorunlarına yol açabileceği değerlendirilmiştir (Schafer ve Graham, 2002).

Bunun yanında, Saatlik Mevcut Kar Kalınlığı değişkeni için istisnai bir işlem uygulanmıştır. Bu değişkende eksik olarak kaydedilen gözlemler, meteorolojik anlamda kar bulunmadığı durumlar olarak değerlendirilmiş ve tüm eksik hücreler 0 değeri ile doldurulmuştur. Bu sayede, kar kalınlığına ilişkin zaman serisi üzerinde yapay artışlar veya meteorolojik olarak anlamsız değerler oluşması engellenmiştir.

Belirlenen bu yöntemler sayesinde, veri setinde yer alan değişkenlerin zamansal bütünlüğü korunmuş, mevsimsel ve kısa dönemli değişimler istatistiksel olarak tutarlı bir biçimde temsil edilmiş ve modelleme sürecinde kullanılacak veri yapısı homojen hale getirilmiştir.

Meteorolojik verinin eksik veri giderilmeden önce, boş hücrelerin de yer aldığı 11.02.2024 tarihine ait 24 saatlik şekli Şekil 4.2 de gösterilmiştir. Bu veri eksik veri giderim ve model dışı bırakma yöntemlerinden sonra Şekil 4.3 teki halini almıştır.

	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	Q	R	S
			SaatlikSıcaklık	ToplamYağış	SaatlikYatayGörüşMesafesi	SaatlikAktüelBasınc	SaatlikGüneslenmeSuresi	SaatlikMaksimumNispiNem	SaatlikMaksimumSıcaklık	SaatlikMevcutKarKalınlığı	SaatlikMinimumNispiNem	SaatlikMinimumSıcaklık	SaatlikMinimumNispiNem	SaatlikOrtalamaRüzgarHızı	SaatlikOrtalamaRüzgarYönü	SaatlikOrtalamaRüzgarGüçü	SaatlikOrtalamaRüzgarYönü	SaatlikOrtalamaRüzgarGüçü	SaatlikOrtalamaRüzgarYönü
1																			
2	23	11.02.2024	9.7	0.0		948.6		61	10.4		56	9.1	59.0	0.0	5.5		314.0	1.7	0° 0.0
3	22	11.02.2024	11.1	0.0		948.7		59	11.9		49	9.8	55.0	1.9	7.6		3.0	2.3	356° 1.9
4	21	11.02.2024	11.0	0.0	20.0	948.2		59	11.3		53	10.3	56.0	0.5	6.2		269.0	2.1	190° 0.5
5	20	11.02.2024	11.8	0.0		948.4		58	12.4		48	10.7	52.0	1.0	6.1		187.0	1.7	317° 1.0
6	19	11.02.2024	11.6	0.0		948.1		55	12.6		48	11.4	53.0	0.5	7.2		221.0	2.2	88° 0.5
7	18	11.02.2024	12.7	0.0	20.0	948.1	0.0	54	12.7		48	10.9	48.0	0.0	6.7	0.0	184.0	2.7	0° 0.0
8	17	11.02.2024	13.8	0.0	20.0	947.8	0.0	54	14.3		42	10.9	43.0	0.0	7.4	0.0	311.0	2.9	0° 0.0
9	16	11.02.2024	14.3	0.0	20.0	947.5	0.0	45	14.9		38	13.5	42.0	0.5	8.1	0.0	315.0	2.1	90° 0.5
10	15	11.02.2024	15.9	0.0	20.0	946.7	0.0	42	15.8		37	14.1	38.0	1.0	11.4	0.0	91.0	2.6	90° 1.0
11	14	11.02.2024	17.4	0.0	20.0	947.2	0.0	38	17.3		31	15.8	33.0	2.1	16.1	39.1	91.0	2.2	290° 2.1
12	13	11.02.2024	18.5	0.0	20.0	947.0	0.3	32	18.4		28	17.4	29.0	4.1	19.1	145.7	308.0	6.4	300° 4.1
13	12	11.02.2024	18.9	0.0	20.0	947.1	1.0	28	19.4		22	18.3	24.0	3.1	20.8	329.9	293.0	6.5	220° 3.1
14	11	11.02.2024	18.4	0.0	20.0	947.3	1.0	25	19.2		23	18.7	26.0	2.6	21.8	472.3	211.0	6.2	230° 2.6
15	10	11.02.2024	17.6	0.0	20.0	948.1	1.0	27	18.9		24	18.0	27.0	2.1	23.5	590.2	207.0	6.4	260° 2.1
16	9	11.02.2024	16.4	0.0	20.0	949.3	1.0	32	18.1		25	16.5	33.0	0.5	24.6	624.0	224.0	5.5	200° 0.5
17	8	11.02.2024	14.3	0.0	20.0	949.6	1.0	39	17.2		30	14.6	40.0	1.0	21.7	573.5	125.0	2.3	170° 1.0
18	7	11.02.2024	10.7	0.0	20.0	950.3	1.0	50	14.8		38	11.4	53.0	1.5	14.1	457.4	87.0	2.4	100° 1.5
19	6	11.02.2024	7.1	0.0	20.0	950.5	1.0	63	11.4		49	7.4	65.0	1.5	6.5	310.4	84.0	3.6	100° 1.5
20	5	11.02.2024	6.3	0.0		950.0	0.4	70	7.5		63	5.4	65.0	2.0	3.8	94.9	89.0	4.7	102° 2.0
21	4	11.02.2024	6.1	0.0		949.7	0.0	67	6.9		63	5.9	67.0	1.5	3.7	3.0	87.0	3.7	109° 1.5
22	3	11.02.2024	7.4	0.0	20.0	949.7	0.0	66	7.5		61	6.2	61.0	1.5	5.3	0.0	84.0	4.2	90° 1.5
23	2	11.02.2024	8.2	0.0		949.5	0.0	64	8.8		54	6.9	58.0	0.0	4.6	0.0	86.0	4.4	0° 0.0
24	1	11.02.2024	8.0	0.0		949.3		63	9.0		55	7.2	57.0	0.0	4.0		66.0	1.8	0° 0.0
25	0	11.02.2024	8.8	0.0	20.0	949.4		60	9.4		52	7.4	56.0	0.0	4.2		89.0	2.1	0° 0.0
26	23	10.02.2024	10.3	0.0		949.4		54	10.8		47	9.3	49.0	1.2	4.7		134.0	1.7	300° 1.2
27	22	10.02.2024	10.6	0.0		949.2		51	11.4		45	9.9	48.0	0.2	3.9		221.0	1.9	79° 0.2
28	21	10.02.2024	11.4	0.0	20.0	948.9		51	12.1		44	10.3	47.0	0.5	4.4		294.0	2.9	150° 0.5
29	20	10.02.2024	12.5	0.0		948.5		47	12.5		43	11.2	44.0	1.5	7.9		284.0	3.0	18° 1.5
30	19	10.02.2024	12.7	0.0		947.7		45	13.2		43	12.3	45.0	2.4	8.5		333.0	4.0	324° 2.4

Şekil 4.2. Meteorolojik verinin eksik veri giderilmeden önceki hali

	A	B	C	D	E	F	G	H	I	J	K
	Saat	Tarih	Saatlik Sicaklik	SaatlikAkt uelBasinc	SaatlikOrtala maRuzgarhizi	SaatlikYatay GorusMesaf esi	SaatlikNis piNem	RuzgarYo nDerece	RuzgarHi zMS	SaatlikMevc utKarKalinli gi	Zaman
2	23	11.02.2024 00:00	9,7	948,6	0	20	59	0	0	0	11.02.2024 23:00
3	22	11.02.2024 00:00	11,1	948,7	1,9	20	55	356	1,9	0	11.02.2024 22:00
4	21	11.02.2024 00:00	11	948,2	0,5	20	56	190	0,5	0	11.02.2024 21:00
5	20	11.02.2024 00:00	11,8	948,4	1	20	52	317	1	0	11.02.2024 20:00
6	19	11.02.2024 00:00	11,6	948,1	0,5	20	53	88	0,5	0	11.02.2024 19:00
7	18	11.02.2024 00:00	12,7	948,1	0	20	48	0	0	0	11.02.2024 18:00
8	17	11.02.2024 00:00	13,8	947,8	0	20	43	0	0	0	11.02.2024 17:00
9	16	11.02.2024 00:00	14,3	947,5	0,5	20	42	90	0,5	0	11.02.2024 16:00
10	15	11.02.2024 00:00	15,9	946,7	1	20	38	90	1	0	11.02.2024 15:00
11	14	11.02.2024 00:00	17,4	947,2	2,1	20	33	290	2,1	0	11.02.2024 14:00
12	13	11.02.2024 00:00	18,5	947	4,1	20	29	300	4,1	0	11.02.2024 13:00
13	12	11.02.2024 00:00	18,9	947,1	3,1	20	24	220	3,1	0	11.02.2024 12:00
14	11	11.02.2024 00:00	18,4	947,3	2,6	20	26	230	2,6	0	11.02.2024 11:00
15	10	11.02.2024 00:00	17,6	948,1	2,1	20	27	260	2,1	0	11.02.2024 10:00
16	9	11.02.2024 00:00	16,4	949,3	0,5	20	33	200	0,5	0	11.02.2024 09:00
17	8	11.02.2024 00:00	14,3	949,6	1	20	40	170	1	0	11.02.2024 08:00
18	7	11.02.2024 00:00	10,7	950,3	1,5	20	53	100	1,5	0	11.02.2024 07:00
19	6	11.02.2024 00:00	7,1	950,5	1,5	20	65	100	1,5	0	11.02.2024 06:00
20	5	11.02.2024 00:00	6,3	950	2	20	65	102	2	0	11.02.2024 05:00
21	4	11.02.2024 00:00	6,1	949,7	1,5	20	67	109	1,5	0	11.02.2024 04:00
22	3	11.02.2024 00:00	7,4	949,7	1,5	20	61	90	1,5	0	11.02.2024 03:00
23	2	11.02.2024 00:00	8,2	949,5	0	20	58	0	0	0	11.02.2024 02:00
24	1	11.02.2024 00:00	8	949,3	0	20	57	0	0	0	11.02.2024 01:00
25	0	11.02.2024 00:00	8,8	949,4	0	20	56	0	0	0	11.02.2024 00:00

Şekil 4.3. Meteorolojik verinin eksik veri giderildikten sonraki hali

4.4. Sayısal Dönüşüm ve Veri Tipi Uyarlaması

Excel tabanlı veri dosyasından MATLAB ortamına aktarılan verilerin bazıları, sayısal değil cell tipinde okunmuş, bu da interpolasyon gibi yöntemlerin uygulanmasına engel olmuştur. Bu nedenle tüm sayısal değişkenler, `str2double()` fonksiyonu ile double veri tipine dönüştürülerek işlenebilir hale getirilmiştir.

4.5. Modelleme Dışı Bırakma

Çalışma kapsamında eksik oranı %60'ı aşan ve istatistiksel olarak tamamlanabilirliği düşük olan değişkenler modelleme dışında bırakılmıştır. Benzer şekilde, rüzgâr yönü gibi yönelimsel ve metinsel veri içeren değişkenler de sayısal işlemlere uygun olmadığından çalışma dışında tutulmuştur.

Bu çok katmanlı yaklaşım sayesinde, LSTM modeli için yalnızca sağlıklı şekilde tamamlanabilmiş, zamansal tutarlılığı koruyan ve sayısal niteliği uygun olan veriler kullanılmıştır.

Tablo 4.2. Meteoroloji Müdürlüğünden alınan verilerin doluluk oranı

Değişken Adı	Doluluk Oranı	%
Saatlik Aktüel Basıncı	99,51	
Saatlik Güneşlenme Süresi	56,07	
Saatlik Küresel Güneş Radyasyonu	36,50	
Saatlik Maksimum Nispi Nem	40,63	
Saatlik Maksimum Rüzgarın Yönü	52,18	
Saatlik Maksimum Sıcaklık	52,58	
Saatlik Mevcut Kar Kalınlığı	1,10	
Saatlik Minimum Nispi Nem	40,63	
Saatlik Minimum Sıcaklık	52,53	
Saatlik Nispi Nem	61,86	
Saatlik Ortalama Rüzgar hızı	99,35	
Saatlik Rüzgar Yönü	69,42	
Saatlik Sıcaklık	99,54	
Saatlik Toplam Küresel Güneş Radyasyonu	39,43	
Saatlik Toplam Yağış	52,26	
Saatlik Toprak Üstü Minimum Sıcaklık	35,32	
Saatlik Yatay Görüş Mesafesi	65,68	

4.6. Modelleme Süreci ve Aşamaları

Bu tez çalışmasında, Tokat iline ait 28 yıllık meteorolojik veriler kullanılarak, derin öğrenme tabanlı sıcaklık tahmin modelleri geliştirilmiştir. Modelleme süreci, farklı zaman ölçeklerinde (günlük, haftalık ve aylık) yapılan tahminlerle kademeli bir biçimde ilerlemiş; her aşamada modelin genel eğilimleri öğrenme kapasitesi ve öngörü gücü sistematik olarak test edilmiştir.

Başlangıçta günlük sıcaklık tahminleriyle, modelin kısa vadeli öngörü kapasitesi değerlendirilmiştir. Bu adımda amaç, sistemin anlık dalgalanmalara ne derece duyarlı

olduğunu ve kısa zaman dilimlerindeki sıcaklık değişimlerini öğrenebilme kabiliyetini gözlemlemektir. Ardından haftalık tahmin sürecine geçilmiş, bu aşamada modelin daha geniş zaman aralıklarındaki ortalama eğilimleri yakalayabilme potansiyeli analiz edilmiştir. Son aşamada ise aylık tahminler yapılmış ve böylece uzun vadeli sıcaklık öngörülerinin modellenmesine odaklanılmıştır.

Bu kademeli geçişin temel amacı, iklim tahminine yönelik geliştirilen derin öğrenme modellerinin farklı zaman ölçekleri karşısında ne kadar dayanıklı ve güvenilir olduğunu ölçmektir. Çünkü iklim tahmini, yalnızca birkaç gün veya hafta sonrasının hava durumunu değil, aynı zamanda mevsimsel ve yıllık sıcaklık eğilimlerini öngörmeye çalışan, stratejik planlamaya dayalı bir analiz biçimidir. Tarım, enerji, afet yönetimi ve şehir planlaması gibi çok sayıda sektör, uzun vadeli sıcaklık öngörülerine dayalı olarak kritik kararlar almaktadır. Bu nedenle, geliştirilen modellerin yalnızca kısa vadeli tahminlerde değil, aynı zamanda uzun vadeli projeksiyonlarda da anlamlı sonuçlar üretebilmesi hedeflenmiştir.

Modelleme sürecinde yalnızca sıcaklık verisiyle sınırlı kalınmamış, modelin başarımını artırmak amacıyla nem, basınç, rüzgar hızı gibi çeşitli meteorolojik değişkenler de modele giriş olarak dahil edilmiştir. Çünkü sıcaklık, atmosferik sistemin yalnızca bir çıktısıdır ve çoğu zaman diğer değişkenlerle birlikte etkileşimli olarak değişim gösterir. Bu nedenle tek değişkenli bir tahmin modeli, atmosferdeki karmaşık ilişkileri göz ardı edebilir. Çok değişkenli yaklaşım ise, modelin daha geniş bir bağlamı öğrenmesini ve böylece daha isabetli tahminler üretmesini sağlar. Bu çalışmada kullanılan derin öğrenme mimarileri, çok boyutlu verileri işleyebilecek şekilde tasarlanmış ve bu sayede sıcaklığı etkileyen farklı meteorolojik faktörler birlikte değerlendirilerek modelin öngörü gücü artırılmıştır.

Bu bölümde, yukarıda açıklanan hedefler doğrultusunda geliştirilen tüm modeller sırasıyla ele alınacak; her bir modelin mimarisi, eğitim süreci, performans ölçütleri ve bir sonraki aşamaya nasıl katkı sağladığı detaylı biçimde açıklanacaktır.


4.6.1. Model 1 – Temel LSTM yapısı ile günlük sıcaklık tahmini

Bu model, geçmiş saatlik meteorolojik verileri kullanarak günlük sıcaklık değerlerinin tahmin edilmesini amaçlayan temel bir LSTM mimarisi ile geliştirilmiştir. Modelin girişinde rüzgâr hızı (RuzgarHizMS), rüzgâr yönü (RuzgarYonDerece), saat (Saat), basınç (SaatlikAktuelBasinc), kar kalınlığı (SaatlikMevcutKarKalinligi), nem (SaatlikNispiNem) ve ortalama rüzgâr hızı (SaatlikOrtalamaRuzgarhizi) olmak üzere toplam yedi değişken kullanılmıştır. Girdi verileri Z-score normalizasyonuna tabi tutulmuş, veri seti %80 eğitim ve %20 test olacak şekilde bölünmüştür.

Model mimarisi `sequenceInputLayer(7) → lstmLayer(100, 'OutputMode','last') → fullyConnectedLayer(1) → regressionLayer` şeklindedir. Girdi dizileri bir zaman adımı olacak biçimde hazırlanmıştır (`timeStep = 1`). Eğitim, ‘adam’ optimizasyon algoritması ile 30 epoch boyunca, mini-batch boyutu 128 seçilerek ve karıştırma (Shuffle) “never” olacak şekilde gerçekleştirilmiştir. Doğrulama kümesi ayrılmamış, eğitim süreci MATLAB eğitim arayüzü üzerinden izlenmiştir.

Model Eğitimi


Eğitim sürecine ait RMSE ve loss eğrileri Şekil 4.4’de verilmiştir. İlk iterasyonlarda yüksek başlayan RMSE’nin kısa sürede belirgin biçimde azaldığı, sonrasında dalgalı fakat düşük genlikli bir bantta seyrettiği görülmektedir. Loss eğrisi de benzer şekilde hızlı bir düşüşten sonra kararlı bir plato davranışı göstermiştir. Doğrulama verisi ayrılmadığından aşırı öğrenme doğrudan izlenemese de, eğrilerde keskin sıçramalar ve büyüyen varyans gözlenmediği için eğitim aşamasında belirgin bir overfitting belirtisi saptanmamıştır.



Şekil 4.4. Model 1 eğitim süreci RMSE ve Loss eğrileri

Modelin Değerlendirilmesi

Test kümesinde elde edilen tahminler Şekil 4.5’te gerçek değerlerle birlikte gösterilmiştir. Zaman serisinin daha okunaklı sunumu için hem gerçek hem de tahmin serilerine 100 örnek pencereyi hareketli ortalama uygulanmıştır. Grafik incelendiğinde genel trendin ve mevsimsel dalgalanmanın büyük ölçüde takip edildiği; ancak kısa süreli, ani değişimlerde tahminlerin genlik açısından zayıf kaldığı dikkati çekmektedir. Sayısal olarak test metrikleri $MAE = 5.6739$, $MSE = 48.6941$ ve $RMSE = 6.9781$ olarak hesaplanmıştır. Bu sonuçlar, temel tek adımlı LSTM yapısının genel eğilimleri yakalayabildiğini; ancak kısa ölçekli keskin dalgalanmaları temsil etmede sınırlılıkları bulunduğunu göstermektedir.



Şekil 4.5. Model 1 gerçek ve tahmin edilen sıcaklık değerlerinin karşılaştırması (Hareketli ortalama uygulanmış)


4.6.2. Model 2 – 2 Katmanlı LSTM ile kısa vadeli sıcaklık tahmini (12 Zaman Adımı)

Bu model, geçmiş saatlik meteorolojik gözlemlerden yararlanarak bir sonraki zaman adımıdaki sıcaklık değerini tahmin etmeyi amaçlamaktadır. Girişte rüzgâr hızı (RuzgarHizMS), rüzgâr yönü (RuzgarYonDerece), saat (Saat), basınç (SaatlikAktuelBasinc), kar kalınlığı (SaatlikMevcutKarKalinligi), bağıl nem (SaatlikNispiNem) ve ortalama rüzgâr hızı (SaatlikOrtalamaRuzgarhizi) olmak üzere yedi değişken kullanılmıştır. Girdi özellikleri Z-score yöntemiyle normalize edilmiş, veriler pencerelenerek 12 saatlik giriş sekansı → 1 saat sonrası hedef biçiminde düzenlenmiş ve veri seti %80 eğitim, %20 test olarak ayrılmıştır.

Model mimarisi `sequenceInputLayer(7) → lstmLayer(100, 'OutputMode','sequence') → lstmLayer(50, 'OutputMode','last') → fullyConnectedLayer(1) → regressionLayer` şeklindedir. Eğitim ‘adam’ algoritmasıyla 30 epoch boyunca, mini-batch boyutu 128 ve “Shuffle=never” ayarıyla yürütülmüştür; doğrulama kümesi ayrılmamış, eğitim seyri MATLAB arayüzü üzerinden izlenmiştir.

Model Eğitimi


Eğitim sürecine ait RMSE ve loss eğrileri Şekil 4.6’te sunulmuştur. Başlangıçta yüksek olan hata değerlerinin ilk aşamada hızlı biçimde azaldığı, devamında ise dalgalı ancak giderek daralan bir bantta seyrettiği gözlenmektedir. Loss eğrisindeki hızlı düşüş sonrası plato davranışı, modelin öğrenme sürecinde kararlılığa ulaştığını göstermektedir. Doğrulama verisi bulunmadığından aşırı uyumu doğrudan izlemek mümkün değildir; yine de Şekil 4.6’te belirgin bir varyans artışı ya da keskin sıçramalar görülmemektedir.



Şekil 4.6. Model 2 eğitim süreci RMSE ve Loss eğrileri

Modelin Değerlendirilmesi

Test kümesinde gerçek ve tahmin serileri, okunabilirliği artırmak için 100 örnek pencereli hareketli ortalama uygulanarak Şekil 4.7’te karşılaştırılmıştır. Genel eğilim ve mevsimsel dalga çoğunlukla yakalanmakla birlikte, kısa süreli keskin değişimlerde tahmin genliğinin yer yer yetersiz kaldığı görülmektedir. Sayısal performans metrikleri $MAE = 5.7738$, $MSE = 55.6365$ ve $RMSE = 7.4590$ olarak hesaplanmıştır. Model 1 ile kıyaslandığında ($MAE = 5.6739$, $MSE = 48.6941$, $RMSE = 6.9781$), Model 2’nin hata değerlerinin bir miktar daha yüksek olduğu, bu nedenle doğruluk açısından Model 1’e kıyasla sınırlı bir iyileşme sağladığı anlaşılmaktadır.



Şekil 4.7. Model 2 gerçek ve tahmin edilen sıcaklık değerlerinin karşılaştırması (Hareketli Ortalama Uygulanmış)


4.6.3. Model 3 – LSTM+GRU ile kısa vadeli sıcaklık tahmini (12 Zaman Adımı)

Bu model, geçmiş saatlik meteorolojik verilerden yararlanarak bir sonraki saatlik sıcaklık değerinin tahmin edilmesini amaçlayan melez bir derin öğrenme yapısı ile tasarlanmıştır. Modelin girişinde rüzgâr hızı (RuzgarHizMS), rüzgâr yönü (RuzgarYonDerece), saat (Saat), basınç (SaatlikAktuelBasinc), kar kalınlığı (SaatlikMevcutKarKalinligi), bağıl nem (SaatlikNispiNem) ve ortalama rüzgâr hızı (SaatlikOrtalamaRuzgarhizi) olmak üzere toplam yedi değişken kullanılmıştır. Bu veriler Z-score normalizasyonuna tabi tutulmuş ve 12 saatlik veri penceresi kullanılarak bir sonraki saatlik sıcaklığın tahmin edilmesine yönelik giriş-çıkış çiftleri oluşturulmuştur. Veri seti %80 eğitim ve %20 test olacak şekilde bölünmüştür.

Model mimarisi, giriş katmanı olarak sequenceInputLayer, ardından 64 birimli bir LSTM katmanı ve %20 oranında dropout katmanı, sonrasında 32 birimli bir GRU katmanı, tek bir fullyConnectedLayer ve regressionLayer katmanlarından oluşmaktadır. Eğitim süreci, ‘adam’ optimizasyon algoritması ile 30 epoch boyunca yürütülmüş, mini-batch boyutu 64 olarak seçilmiş ve veri karıştırma (shuffle) işlemi yapılmamıştır. Eğitim sırasında doğrulama verisi olarak test kümesi kullanılmış, doğrulama çıktıları her 1000 iterasyonda elde edilmiştir.

Model Eğitimi

Modelin eğitim sürecinde oluşan RMSE ve loss eğrileri Şekil 4.8’de sunulmuştur. Eğitim başlangıcında yüksek değerlerle başlayan RMSE, ilk birkaç iterasyonda hızlı bir düşüş göstermiş ve ardından dalgalı fakat daralan bir bant içinde seyretmiştir. Eğitim ve doğrulama eğrileri genel olarak paralel bir eğilim göstermiş, bu durum modelin öğrenme sürecinde tutarlılığın korunduğunu düşündürmektedir. Loss eğrisi de benzer şekilde, başlangıçta hızlı bir azalma göstermiş ve ilerleyen iterasyonlarda plato davranışı sergilemiştir. Smoothed eğriler incelendiğinde, hem eğitim hem de doğrulama süreçlerinde dalgalanma olmakla birlikte, genel eğilimin istikrarlı bir şekilde azaldığı gözlenmektedir. Eğitim ve doğrulama eğrilerinin birbirine yakın seyretmesi, belirgin bir aşırı öğrenme eğiliminin olmadığını göstermektedir.




Şekil 4.8. Model 3 eğitim süreci RMSE ve Loss eğrileri

Modelin Değerlendirilmesi

Modelin test verisi üzerindeki performansı Şekil 4.9’de gösterilmiştir. Gerçek sıcaklık değerleri ile modelin tahmin ettiği değerler karşılaştırıldığında, genel trendin ve mevsimsel dalgaların büyük ölçüde yakalandığı görülmektedir. Ancak kısa süreli ani sıcaklık değişimlerinde tahmin eğrisinin genlik bakımından yetersiz kaldığı, bu durumun özellikle keskin geçişlerde daha belirgin olduğu anlaşılmaktadır. Grafiklerin okunabilirliğini artırmak amacıyla, hem gerçek hem de tahmin edilen değerler için 100 pencere uzunluğunda hareketli ortalama uygulanmıştır. Sayısal değerlendirme sonucunda test kümesi için MAE = 5.9054, MSE = 57.7613 ve RMSE = 7.6001 değerleri elde edilmiştir. Bu sonuçlar, Model 1 (MAE = 5.6739, MSE = 48.6941, RMSE = 6.9781) ve Model 2’ye (MAE = 5.7738, MSE = 55.6365, RMSE = 7.4590) kıyasla hata oranlarının

bir miktar yükseldiğini ve modelin doğruluk bakımından önceki iki yapıdan daha düşük performans gösterdiğini ortaya koymaktadır.



Şekil 4.9. Model 3 gerçek ve tahmin edilen sıcaklık değerlerinin karşılaştırması (Hareketli Ortalama Uygulanmış)


4.6.4. Model 4 – Geliştirilmiş LSTM+GRU melez yapı ile kısa vadeli sıcaklık tahmini (12 Zaman Adımı)

Bu model, geçmiş saatlik meteorolojik veriler kullanılarak bir sonraki saatlik sıcaklık değerinin tahmin edilmesi amacıyla geliştirilmiştir. Girişte rüzgâr hızı (RuzgarHizMS), rüzgâr yönü (RuzgarYonDerece), saat (Saat), basınç (SaatlikAktuelBasinc), kar kalınlığı (SaatlikMevcutKarKalinligi), bağıl nem (SaatlikNispiNem) ve ortalama rüzgâr hızı (SaatlikOrtalamaRuzgarhizi) olmak üzere toplam yedi değişken yer almaktadır. Girdi özellikleri Z-score normalizasyonuna tabi tutulmuş; veriler 12 saatlik giriş penceresi → 1 saat sonrası hedef biçiminde dizilenmiş ve veri seti %80 eğitim, %20 test olacak şekilde ayrılmıştır.

Model mimarisi `sequenceInputLayer(7) → lstmLayer(128, 'OutputMode','sequence') → dropoutLayer(0.3) → gruLayer(64, 'OutputMode','last') → fullyConnectedLayer(1) → regressionLayer` şeklindedir. Eğitim ‘adam’ algoritması ile 30 epoch boyunca, mini-batch boyutu 64 ve “Shuffle=never” ayarıyla yürütülmüştür. Doğrulama için test dilimi ValidationData olarak izlenmiş, doğrulama geri bildirimi her 100 iterasyonda alınmıştır.

Model Eğitimi


Eğitim sürecine ilişkin RMSE ve loss eğrileri Şekil 4.10'de verilmiştir. Başlangıçta yüksek düzeyde olan RMSE'nin ilk aşamada hızlı biçimde azaldığı, sonrasında ise dalgalı fakat gittikçe daralan bir bant içinde seyrettiği görülmektedir. Doğrulama işaretleri, eğitim bandının üzerinde fakat ona paralel bir düzeyde konumlanmakta; epoch sonuna doğru yaklaşık 7.9 civarında sabitlenmektedir. Loss eğrisinde de benzer biçimde, erken safhalarda belirgin bir düşüş ve ilerleyen iterasyonlarda plato davranışı gözlenmektedir. Bu görünüm, eğitim boyunca hatanın düzenli biçimde azaldığını ve doğrulama ile eğitim eğrilerinin ayrışmasının sınırlı kaldığını göstermektedir.



Şekil 4.10. Model 4 eğitim süreci RMSE ve Loss eğrileri

Modelin Değerlendirilmesi

Test kümesindeki performans Şekil 4.11'da gösterilmektedir. Okunabilirliği artırmak amacıyla, gerçek ve tahmin serilerine 100 örnek pencereyi hareketli ortalama uygulanmıştır. Modelin test setinde elde ettiği $MAE = 6.1116$, $MSE = 62.9808$ ve $RMSE = 7.9360$ değerleri, hata seviyesinin önceki modellere kıyasla yükseldiğini göstermektedir. Özellikle RMSE değerinin, Model 3'te elde edilen 7.6001 değerinden daha yüksek olması, bu yapının önceki mimariye göre ani sıcaklık değişimlerini yakalamada daha fazla sapma ürettiğini işaret etmektedir. Genel olarak Model 4, trend ve mevsimsel yapıyı korumakta başarılı olsa da, ani geçişler ve kısa vadeli dalgalanmalarda önceki modellere göre daha zayıf bir uyum sergilemiştir.



Şekil 4.11. Model 4 gerçek ve tahmin edilen sıcaklık değerlerinin karşılaştırması (Hareketli Ortalama Uygulanmış)


4.6.5. Model 5 – Mevsimsel bilgi eklenmiş LSTM+GRU ile kısa vadeli sıcaklık tahmini (24 Zaman Adımı)

Bu model, geçmiş saatlik meteorolojik verilerden bir sonraki saatlik sıcaklığın kestirimini amaçlamakta ve girdilere mevsimsellik taşıyan takvimsel öznitelikler eklenmektedir. Giriş değişkenleri; basınç (SaatlikAktuelBasinc), bağıl nem (SaatlikNispiNem), ortalama rüzgâr hızı (SaatlikOrtalamaRuzgarhizi), mevcut kar kalınlığı (SaatlikMevcutKarKalinligi), rüzgâr yönü (RuzgarYonDerece), rüzgâr hızı (RuzgarHizMS) ile takvimden türetilen ay (Ay) ve saat (SaatDegeri) olmak üzere sekiz özelliktir. Özellikler normalize edilmiş, dizileme 24 saatlik giriş penceresi → 1 saat sonrası hedef biçiminde kurulmuş ve veri kümesi %80 eğitim, %20 test olarak ayrılmıştır.

Model mimarisi `sequenceInputLayer(8) → lstmLayer(128, 'OutputMode','sequence') → dropoutLayer(0.2) → gruLayer(64, 'OutputMode','last') → fullyConnectedLayer(32) → reluLayer → fullyConnectedLayer(1) → regressionLayer` bileşenlerinden oluşmaktadır. Eğitim ‘adam’ algoritması ile 30 epoch boyunca, mini-batch boyutu 64 ve “Shuffle=never” ayarıyla yürütülmüş; doğrulama için test dilimi ValidationData olarak kullanılmış ve geribildirim her 1000 iterasyonda alınmıştır.

Model Eğitimi


Eğitim sürecine ait RMSE ve loss eğrileri Şekil 4.12’de gösterilmektedir. Eğitim başlangıcında yüksek seyreden hata değerlerinin erken safhada hızlı bir azalma gösterdiği, devamında dalgalı fakat giderek daralan bir bantta kararlılaştığı izlenmiştir. Doğrulama işaretlerinin eğitim bandıyla paralel ilerleyip epoch sonuna doğru düşük bir seviyede sabitlenmesi, öğrenme sürecinin düzenli ve tutarlı ilerlediğini göstermektedir.



Şekil 4.12. Model 5 eğitim süreci: RMSE ve Loss eğrileri

Modelin Değerlendirilmesi

Test kümesi performansı Şekil 4.13’de sunulmuştur. Okunabilirliği artırmak amacıyla gerçek ve tahmin serileri için 100 örnek pencereli hareketli ortalama uygulanmıştır. Grafik incelendiğinde genel eğilim ve mevsimsel dalganın yüksek bir örtüşme ile takip edildiği, doruk ve çukur bölgelerde faz uyumunun önceki modellere kıyasla daha tutarlı olduğu; kısa süreli ani değişimlerde ise genlik farklarının belirgin biçimde azaldığı görülmektedir. Sayısal olarak modelin test setinde $MAE = 3.2586$, $MSE = 17.7958$ ve $RMSE = 4.2185$ değerlerine ulaştığı hesaplanmıştır. Bu düzey, önceki dört modelin genel hata seviyelerine göre belirgin bir iyileşmeye işaret etmektedir; örneğin RMSE, Model 3’teki ~ 7.60 düzeyinden bu modelde ~ 4.22 düzeyine gerilemiştir. Genel olarak Model 5, hem trend hem de mevsimsel bileşenlerin temsilinde önceki modellere göre daha başarılı bir uyum sergilemiştir.



Şekil 4.13. Model 5 gerçek ve tahmin edilen sıcaklık değerlerinin karşılaştırması (Hareketli Ortalama Uygulanmış)


4.6.6. Model 6 – Haftalık ortalama sıcaklık tahmini (LSTM, 4 Haftalık Girdi)

Bu model, saatlik gözlemlerden türetilen haftalık ortalama sıcaklık serisini kullanarak bir sonraki haftanın ortalama sıcaklığını tahmin etmektedir. Veri Z-score ile standartlaştırılmış; dizileme 4 haftalık giriş penceresi → 1 hafta sonrası hedef olacak biçimde kurulmuş ve küme %80 eğitim, %20 test olarak ayrılmıştır.

Model mimarisi `sequenceInputLayer(1) → lstmLayer(64, 'OutputMode','last') → dropoutLayer(0.2) → fullyConnectedLayer(1) → regressionLayer` bileşenlerinden oluşmaktadır. Eğitim, ‘adam’ algoritmasıyla 100 epoch, mini-batch 16 ve “Shuffle=never” ayarlarıyla yürütülmüş; test dilimi `ValidationData` olarak izlenmiş ve doğrulama geri bildirimi her 10 iterasyonda alınmıştır.

Model Eğitimi


Eğitim sürecine ait RMSE ve loss eğrileri Şekil 4.14’de sunulmaktadır. Başlangıçta yüksek seyreden hata değerlerinin erken safhada hızla azaldığı; devamında dalgalı fakat giderek daralan bir bandta plato davranışı sergilediği görülmektedir. Doğrulama işaretlerinin eğitim bandına paralel ilerlemesi ve epoch sonuna doğru kararlı bir düzeye yerleşmesi, haftalık ölçekte öğrenmenin tutarlı biçimde sürdüğünü göstermektedir.



Şekil 4.14. Model 6 eğitim süreci RMSE ve Loss eğrileri

Modelin Değerlendirilmesi

Test kümesindeki gerçek ve tahmin serileri Şekil 4.15'te verilmiştir. Haftalık ortalama yapısı nedeniyle seri daha düzgün seyrederken, grafik üzerinde genel eğilim ve mevsimsel dalgalardan yüksek bir örtüşme ile takip edildiği; doruk ve çukur bölgelerde faz uyumunun belirgin olduğu gözlenmektedir. Modelin test performansı $MAE = 2.4782$, $MSE = 10.0417$ ve $RMSE = 3.1689$ 'dur. Saatlik/dakikalık çözünürlükte kurulan önceki modellerle genel düzeyde kıyaslandığında, haftalık ölçeğe geçişin kısa vadeli dalgalanmaları doğal olarak yumuşattığı; bu nedenle hata seviyelerinin belirgin biçimde daha düşük gerçekleştiği görülmektedir. Nitekim saatlik ölçekteki en iyi sonuçlardan biri olan Model 5'te $RMSE \approx 4.22$ iken, Model 6'da $RMSE$ 'nin 3.17 düzeyine indiği izlenmektedir. Ölçek farkı doğrudan karşılaştırmayı sınırlasa da, haftalık modelin eğilim ve mevsimsellik bileşenlerini daha istikrarlı biçimde temsil ettiği söylenebilir.



Şekil 4.15. Model 6 haftalık gerçek ve tahmin edilen sıcaklık değerlerinin karşılaştırması

4.6.7. Model 7 – Haftalık ortalama sıcaklık tahmini (LSTM+GRU, 4 Haftalık Girdi)


Bu modelde, haftalık sıcaklık tahmini amacıyla LSTM ve GRU katmanlarının birlikte kullanıldığı melez bir yapı geliştirilmiştir. Zaman serisinin geçmiş dört haftalık penceresi giriş olarak kullanılmış, hedef değişken ise bir sonraki haftanın ortalama sıcaklık değeri olarak belirlenmiştir. Haftalık ortalama serisi Z-score yöntemiyle normalize edilmiş, eğitim–test ayrımı %80–%20 oranında yapılmıştır.

Model mimarisi, sequenceInputLayer (boyut: 1) ile başlamış; 128 birimli LSTM (OutputMode='sequence'), %30 dropout, 64 birimli GRU (OutputMode='last') ve ardından fullyConnectedLayer(1) ile regressionLayer katmanlarıyla tamamlanmıştır. Eğitimde adam optimizasyonu, MaxEpochs=100, MiniBatchSize=16, Shuffle=never ayarları kullanılmış; test kümesi ValidationData olarak tanımlanmış ve doğrulama çıktıları 10 iterasyonda bir alınmıştır.

Model Eğitimi

Modelin eğitim sürecine ait RMSE ve loss eğrileri Şekil 4.16’te sunulmuştur. Başlangıçta yüksek seyreden RMSE değerlerinin kısa sürede ≈ 0.4 düzeyine gerileyerek burada kararlılaştığı gözlenmiştir. Loss eğrisi benzer biçimde düşmüş ve düşük bir bandta


seyretmiştir. Doğrulama işaretlerinin eğitim bandıyla paralel ilerlemesi, öğrenme sürecinin dengeli biçimde sürdüğünü göstermektedir.



Şekil 4.16. Model 7 eğitim süreci RMSE ve Loss eğrileri

Modelin Değerlendirilmesi

Modelin test verisi üzerindeki performansı Şekil 4.17’te sunulmuştur. Gerçek haftalık sıcaklık ortalamaları ile modelin tahmin ettiği değerler arasında yüksek düzeyde uyum gözlenmektedir; mevsimsel dalga yapısı ve artış–azalış dönemleri büyük ölçüde doğru izlenmiştir. Test kümesi için $MAE = 2.4896$, $MSE = 10.1286$ ve $RMSE = 3.1825$ elde edilmiştir. Bu değerler, bir önceki haftalık yapı olan Model 6 ile aynı mertebede bir doğruluğa işaret etmektedir; RMSE farkı (Model 6 ≈ 3.17) oldukça küçüktür. Grafik incelemesinde, özellikle mevsimsel döngülerin tepe bölgelerinde tahmin eğrisinin zaman zaman gerçek değerın hafif üzerine çıktığı görülmektedir; bu durum, penceredeki son haftalarda artış eğilimi baskınken Model 7’nin ardışık zaman adımlarını LSTM(‘sequence’)→GRU zinciriyle birlikte değerlendirmesi nedeniyle yükseliş momentumunu kısa süreli olarak korumasıyla tutarlıdır.



Şekil 4.17. Model 7 haftalık gerçek ve tahmin edilen sıcaklık değerlerinin karşılaştırması

4.6.8. Model 8 – Derin LSTM+GRU ile haftalık ortalama sıcaklık tahmini (4 Hafta → 1 Hafta)


Bu modelde, saatlik sıcaklıklardan türetilen haftalık ortalama seri kullanılarak bir sonraki haftanın ortalama sıcaklık değeri tahmin edilmiştir. Geçmiş dört haftalık pencere giriş olarak alınmış, hedef bir sonraki haftanın ortalaması olarak belirlenmiştir. Eğitim–test ayrımı %80–%20 oranındadır. Bu kurulumda haftalık seri normalizasyon uygulanmadan (ham değerlerle) modele verilmiştir.

Model mimarisi, `sequenceInputLayer` (boyut: 1) ile başlayıp `LSTM(128, OutputMode='sequence') → Dropout(0.3) → LSTM(64, 'sequence') → GRU(64, 'last') → FC(32) → ReLU → FC(1) → regressionLayer` zinciriyle derin bir melez yapı oluşturulmuştur. Eğitimde adam optimizasyonu, `MaxEpochs=200`, `MiniBatchSize=16`, `Shuffle=never` ayarları kullanılmış; test dilimi `ValidationData` olarak izlenmiş ve doğrulama çıktıları her 10 iterasyonda alınmıştır.

Model Eğitimi

Modelin eğitim sürecine ait RMSE ve loss eğrileri Şekil 4.18’de sunulmuştur. Hata değerlerinin erken safhada hızlı biçimde azaldığı, ilerleyen bölümlerde ise daralan bir dalgalanma bandı içinde kararlılaştığı gözlenmektedir. Doğrulama eğrilerinin eğitim


bantlarını genel olarak paralel izlemesi, öğrenme sürecinin dengeli seyrettiğine işaret etmektedir. Erken durdurma devre dışı bırakıldığından eğitim, belirlenen epoch sayısı tamamlanıncaya kadar sürmüştür.



Şekil 4.18. Model 8 eğitim süreci RMSE ve Loss eğrileri (Validation dahil)

Modelin Değerlendirilmesi

Modelin test verisi üzerindeki başarımı Şekil 4.19’de gösterilmiştir. Gerçek haftalık ortalamalar ile tahminler genel eğilim ve mevsimsel dalga bakımından yüksek bir örtüşme sergilemektedir; bununla birlikte bazı kesitlerde genlik sıkışması ve yer yer faz farkı dikkat çekmektedir. Sayısal olarak $MAE = 2.8372$, $MSE = 13.6331$ ve $RMSE = 3.6923$ elde edilmiştir. Haftalık ölçekte kurulan önceki yapılarla kıyaslandığında, RMSE değerinin Model 6 (≈ 3.17) ve Model 7 (≈ 3.18) seviyelerinin üzerinde kaldığı görülmektedir; bu farklılık, Model 8’in daha derin yığılmış mimarisi ile birlikte ham değerler üzerinde eğitilmesinin (Model 6–7’deki Z-score standardizasyonundan farklı olarak) ölçek duyarlılığını artırması ve tepe/çukur bölgelerinde genlik kalibrasyonunu zorlaştırmasıyla uyumludur.



Şekil 4.19. Model 8 gerçek ve tahmin edilen haftalık ortalama sıcaklık değerleri

4.6.9. Model 9 – Haftalık ortalama sıcaklık tahmini (Derin LSTM+GRU + Batch Normalization, 4 hafta → 1 hafta)


Bu modelde, saatlik sıcaklıklardan türetilen haftalık ortalama seri kullanılarak bir sonraki haftanın ortalama sıcaklığı öngörülmüştür. Geçmiş dört haftalık pencere giriş olarak kullanılmış, hedef değişken bir sonraki haftanın ortalaması olarak tanımlanmıştır. Eğitim–test ayrımı %80–%20 oranındadır; seri ham değerleriyle modele verilmiştir.

Model mimarisi $\text{sequenceInputLayer}(1) \rightarrow \text{LSTM}(128, \text{'sequence'}) \rightarrow \text{Dropout}(0.2) \rightarrow \text{BatchNormalization} \rightarrow \text{LSTM}(64, \text{'sequence'}) \rightarrow \text{FC}(32) \rightarrow \text{GRU}(64, \text{'last'}) \rightarrow \text{ReLU} \rightarrow \text{FC}(1) \rightarrow \text{regressionLayer}$ zincirinden oluşan derin bir melez yapıdır. Eğitim adam algoritmasıyla, $\text{MaxEpochs}=250$, $\text{MiniBatchSize}=16$ ve $\text{Shuffle}=\text{never}$ ayarlarında yürütülmüş; test dilimi ValidationData olarak izlenmiş ve doğrulama çıktıları her 10 iterasyonda alınmıştır.

Model Eğitimi

Eğitim sürecine ait RMSE ve loss eğrileri Şekil 4.20 de sunulmuştur. Hata değerleri başlangıçta hızlı bir düşüş göstermiş, ardından giderek yataylaşan bir bantta ilerlemiştir.


Doğrulama eğrisi eğitim bandının belirgin biçimde üzerinde seyretmiş ve epoch sonunda Validation RMSE ≈ 4.19 düzeyinde plato davranışı sergilemiştir. Erken durdurma kapalı olduğundan eğitim, belirlenen epoch sayısına kadar sürmüştür.



Şekil 4.20. Model 9 eğitim süreci RMSE ve Loss eğrileri (Validation dâhil)

Modelin Değerlendirilmesi

Test verisi üzerindeki performans Şekil 4.21’de gösterilmiştir. Grafik genel eğilim ve mevsimsel dalga bakımından uyumludur; buna karşın tepe ve çukur bölgelerde genliklerin sistematik olarak daha düşük tahmin edildiği ve yer yer kısa bir faz gecikmesi görüldüğü dikkati çekmektedir. Sayısal olarak modelin test seti sonuçları MAE = 3.3805, MSE = 17.5905 ve RMSE = 4.1941’dir. Doğruluk açısından, bir önceki haftalık yapı olan Model 8’e göre RMSE’nin yükseldiği (Model 8 ≈ 3.69) ve Model 6–7’nin ulaştığı düzeyin gerisinde kalındığı anlaşılmaktadır. Bu tablo, Model 9’daki daha derin yığılmış mimari ile Batch Normalization ve ara FC→GRU geçişinin, ham ölçekte eğitilen haftalık seride genlik kalibrasyonunu nispeten sıkıştırması ve doğrulama eğrisiyle eğitim eğrisi arasında kalıcı bir genel performans farkı oluşmasıyla uyumludur.



Şekil 4.21. Model 9 gerçek ve tahmin edilen haftalık ortalama sıcaklık değerleri


4.6.10. Model 10 – Haftalık ortalama sıcaklık tahmini (LSTM, Lookback=10 hafta → 1 hafta)

Bu modelde, saatlik ölçümlerden türetilen haftalık ortalama sıcaklık serisi kullanılarak bir sonraki haftanın ortalaması tahmin edilmiştir. Girdi olarak son 10 haftanın (lookback=10) Z-score ile normalize edilmiş değerleri alınmış, hedef değişken bir sonraki haftanın ortalaması olarak tanımlanmıştır. Eğitim–test ayrımı %80–%20 oranındadır.

Model mimarisi `sequenceInputLayer(1) → lstmLayer(100, 'sequence') → ReLU → lstmLayer(50, 'last') → ReLU → fullyConnectedLayer(1) → regressionLayer` bileşenlerinden oluşmaktadır. Eğitim adam algoritmasıyla `MaxEpochs=250`, `MiniBatchSize=128`, `Shuffle=never` ayarlarında yürütülmüş; test kümesi `ValidationData` olarak izlenmiş ve doğrulama çıktıları 10 iterasyonda bir alınmıştır.

Model Eğitimi

Eğitime ilişkin RMSE ve loss eğrileri Şekil 4.22’de gösterilmiştir. Hata değerleri ilk aşamada hızlı bir düşüş sergilemiş, ardından dar bir bantta yatay seyretmiştir. Doğrulama eğrilerinin eğitim bandına paralel ilerlemesi, öğrenmenin dengeli biçimde sürdüğünü ve erken durdurma kapalıyken de aşırı uyum belirtisinin belirginleşmediğini göstermektedir.




Şekil 4.22. Model 10 eğitim süreci RMSE ve Loss eğrileri (Validation dâhil)

Modelin Değerlendirilmesi

Test verisi üzerindeki performans Şekil 4.23'te sunulmuştur. Gerçek ve tahmin serileri mevsimsel dalga ve uzun dönem eğilim açısından yüksek uyum sergilemektedir; özellikle tepe/çukur bölgelerde faz hizasının önceki haftalık modellere göre daha tutarlı olduğu gözlenmektedir. Test kümesi için $MAE = 2.2995$, $MSE = 8.9730$ ve $RMSE = 2.9955$ elde edilmiştir. Bu sonuç, haftalık ölçekte kurulan önceki yapılara kıyasla en düşük hata düzeyine işaret etmektedir: Model 6–7'nin ≈ 3.17 – 3.18 bandı ile Model 8 (≈ 3.69) ve Model 9 (≈ 4.19) değerlerinin altına inilmiştir. İyileşme, kod farklarıyla tutarlıdır:

(i) Lookback'ın 10 haftaya çıkarılması mevsimsel geçişler için daha geniş bağlam sunmuş ve kısa süreli faz sapmalarını azaltmıştır.

(ii) Mimariyin yalnız LSTM katmanlarıyla sadeleştirilmesi (GRU/BN/ara FC katmanları olmadan) genlik kalibrasyonunu dengede tutmuş; haftalık ortalama serinin pürüzsüz yapısıyla daha iyi örtüşmüştür.




Şekil 4.23. Model 10 gerçek ve tahmin edilen haftalık ortalama sıcaklık değerleri

4.6.11. Model 11 – Aylık ortalama sıcaklık tahmini (Çoklu Girdi, Lookback=10)

Model 11’de zamansal çözünürlük aylık ölçeğe alınmış, giriş olarak basınç, nem, ortalama rüzgâr hızı, yatay görüş, mevcut kar kalınlığı, rüzgâr yönü ve rüzgâr hızı gibi değişkenlerin aylık ortalamaları kullanılmıştır. Amaç, geçmiş 10 aya ait çok değişkenli dizilerden bir sonraki ayın ortalama sıcaklığını tahmin etmektir. Mimari, 100 birimli LSTM (OutputMode='sequence')–ReLU–50 birimli LSTM (OutputMode='last')–ReLU–tam bağlantılı–regresyon şeklindedir.

Modelin Eğitimi


Eğitim süreci Şekil 4.24’de verilmiştir. Doğrulama RMSE’si başta hızlı düşmüş, ardından ~0.30–0.35 (normalize ölçekte) bandında kararlı bir görünüm sergilemiştir. Eğitim ve doğrulama eğrilerinin birlikte ve istikrarlı ilerlemesi, modelin aydan aya değişimleri fazla dalgalanmadan öğrendiğini göstermektedir.



Şekil 4.24. Model 11 eğitim süreci RMSE ve Loss eğrileri (Validation dâhil)

Modelin Değerlendirilmesi

Test kümesinde $MAE = 1.9470$, $MSE = 5.4551$ ve $RMSE = 2.3356$ elde edilmiştir. Şekil 4.25'te görüldüğü üzere tahmin eğrisi mevsimsel dalgayı düzgün biçimde izlemekte; yaz tepe ve kış diplerine yakınsar nitelikte sonuçlar üretmektedir. Aylık ortalamaya geçtiğimiz için seri daha pürüzsüzdür; bu yüzden hataların haftalık modellere göre daha düşük çıkması doğaldır. Çoklu girdilerin kullanımı da (nem, basınç vb.) mevsimsel hareketi açıklamada modele ek destek sağlamıştır.




Şekil 4.25. Model 11 gerçek ve tahmin edilen aylık ortalama sıcaklık değerleri

4.6.12. Model 12 — LSTM+GRU (Lookback=10) ile çok değişkenli aylık ortalama sıcaklık tahmini

Model 12, aylık sıcaklık tahmini için çok değişkenli (basınç, nem, rüzgâr hızı vb.) girişlerle çalışan bir LSTM+GRU yapısıdır. Girdi olarak her ay için geriye dönük 10 aylık pencere kullanılmış, hedef değişken bir sonraki ayın ortalama sıcaklığı olarak tanımlanmıştır. Mimari sırayla: sequenceInputLayer → 100 birimli LSTM (OutputMode='sequence') → ReLU → 64 birimli GRU (OutputMode='last') → ReLU → tek nöronlu tam bağlı katman ve regresyon çıkışıdır. Eğitim %80–%20 bölünmüş veriyle, Adam optimizasyonu ve MiniBatchSize=8 ile gerçekleştirilmiştir.

Model Eğitimi

Eğitim sürecine ait RMSE ve loss eğrileri Şekil 4.26’da verilmiştir. İlk iterasyonlarda hızlı bir düşüşün ardından doğrulama RMSE’si 0.35–0.45 bandında dalgalanarak plato yapmaktadır. Bu dalgalanma, küçük mini-batch seçimi (8) ve GRU katmanının eklenmesiyle artan zamanlama hassasiyetinin bir sonucudur; bunun karşılığı olarak eğitim eğrisi düşük seviyede kararlı kalmıştır.




Şekil 4.26. Model 12 eğitim süreci RMSE ve Loss eğrileri (Validation dâhil)

Modelin Değerlendirilmesi

Test kümesi üzerinde $MAE = 2.4088$, $MSE = 8.2813$ ve $RMSE = 2.8777$ elde edilmiştir. Gerçek ve tahmin edilen aylık ortalama sıcaklıkların karşılaştırması Şekil 4.27’de görülmektedir. Eğriler, mevsimsel dalgalanımın fazını ve genliğini genel olarak doğru izlemektedir; yaz tepelerinde yer yer hafif düşük tahmin (underestimation), kış diplerinde ise hafif yüksek tahmin (overestimation) eğilimi gözlenmektedir. Bu desen, Model 11’e kıyasla (aynı lookback=10, aynı girdi seti) iki yapısal farkla tutarlıdır:

- (i) LSTM’den sonra ikinci bir LSTM yerine GRU kullanılması, bellek kapıları sayesinde geçişleri biraz daha “yumuşatıp” aşırı uçları sınırlandırabilir;
- (ii) Mini-batch’in 128’den 8’e düşmesi, doğrulama eğrisinde görülen küçük salınımları artırırken tepe/dip bölgelerinde daha temkinli (daha düz) tahminlere yol açabilir.

Sonuç olarak Model 12’nin doğruluğu aylık ölçekte yüksektir; RMSE değeri Model 11’in (~2.34) biraz üzerindedir ancak mevsimsel örüntüleri benzer başarıyla yakalamaktadır.




Şekil 4.27. Model 12 gerçek ve tahmin edilen aylık ortalama sıcaklık değerleri

4.6.13. Model 13 – Aylık ortalama sıcaklık tahmini (3 Girdi, Tek Adım LSTM; Lookback=1)

Model 13, aylık ortalama sıcaklığı üç değişkenle (SaatlikAktuelBasinc, SaatlikNispiNem, SaatlikOrtalamaRuzgarhizi) tek adımda tahmin eden yalın bir zaman serisi modelidir. Her örnek, ilgili aya ait bu üç değişkenin ortalamasından oluşur; geçmiş ayları kapsayan bir pencere kullanılmaz (lookback=1). Mimari: sequenceInputLayer → 100 birimli lstmLayer (OutputMode='last') → fullyConnected → regressionLayer. Veri %80 eğitim–%20 test olarak ayrılmıştır.

Model Eğitimi

Eğitim 250 epoch boyunca, MiniBatchSize=16 ile ve doğrulama izlemesi olmadan yürütülmüştür. RMSE başlangıçta hızla düşüp kısa sürede yataya bağlanmış, loss eğrisi de benzer biçimde kararlı bir seviyeye oturmuştur.




Şekil 4.28. Model 13 eğitim süreci RMSE ve Loss eğrileri

Modelin Değerlendirilmesi

Test kümesi sonuçları: $MAE=3.9586$, $MSE=24.6248$, $RMSE=4.9623$. Şekil 4.29’da gerçek ve tahmin eğrileri genel mevsimsel dalgayı takip ederken, tepe ve diplerde sapmalar belirgindir. Bunun iki temel nedeni var:

- (i) Zaman penceresi yok: Lookback=1 olduğundan model, önceki ayların bilgisini doğrudan kullanamıyor; LSTM’nin “hafıza” avantajı fiilen sınırlanıyor.
- (ii) Sınırlı girdi kümesi: Yalnızca üç değişkenle çalışmak, mevsimsel faz ve genlik bilgisini Model 11–12’deki gibi zenginleştiremiyor. Bu yüzden yaz aylarındaki zirveler nispeten eksik, kış aylarındaki dipler ise yer yer hatalı konumlanıyor.



Şekil 4.29. Model 13 gerçek ve tahmin edilen aylık ortalama sıcaklık değerleri


4.6.14. Model 14 – Aylık ortalama sıcaklık tahmini (LSTM + GRU, 3 Girdi, Tek Adım)

Model 14, saatlik ölçümlerden hesaplanan aylık ortalamalara dayanarak aynı ayın ortalama sıcaklığını tek adımda tahmin etmektedir. Giriş değişkenleri Saatlik Aktüel Basınç, Saatlik Nispi Nem ve Saatlik Ortalama Rüzgâr Hızı olup z-skor normalizasyonu uygulanmıştır. Her ay bağımsız bir örnek olarak ele alınmış (sekans uzunluğu=1), mimari $\text{sequenceInputLayer}(3) \rightarrow \text{lstmLayer}(100, 'last') \rightarrow \text{dropout}(0.2) \rightarrow \text{gruLayer}(50, 'last') \rightarrow \text{fullyConnected}(1) \rightarrow \text{regressionLayer}$ şeklinde kurgulanmıştır. Zaman sırasını koruyan %80 eğitim – %20 test ayrımı kullanılmış, Adam iyileştirici ile MaxEpochs=300, MiniBatchSize=16, Shuffle='never' ve sabit öğrenme hızı tercih edilmiştir.

Model Eğitimi

Eğitim sürecine ait RMSE ve loss eğrileri Şekil 4.30’da gösterilmiştir. Başlangıçta yüksek seyreden RMSE kısa sürede belirgin biçimde düşmüş, ardından yaklaşık 0.7 bandında kararlı salınımlar sergilemiştir. Loss eğrisi buna paralel olarak erken evrede hızlı bir azalma göstermiş ve yataya yakın bir düzeye yerleşmiştir. Doğrulama kümesi


tanımlanmadığından erken durdurma uygulanmamış, eğitim 300 epoch sonunda tamamlanmış ve toplam süre yaklaşık 46 saniye olarak kaydedilmiştir.



Şekil 4.30. Model 14 eğitim süreci RMSE ve Loss eğrileri (Validation: N/A)

Modelin Değerlendirilmesi

Test dönemine ait gerçek ve tahmin edilen aylık ortalama sıcaklıklar Şekil 4.31’de sunulmuştur. Tahminler mevsimsel döngünün zamanlamasını genel olarak izlemekte; tepe ve dip noktaları çoğu bölümde doğru konumlanmaktadır. Bununla birlikte bazı aralıklarda genlik tarafında aşırı/eksik tahmin davranışı görülmektedir: yaz aylarındaki tepe seviyeleri kısmen düşük, geçiş aylarında ise yer yer yüksek tahminler üretilmiştir. Ölçülen hata metrikleri $MAE = 3.9004$, $MSE = 24.4818$ ve $RMSE = 4.9479$ °C’dir. Bu tablo, mevsimselliğin izlenebildiğini; ancak yalnızca üç eşzamanlı değişkene dayanan, gecikmesiz tek-adım kurgunun seviye ve genlik hatalarını artırabildiğini göstermektedir.



Şekil 4.31. Model 14 gerçek ve tahmin edilen aylık ortalama sıcaklık değerleri


4.6.15. Model 15 – Aylık ortalama sıcaklık tahmini (24 Aylık Girdi, LSTM+GRU)

Model 15, saatlik gözlemlerden hesaplanan aylık ortalamalar üzerinden, geçmiş 24 aylık pencereyi kullanarak bir sonraki ayın ortalama sıcaklığını tahmin etmektedir. Giriş uzayı üç meteorolojik değişkenden (Saatlik Aktüel Basınç, Saatlik Nispi Nem, Saatlik Ortalama Rüzgâr Hızı) ve mevsimselliği temsil eden sin/cos ay kodlarından oluşmakta (toplam 5 özellik) ve yalnızca eğitim bölümünden öğrenilen istatistiklerle ölçeklenmektedir. Mimari, `sequenceInputLayer(5) → lstmLayer(100, 'last') → dropout(0.2) → gruLayer(64, 'last') → fullyConnected(1) → regressionLayer` şeklindedir. Zaman sırası korunarak yaklaşık %80 eğitim – %20 test ayrımı yapılmış; Adam iyileştirici, `MaxEpochs=250`, `MiniBatchSize=16`, `InitialLearnRate=5e-4`, `Shuffle='never'` ayarlarıyla kullanılmıştır. Doğrulama eğrilerinin izlenmesi için test kümesi `ValidationData` olarak atanmış, erken durdurma devre dışı bırakılmıştır.

Model Eğitimi

Eğitim sürecine ait RMSE ve loss eğrileri Şekil 4.32’de verilmiştir. RMSE’nin ilk iterasyonlarda keskin bir düşüş gösterdiği, kısa süre içinde ~0.2–0.25 bandına yerleştiği ve eğitim boyunca düşük genlikli salınımlarla seyrettiği görülmektedir. Doğrulama


RMSE'si ~0.33 civarında, zaman içinde sınırlı bir yükselme eğilimi sergilemekle birlikte kararlı kalmıştır. Loss eğrisi de başlangıçta hızlıca düşerek 0.02 düzeyine yakınsatmıştır. Eğitim 250 epoch sonunda tamamlanmış, toplam süre yaklaşık 1 dakika 35 saniye olarak kaydedilmiştir.



Şekil 4.32. Model 15 eğitim süreci RMSE ve Loss eğrileri (Validation izleme ile)

Modelin Değerlendirilmesi

Test döneminde gerçek ve tahmin edilen aylık ortalamalar Şekil 4.33'te karşılaştırılmıştır. Tahmin eğrisi, mevsimsel fazı büyük ölçüde doğru izlemekte; tepe ve dip noktalarının zamanlamasıyla uyum göstermektedir. Genlik tarafında ise yaz tepe değerlerinde hafif eksik, kış diplerinde yer yer hafif yüksek tahmin eğilimi gözlenmektedir. Nicel olarak, test kümesi üzerinde $MAE = 1.9966$, $MSE = 6.4300$ ve $RMSE = 2.5357$ °C elde edilmiştir. Bu sonuç, aylık ölçekte mevsimselliğin hem zamanlamasının hem de genel seyrinin başarılı biçimde yakalandığını; 24 aylık bellek ve mevsimsel kodlamanın özellikle trend takibinde belirgin katkı sağladığını göstermektedir. Önceki aylık tek-adım kurguya kıyasla hata düzeyinin dikkate değer ölçüde düştüğü ve tahmin eğrisi-gerçek seri örtüşmesinin güçlendiği görülmektedir.



Şekil 4.33. Model 15 gerçek ve tahmin edilen aylık ortalama sıcaklık değerleri


4.6.16. Model 16 – Aylık ortalama sıcaklık tahmini (12 Aylık Girdi, LSTM Lite)

Model 16, saatlik ölçümlerden türetilen aylık ortalamalar üzerinden, geçmiş 12 aylık pencereyi kullanarak bir sonraki ayın ortalama sıcaklığını tahmin etmektedir. Giriş uzayı üç meteorolojik değişkenden oluşmaktadır: Saatlik Aktüel Basınç, Saatlik Nispi Nem ve Saatlik Ortalama Rüzgâr Hızı. Ölçekleme yalnızca eğitim bölümünden öğrenilen istatistiklerle yapılmış (train-only normalize), zaman sırası korunarak yaklaşık %80 eğitim – %20 test ayrımı uygulanmıştır. Mimari yalın tutulmuş; `sequenceInputLayer(3) → lstmLayer(50, 'last') → fullyConnected(1) → regressionLayer` biçimindedir. Eğitim, Adam iyileştiriciyle `MaxEpochs=200`, `MiniBatchSize=16`, `Shuffle='every-epoch'` ayarları altında yürütülmüştür.

Model Eğitimi

Eğitim sürecine ait RMSE ve loss eğrileri Şekil 4.34'te verilmiştir. Başlangıçta yüksek seyreden RMSE hızlı bir düşüşle kısa sürede ~0.2 civarına yakınsamış, eğitim boyunca düşük genlikli salınımlarla kararlı biçimde devam etmiştir. Loss eğrisi de ilk iterasyonlarda keskin biçimde azalarak yaklaşık 0.02 seviyesine gerilemiştir. Doğrulama


kümesi tanımlı olmadığından erken durdurma devreye girmemiş; eğitim 200 epoch sonunda tamamlanmış ve toplam süre yaklaşık 26 saniye olarak kaydedilmiştir.



Şekil 4.34. Model 16 eğitim süreci RMSE ve Loss eğrileri (Validation: N/A)

Modelin Değerlendirilmesi

Test dönemine ait gerçek ve tahmin edilen aylık ortalamalar Şekil 4.35'te gösterilmiştir. Tahmin eğrisi mevsimsel döngünün fazını büyük ölçüde doğru izlemekte; tepe ve dip noktalarının zamanlamasıyla uyum sağlamaktadır. Genlik tarafında ise yaz zirvelerinde yer yer hafif eksik, bazı kış diplerinde ise biraz daha soğuk tahmin eğilimi gözlenmektedir. Nicel sonuçlar $MAE = 2.0337$, $MSE = 7.6403$ ve $RMSE = 2.7641$ °C'dir. Bu tablo, yalın LSTM yapısının 12 aylık bellekle mevsimselliği etkili biçimde yakaladığını; genlik hatalarının ise orta düzeyde kaldığını göstermektedir. Daha uzun bellek kullanan melez yapılara göre mimari basitliğin korunmasına karşın faz uyumunun güçlü olması dikkat çekicidir.



Şekil 4.35. Model 16 gerçek ve tahmin edilen aylık ortalama sıcaklık değerleri


4.6.17. Model 17 – Aylık ortalama sıcaklık tahmini (24 Aylık Girdi, LSTM+GRU, Mevsimsellik)

Model 17, saatlik ölçümlerden üretilen aylık ortalamalar üzerinden geçmiş 24 aylık pencereyi kullanarak bir sonraki ayın ortalama sıcaklığını tahmin etmektedir. Giriş uzayı üç meteorolojik değişkenin (Saatlik Aktüel Basınç, Saatlik Nispi Nem, Saatlik Ortalama Rüzgâr Hızı) yanı sıra mevsimselliği temsil eden sin/cos ay kodları ile genişletilmiş (toplam 5 özellik) ve ölçekleme yalnızca eğitim bölümünden öğrenilen istatistiklerle yapılmıştır. Mimari `sequenceInputLayer(5) → lstmLayer(50,'last') → dropout(0.2) → gruLayer(64,'last') → fullyConnected(1) → regressionLayer` biçimindedir. Zaman sırası korunarak yaklaşık %80 eğitim – %20 test ayrımı kullanılmış; Adam iyileştirici ile `MaxEpochs=250`, `MiniBatchSize=16`, `InitialLearnRate=5e-4`, `Shuffle='never'` ve test kümesi `ValidationData` olarak izlenmiştir.

Model Eğitimi

Eğitim sürecine ait RMSE ve loss eğrileri Şekil 4.36’da yer almaktadır. RMSE ilk iterasyonlarda keskin biçimde düşmüş, kısa sürede ≈ 0.19 – 0.20 bandında kararlı bir düzeye yerleşmiştir. Doğrulama RMSE’si boyunca ≈ 0.27 – 0.37 aralığında dalgalanmış ve


son değeri 0.3676 olarak kaydedilmiştir. Loss eğrisi erken evrede hızlı bir azalma göstererek ≈ 0.02 düzeyine yakınsamıştır. Erken durdurma kapalı olduğundan eğitim 250 epoch sonunda tamamlanmış, toplam süre yaklaşık 1 dakika 3 saniye olmuştur.



Şekil 4.36. Model 17 eğitim süreci RMSE ve Loss eğrileri (Validation izleme ile)

Modelin Değerlendirilmesi

Test dönemine ait gerçek ve tahmin edilen aylık ortalamalar Şekil 4.37’de karşılaştırılmıştır. Tahmin eğrisi mevsimsel fazı tutarlı biçimde izlemekte, tepe ve dip zamanlamalarını çoğunlukla doğru konumlandırmaktadır. Genlik tarafında yaz zirvelerinde hafif eksik, bazı kış diplerinde ise daha soğuk tahmin eğilimi görülmektedir; geçiş dönemlerinde seviye hataları sınırlı kalmıştır. Nicel olarak test kümesinde $MAE = 2.1367$, $MSE = 8.0077$ ve $RMSE = 2.8298$ °C elde edilmiştir. Bu sonuç, 24 aylık bellek ve mevsimsel kodlamanın faz takibini güçlendirdiğini; genlikteki küçük önyargılara rağmen genel eğilimin başarıyla yakalandığını göstermektedir. Model 16 ile benzer bir doğruluk mertebesinde, Model 15’e kıyasla ise hata düzeyinin bir miktar daha yüksek olduğu gözlenmektedir.




Şekil 4.37. Model 17 gerçek ve tahmin edilen aylık ortalama sıcaklık değerleri

4.6.18. Model 18 – 2 Katmanlı LSTM + Dropout ile aylık sıcaklık tahmini (12 Zaman Adımı)

Model 18, saatlik gözlemlerden üretilen aylık ortalamalar üzerinden, geçmiş 12 aylık pencereyi kullanarak bir sonraki ayın ortalama sıcaklığını tahmin etmektedir. Giriş olarak Saatlik Aktüel Basınç, Saatlik Nispi Nem ve Saatlik Ortalama Rüzgâr Hızı kullanılmış, z-skor normalizasyonu tüm veri üzerinde uygulanmıştır. Mimari `sequenceInputLayer(3) → lstmLayer(100,'sequence') → dropout(0.2) → lstmLayer(50,'last') → fullyConnected(1) → regressionLayer` şeklindedir. Zaman sırası korunarak yaklaşık %80 eğitim – %20 test ayrımı yapılmış; Adam iyileştirici ile `MaxEpochs=100`, `MiniBatchSize=64`, `Shuffle='every-epoch'` ayarları kullanılmıştır.

Model Eğitimi


Eğitim sürecine ait RMSE ve loss eğrileri Şekil 4.38’de sunulmuştur. RMSE başlangıçta yüksek seviyeden hızla düşerek kısa sürede $\approx 0.25-0.30$ bandına yerleşmiş, eğitim boyunca düşük genlikli dalgalanmalarla kararlı seyretmiştir. Loss eğrisi de erken evrede belirgin azalma göstererek $\approx 0.03-0.04$ düzeyine yakınsamıştır. Doğrulama kümesi tanımlı olmadığından validation eğrisi bulunmamaktadır; eğitim 100 epoch sonunda tamamlanmış ve toplam süre yaklaşık 9 saniye olarak kaydedilmiştir.



Şekil 4.38. Model 18 eğitim süreci RMSE ve Loss eğrileri (Validation: N/A)

Modelin Değerlendirilmesi

Test döneminde gerçek ve tahmin edilen aylık ortalamalar Şekil 4.39'da karşılaştırılmıştır. Tahmin eğrisi mevsimsel döngünün fazını oldukça iyi izlemekte; tepe ve dip zamanlamaları büyük ölçüde doğru konumlanmaktadır. Genlik tarafında yaz zirvelerinde hafif yüksek, bazı kış diplerinde ise biraz ılık tahmin eğilimi gözlenmektedir; buna karşın hatalar çoğu bölümde sınırlıdır. Nicel sonuçlar $MAE = 1.6744$, $MSE = 4.7083$ ve $RMSE = 2.1699$ °C olup, bu değerler önceki aylık modellerle karşılaştırıldığında hata mertebesinin daha düşük bir seviyeye indiğini göstermektedir.



Şekil 4.39. Model 18 gerçek ve tahmin edilen aylık ortalama sıcaklık değerleri

4.6.19. Model 19 – 12 Aylık girdi ile aylık sıcaklık tahmini (LSTM+GRU)

Model 19, saatlik ölçümlerden türetilen aylık ortalamalar üzerinden, geçmiş 12 aylık pencereyi kullanarak bir sonraki ayın ortalama sıcaklığını tahmin etmektedir. Giriş değişkenleri Saatlik Aktüel Basınç, Saatlik Nispi Nem ve Saatlik Ortalama Rüzgâr Hızı olup tüm veri üzerinde z-skor normalizasyonu uygulanmıştır. Mimari `sequenceInputLayer(3) → lstmLayer(100,'sequence') → dropout(0.2) → gruLayer(50,'last') → fullyConnected(1) → regressionLayer` şeklindedir. Zaman sırası korunarak yaklaşık %80 eğitim – %20 test ayrımı yapılmış; Adam iyileştirici ile `MaxEpochs=40`, `MiniBatchSize=8`, `Shuffle='every-epoch'` ayarları kullanılmıştır.

Model Eğitimi


Eğitim sürecine ait RMSE ve loss eğrileri Şekil 4.40'ta sunulmuştur. RMSE ilk iterasyonlarda keskin biçimde düşmüş, kısa sürede $\approx 0.25\text{--}0.30$ bandına yerleşerek düşük genlikli dalgalanmalarla seyretmiştir. Loss eğrisi de erken evrede belirgin bir azalma göstererek $\approx 0.03\text{--}0.04$ seviyelerine yakınsamıştır. Doğrulama kümesi tanımlı değildir; eğitim 40 epoch sonunda tamamlanmış ve toplam süre yaklaşık 17 saniye olarak kaydedilmiştir.



Şekil 4.40. Model 19 eğitim süreci RMSE ve Loss eğrileri (Validation: N/A)

Modelin Değerlendirilmesi

Test dönemine ait gerçek ve tahmin edilen aylık ortalamalar Şekil 4.41’de gösterilmiştir. Tahmin eğrisi mevsimsel döngünün fazını başarılı biçimde izlemekte; tepe ve dip zamanlamaları büyük ölçüde doğru konumlanmaktadır. Genlik tarafında yaz zirvelerinde hafif yüksek, bazı kış diplerinde ise biraz ılık tahmin eğilimi görülmekle birlikte, seri boyunca uyum görece dengelidir. Nicel sonuçlar $MAE = 1.8016$, $MSE = 4.6858$ ve $RMSE = 2.1647$ °C’dir. Bu tablo, 12 aylık bellekle kurulan LSTM+GRU yapısının aylık ölçekte mevsimselliği iyi yakaladığını ve seviye hatalarını düşük bir aralıkta tuttuğunu göstermektedir.




Şekil 4.41. Model 19 gerçek ve tahmin edilen aylık ortalama sıcaklık değerleri

4.6.20. Model 20 – Aylık ortalama sıcaklık tahmini (LSTM + GRU, 12 Aylık Girdi)

Model 20, saatlik gözlemlerden elde edilen aylık ortalamalar üzerinden, geçmiş 12 aylık pencereyi kullanarak bir sonraki ayın ortalama sıcaklığını tahmin etmektedir. Giriş değişkenleri Saatlik Aktüel Basınç, Saatlik Nispi Nem ve Saatlik Ortalama Rüzgâr Hızı'dır. Ölçekleme yalnızca eğitim bölümünden öğrenilen istatistiklerle yapılmış (train-only normalize), zaman sırası korunarak %80 eğitim – %20 test ayrımı uygulanmıştır. Mimari `sequenceInputLayer(3) → lstmLayer(100,'sequence') → dropout(0.2) → gruLayer(50,'last') → fullyConnected(1) → regressionLayer` biçimindedir. Optimizasyon Adam ile MaxEpochs=200, MiniBatchSize=128, Shuffle='every-epoch', sabit öğrenme hızı 0.001 ayarlarıyla yürütülmüştür.

Model Eğitimi


Eğitim sürecine ait RMSE ve loss eğrileri Şekil 4.42'de sunulmuştur. RMSE, ilk iterasyonlarda yüksek seviyeden hızlıca düşmüş ve eğitim ilerledikçe $\approx 0.26-0.28$ bandında plato yapmıştır. Loss eğrisi de buna paralel biçimde kademeli olarak azalmış ve düşük bir düzeyde dengelenmiştir. Doğrulama kümesi tanımlı olmadığından erken durdurma devrede değildir; eğitim 200/200 epoch tamamlanmış ve toplam süre yaklaşık 9 saniye olarak kaydedilmiştir.



Şekil 4.42. Model 20 eğitim süreci RMSE ve Loss eğrileri (Validation: N/A)

Modelin Değerlendirilmesi

Test dönemine ait gerçek ve tahmin edilen aylık ortalamalar Şekil 4.43'te gösterilmiştir. Tahmin eğrisi mevsimsel döngünün fazını tutarlı biçimde izlemekte; tepe ve dip zamanlamalarıyla yüksek uyum sergilemektedir. Genlik tarafında yaz zirvelerinde hafif yüksek, bazı kış diplerinde biraz ılık tahmin eğilimi görülse de seviye farkları sınırlı kalmıştır. Nicel sonuçlar $MAE = 1.5134$, $MSE = 3.6926$ ve $RMSE = 1.9216$ °C olarak hesaplanmıştır. Bu tablo, 12 aylık bellek kullanan LSTM+GRU yapısının aylık ölçekte mevsimselliği güçlü biçimde yakaladığını ve hata düzeyini düşük bir aralıkta tuttuğunu göstermektedir.



Şekil 4.43. Model 20 gerçek ve tahmin edilen aylık ortalama sıcaklık değerleri

4.6.21. Tez Kapsamında geliştirilen modellerin tablolar halinde karşılaştırılması (Günlük, Haftalık ve Aylık Bazlı)

Tablo 4.3. Günlük tahmin modelleri (Model 1 – Model 5 arası)

Model	Yöntem	MAE	MSE	RMSE
Model 1	LSTM (1 zaman adımı)	5.6739	48.6941	6.9781
Model 2	2xLSTM (12 zaman adımı)	5.7738	55.6365	7.4590
Model 3	LSTM + GRU (12 zaman adımı)	5.9054	57.7613	7.6001
Model 4	Geliştirilmiş LSTM + GRU	6.1116	62.9808	7.9360
Model 5	LSTM + GRU + Mevsimsel Bilgi	3.2586	17.7958	4.2185

Tez kapsamında geliştirilen ilk beş model, saatlik meteorolojik verilerden günlük sıcaklık tahmini yapmayı hedeflemiştir. Model 1, tek zaman adımlı temel bir LSTM mimarisiyle çalışmış ve RMSE değeri 6.98 olarak ölçülmüştür. Model 2’de zaman adımı 12’ye çıkarılmış ve iki katmanlı LSTM yapısı kullanılmış, ancak bu değişiklik RMSE’yi 7.45 seviyesinin altına çekememiştir. Model 3 ve Model 4’te LSTM ve GRU katmanlarının bir arada kullanıldığı daha derin mimariler denenmiş; Model 3’te RMSE 7.60, Model 4’te ise 7.93 olarak gerçekleşmiş, bu da mimari karmaşıklığın tahmin performansına anlamlı bir katkı sağlamadığını göstermiştir.

Tablo 4.3 incelendiğinde, en iyi sonuç Model 5’te elde edilmiş olup RMSE değeri 4.21’e kadar düşürülmüştür. Bu modelde mevsimsel bilgilerin (örneğin ay ve saat) giriş verisine dahil edilmesi, tahmin performansını belirgin biçimde artırmıştır. Sonuçlar, günlük sıcaklık tahmininde model başarısının yalnızca ağ mimarisinin derinliğinden değil, aynı zamanda giriş verisinin temsil gücünden de önemli ölçüde etkilendiğini ortaya koymaktadır.

Tablo 4.4. Haftalık tahmin modelleri (Model 6 – Model 10 arası)

Model	Yöntem	MAE	MSE	RMSE
Model 6	LSTM (12 zaman adımı)	2.4782	10.0417	3.1689
Model 7	LSTM + Dropout (12 zaman adımı)	2.4896	10.1286	3.1825
Model 8	LSTM + GRU + Dropout	2.8372	13.6331	3.6923
Model 9	2xLSTM + GRU	3.3805	17.5905	4.1941
Model 10	LSTM + GRU (optimize edilmiş)	2.2995	8.9730	2.9955

Günlük tahmin modellerinin kısa vadeli sıcaklık değişimlerine karşı duyarlılığının düşük olması ve özellikle ani dalgalanmalarda yüksek hata üretmesi, modelin genel eğilimleri öğrenmesini sınırlandırmıştır. Bu nedenle Model 6 ile birlikte haftalık ortalama sıcaklık tahminine geçilmiş, böylece kısa vadeli gürültüler baskılanarak daha uzun vadeli iklim eğilimlerinin öğrenilmesi hedeflenmiştir.

Tablo 4.4 incelendiğinde, haftalık tahmin için geliştirilen Model 6–10 arasında en düşük RMSE değeri 2.99 ile Model 10’da elde edilmiştir. Bu model, optimize edilmiş LSTM + GRU yapısıyla yalnızca geçmiş 12 haftalık sıcaklık bilgisine dayalı olarak yüksek doğruluk sağlamıştır. LSTM ve GRU’nun birlikte kullanıldığı Model 7 ve Model 8 gibi melez yapılarda da benzer hata düzeyleri yakalanmış ($RMSE \approx 3.18\text{--}3.69$), ancak artan mimari karmaşıklık Model 9’da olduğu gibi ($RMSE = 4.19$) her zaman performans artışı sağlamamıştır. Tek katmanlı LSTM mimarisine sahip Model 6 ise 3.16 RMSE değeri ile sade bir yapı sunmasına rağmen tatmin edici bir performans sergilemiştir.

Haftalık zaman ölçeği, doğruluk ve istikrar açısından günlük modellere kıyasla belirgin avantaj sağlamıştır. RMSE değerlerinin tüm modellerde günlük modellere göre daha düşük seviyelerde olması, haftalık tahmin yaklaşımının kısa vadeli gürültüden arındırılmış ve daha dengeli tahminler üretme potansiyelini ortaya koymaktadır.

Tablo 4.5. Aylık tahmin modelleri (Model 11 – Model 20 arası)

Model	Yöntem	MAE	MSE	RMSE
Model 11	LSTM (Aylık tahmin)	1.9470	5.4551	2.3356
Model 12	LSTM + Dropout	2.4088	8.2813	2.8777
Model 13	LSTM (3 girdi, tek adım)	3.9586	24.6248	4.9623
Model 14	LSTM + GRU	3.9004	24.4818	4.9479
Model 15	LSTM (2 katmanlı)	1.9966	6.4300	2.5357
Model 16	LSTM Lite (12 zaman adımı)	2.0337	7.6403	2.7641
Model 17	LSTM + GRU (melez yapı)	2.1367	8.0077	2.8298
Model 18	LSTM (optimizasyonlu)	1.6744	4.7083	2.1699
Model 19	2xLSTM + Dropout	1.8016	4.6858	2.1647
Model 20	LSTM + GRU (12 aylık girdi)	1.5134	3.6926	1.9216

Günlük ve haftalık modellere kıyasla daha uzun dönemli eğilimleri öğrenmek amacıyla geliştirilen aylık tahmin modelleri, Model 11’den itibaren aylık ortalama sıcaklık değerlerine odaklanmıştır. Bu modeller, hem uzun zamansal sekansların (örneğin 12 ay) hem de giriş değişkeni çeşitliliğinin model başarısına etkisini test etmeyi amaçlamıştır.

Tablo 4.5 incelendiğinde, en düşük RMSE değeri 1.92 ile Model 20’de elde edilmiştir. Bu model, 12 aylık zaman adımına sahip LSTM + GRU mimarisiyle uzun vadeli bağımlılıkları ve mevsimsel döngüleri etkin biçimde yakalamıştır. Benzer şekilde, Model 18 (RMSE = 2.16) ve Model 19 (RMSE = 2.16) gibi derin veya melez yapılar da oldukça düşük hata değerleriyle dikkat çekmiştir. Buna karşın, giriş değişkeni seçimi veya zaman penceresi optimizasyonu zayıf olan bazı modellerde (örneğin Model 13 ve Model 14) RMSE değerleri 4.94–4.96 seviyelerinde kalmıştır. Bu durum, model mimarisinin başarısı kadar uygun veri temsili, doğru zaman aralığı ve model doğrulama sürecinin de performans üzerinde belirleyici olduğunu göstermektedir.

Üç farklı zaman ölçeğinde geliştirilen modeller karşılaştırıldığında, tahmin doğruluğunun zaman penceresi uzadıkça belirgin biçimde arttığı görülmektedir. Günlük modellerde en iyi RMSE değeri 4.21 (Model 5) seviyesinde kalırken, haftalık modellerde bu değer 2.99’a (Model 10), aylık modellerde ise 1.92’ye (Model 20) kadar düşmüştür. Bu farkın temel nedeni, günlük modellerin ani sıcaklık değişimlerine karşı yüksek hassasiyetleri

nedeniyle gürültüye açık olması; haftalık ve aylık ortalamaların ise bu dalgalanmaları yumuşatarak modelin genel eğilimleri daha net öğrenmesine imkân tanınmasıdır.

İklim tahmini bağlamında, aylık zaman ölçeğinde geliştirilen modeller mevsimsel döngüleri, uzun vadeli eğilimleri ve iklimsel geçişleri en başarılı şekilde yakalamış; böylece kısa vadeli hava durumu tahminlerinden farklı olarak uzun dönemli iklim öngörülerinde yüksek doğruluk ve istikrar sağlamıştır. Haftalık modeller orta vadeli eğilimler için dengeli bir yapı sunarken, günlük modeller daha ayrıntılı ancak yüksek gürültü barındıran kısa vadeli değişimlerin takibinde kalmıştır. Sonuç olarak, aylık tahmin yaklaşımı, tez kapsamında hedeflenen iklimsel öngörü amacına en yüksek katkıyı sunmuş ve uzun dönemli iklim tahmini için en uygun zaman ölçeği olarak öne çıkmıştır.

Tez kapsamında geliştirilen modeller arasında en iyi sonucu üreten Model 20'ye ait gerçek sıcaklıklar ve bunlara karşılık modelin ürettiği sıcaklık değerleri Tablo 4.6 - 4.10'da verilmiştir.

Tablo 4.6 Model 20'ye ait 2019 yılının gerçek sıcaklık ve tahmin edilen sıcaklık değerleri

Tarih	Gerçek Sıcaklık(C°)	Tahmin Edilen Sıcaklık(C°)
01-Aralık-2018	4,83	3,33
01-Ocak-2019	2,35	3,63
01-Şubat-2019	5,76	6,62
01-Mart-2019	7,29	9,36
01-Nisan-2019	11,63	12,25
01-Mayıs-2019	19,05	15,96
01-Haziran-2019	23,05	20,26
01-Temmuz-2019	21,95	23,52
01-Ağustos-2019	22,37	23,84
01-Eylül-2019	18,99	20,00
01-Ekim-2019	17,37	15,01
01-Kasım-2019	8,94	9,10
01-Aralık-2019	5,76	4,16

Tablo 4.7 Model 20'ye ait 2020 yılının gerçek sıcaklık ve tahmin edilen sıcaklık değerleri

Tarih	Gerçek Sıcaklık(C°)	Tahmin Edilen Sıcaklık(C°)
01-Ocak-2020	2,97	2,81
01-Şubat-2020	4,07	3,71
01-Mart-2020	9,83	7,20
01-Nisan-2020	11,09	11,23
01-Mayıs-2020	17,07	15,48
01-Haziran-2020	20,69	19,33
01-Temmuz-2020	24,16	23,57
01-Ağustos-2020	22,35	25,10
01-Eylül-2020	22,97	23,73
01-Ekim-2020	17,94	19,02
01-Kasım-2020	7,26	11,70
01-Aralık-2020	5,49	4,66
01-Ocak-2020	2,97	2,81

Tablo 4.8 Model 20'ye ait 2021 yılının gerçek sıcaklık ve tahmin edilen sıcaklık değerleri

Tarih	Gerçek Sıcaklık(C°)	Tahmin Edilen Sıcaklık(C°)
01-Ocak-2021	5,05	1,76
01-Şubat-2021	5,11	3,97
01-Mart-2021	5,99	7,58
01-Nisan-2021	13,78	11,91
01-Mayıs-2021	18,51	15,86
01-Haziran-2021	20,08	20,13
01-Temmuz-2021	24,15	23,65
01-Ağustos-2021	23,57	25,30
01-Eylül-2021	17,72	21,41
01-Ekim-2021	12,84	15,49
01-Kasım-2021	8,30	8,31
01-Aralık-2021	5,54	3,92
01-Ocak-2021	5,05	1,76

Tablo 4.9 Model 20'ye ait 2022 yılının gerçek sıcaklık ve tahmin edilen sıcaklık değerleri

Tarih	Gerçek Sıcaklık(C ⁰)	Tahmin Edilen Sıcaklık(C ⁰)
01-Ocak-2022	1,70	3,35
01-Şubat-2022	5,45	5,54
01-Mart-2022	3,34	9,49
01-Nisan-2022	15,09	13,22
01-Mayıs-2022	15,33	17,44
01-Haziran-2022	20,88	20,65
01-Temmuz-2022	21,00	24,30
01-Ağustos-2022	25,63	23,63
01-Eylül-2022	20,41	20,88
01-Ekim-2022	14,13	15,77
01-Kasım-2022	10,54	10,31
01-Aralık-2022	6,55	5,90
01-Ocak-2022	1,70	3,35


Tablo 4.10 Model 20'ye ait 2023 yılının gerçek sıcaklık ve tahmin edilen sıcaklık değerleri

Tarih	Gerçek Sıcaklık(C ⁰)	Tahmin Edilen Sıcaklık(C ⁰)
01-Ocak-2023	3,76	2,89
01-Şubat-2023	2,82	3,56
01-Mart-2023	9,42	6,50
01-Nisan-2023	12,49	11,29
01-Mayıs-2023	15,61	15,08
01-Haziran-2023	20,26	19,24
01-Temmuz-2023	22,30	22,62
01-Ağustos-2023	25,16	23,75
01-Eylül-2023	20,18	20,01
01-Ekim-2023	15,40	13,97
01-Kasım-2023	12,66	9,73
01-Aralık-2023	7,15	6,00
01-Ocak-2024	4,73	4,80


4.6.22. Model 21 – Tüm meteorolojik değişkenler için BiLSTM tabanlı tahmin modeli

Bu çalışmada geliştirilen Model 21, yalnızca sıcaklık tahminiyle sınırlı kalmamış, meteorolojik veri setindeki tüm hedef değişkenleri ayrı ayrı tahmin etmeyi amaçlayan genel bir modelleme yaklaşımını benimsemiştir. Model, her hedef değişken için aynı BiLSTM tabanlı derin öğrenme mimarisini kullanarak bağımsız eğitimler gerçekleştirmiştir. Böylece farklı meteorolojik parametrelerdeki tahmin başarımı karşılaştırmalı olarak incelenebilmiştir. Mimari olarak giriş katmanında sequenceInputLayer, ardından çift yönlü bağımlılıkları öğrenebilen bilstmLayer(100, 'OutputMode','last'), aşırı öğrenmeyi önlemek amacıyla dropoutLayer(0.2) ve tek çıkışlı fullyConnectedLayer(1) ile regressionLayer kullanılmıştır. Bu yapı, önceki tek yönlü LSTM veya LSTM+GRU melez yapılarından çift yönlü bağlam öğrenme kabiliyetiyle ayrılmaktadır.


Eğitim süreci incelendiğinde, BiLSTM mimarisinin veri doluluk oranı yüksek değişkenlerde hızlı ve dengeli bir öğrenme sağladığı görülmüştür. Saatlik sıcaklıkta hata değerleri kısa sürede düşerken (Şekil 4.46), yatay görüş mesafesinde genel eğilimler öğrenilmiş ancak kısa vadeli dalgalanmalar daha zor yakalanmıştır (Şekil 4.47). Aktüel basınçta hem eğitim hem doğrulama hataları düşük seviyelerde seyretmiştir (Şekil 4.48). Mevcut kar kalınlığında ise düşük veri doluluğu nedeniyle doğrulama eğrisinde dalgalı bir seyir gözlenmiştir (Şekil 4.49). Nispi nemde mevsimsel ve günlük döngüler doğru şekilde yakalanmıştır (Şekil 4.50). Ortalama rüzgar hızında yüksek veri kalitesi sayesinde hızlı ve kararlı bir öğrenme gerçekleşmiştir (Şekil 4.51). Rüzgar yönünde yönsel veri yapısından kaynaklı olarak hata seviyeleri nispeten yüksek kalmış, ancak genel yön değişimleri öğrenilebilmiştir (Şekil 4.52). Rüzgar hızı değişkeninde ise düzenli veri yapısı sayesinde düşük hata değerleri elde edilmiştir (Şekil 4.53).




Şekil 4.46: Saatlik sıcaklık için eğitim kayıp eğrisi




Şekil 4.47: Saatlik yatay görüş mesafesi için eğitim kayıp eğrisi




Şekil 4.48: Saatlik aktüel basınç için eğitim kayıp eğrisi




Şekil 4.49: Saatlik mevcut kar kalınlığı için eğitim kayıp eğrisi




Şekil 4.50: Saatlik nispi nem için eğitim kayıp eğrisi



Şekil 4.51: Saatlik ortalama rüzgar hızı için eğitim kayıp eğrisi



Şekil 4.52: Rüzgar yönü (derece) için eğitim kayıp eğrisi




Şekil 4.53: Saatlik rüzgar hızı (m/s) için eğitim kayıp eğrisi


Test sonuçları incelendiğinde, saatlik sıcaklık tahmininde mevsimsel değişimler yüksek doğrulukla yakalanmış, kısa vadeli dalgalanmalarda ise hafif yumuşatma etkisi görülmüştür (Şekil 4.54). Yatay görüş mesafesinde genel eğilimler doğru tahmin edilmiş ancak ani değişimlerde gecikmeli tepki gözlenmiştir (Şekil 4.55). Aktüel basınç değişimlerinde gerçek ve tahmin eğrileri büyük oranda örtüşmüştür (Şekil 4.56). Mevcut kar kalınlığında veri eksikliği ve sıfır değerlerin yoğunluğu nedeniyle ani artışlar yakalanamamış, çoğunlukla sıfıra yakın tahminler üretilmiştir (Şekil 4.57). Nispi nem

tahminlerinde yüksek nem dönemleri doğru biçimde yakalanmıştır (Şekil 4.58). Ortalama rüzgar hızında mevsimsel değişimler ve genel trend yüksek uyum göstermiştir (Şekil 4.59). Rüzgar yönünde genel yön değişimleri öğrenilmiş ancak ani yön değişikliklerinde tahminler zayıflamıştır (Şekil 4.60). Rüzgar hızı değişkeninde ise yüksek veri doluluğu sayesinde düşük hata seviyeleri korunmuştur (Şekil 4.61).


Bununla birlikte, Saatlik Mevcut Kar Kalınlığı (Şekil 4.57) gibi düzensiz veya nadiren ölçülen değişkenlerde tahmin başarımının görece zayıf kaldığı, zaman zaman gerçek verilerden sapmalar gösterdiği dikkat çekmektedir. Bu farklar, söz konusu değişkenlerin zaman serilerinde ani sıçramaların ve çok sayıda sıfırın bulunmasından kaynaklanmaktadır. Genel olarak, test performansı grafiklerinde modelin büyük veri içeriğine sahip ve düzenli örüntüler barındıran değişkenlerde daha başarılı sonuçlar ürettiği gözlemlenmiştir. Zayıf tahmin performansının görüldüğü değişkenlerde ise modelin istatistiksel örüntü yakalama kapasitesi veri yetersizliği nedeniyle sınırlanmış olabilir.




Şekil 4.54: Saatlik sıcaklık – gerçek ve tahmin karşılaştırması




Şekil 4.55: Saatlik yatay görüş mesafesi – gerçek ve tahmin karşılaştırması




Şekil 4.56: Saatlik aktüel basınç – gerçek ve tahmin karşılaştırması




Şekil 4.57: Saatlik mevcut kar kalınlığı – gerçek ve tahmin karşılaştırması




Şekil 4.58: Saatlik nispi nem – gerçek ve tahmin karşılaştırması



Şekil 4.59: Saatlik ortalama rüzgar hızı – gerçek ve tahmin karşılaştırması



Şekil 4.60: Rüzgar yönü (derece) – gerçek ve tahmin karşılaştırması



Şekil 4.61: Saatlik rüzgar hızı (m/s) – gerçek ve tahmin karşılaştırması

Tablo 4.11 Model 21'nin her bir hedef değişken için test seti üzerindeki başarımını

Değişken	Veri Doluluk (%)	RMSE	MAE	R ²
Saatlik Sıcaklık	99.54	6.54	5.40	0.519
Saatlik Aktüel Basınç	99.51	5.50	4.42	-0.031
Saatlik Nispi Nem	61.86	12.93	10.07	0.526
Saatlik Ortalama Rüzgar Hızı	99.35	0.11	0.07	0.995
Rüzgar Yönü (Derece)	69.42	92.21	72.69	0.118
Rüzgar Hızı (m/s)	99.29	0.18	0.12	0.986
Saatlik Mevcut Kar Kalınlığı	1.10	0.73	0.11	-0.020
Saatlik Yatay Görüş Mesafesi	65.68	2.45	1.39	0.314

Tablo 4.11 incelendiğinde, veri doluluğu yüksek olan değişkenlerde modelin başarısının da yüksek olduğu görülmektedir. Özellikle Saatlik Ortalama Rüzgâr Hızı ve Rüzgar Hızı (m/s) değişkenlerinde %99'un üzerinde veri doluluğu ile R² değerleri sırasıyla 0.995 ve

0.986 seviyesinde gerekleşmiştir. Buna karşılık, eksik veri oranı ok yüksek olan Mevcut Kar Kalınlığı (%1.10) deęişkeninde negatif R^2 deęeri ile modelin tahmin başarımı oldukça düşük kalmıştır.

Model 21'in oklu deęişken tahmini yapabilme yeteneęi, önceki tek hedefli modellere kıyasla önemli bir esneklik ve karşılaştırma imkânı sunmaktadır. Ancak, sıcaklık tahmininde elde ettięi RMSE deęeri (6.54) önceki aylık sıcaklık modellerinin (örneğin Model 20: RMSE = 1.92) gerisinde kalmıştır. Bu durum, tek hedefli derin mimarilerin belirli deęişkenler üzerinde daha yüksek doğruluk sağlayabildięini, oklu hedefli yapıların ise geniş kapsamlı fakat görece düşük doğruluklu ıktılar üretebildięini göstermektedir.



5. TARTIŞMA

Bu tez çalışmasında, Tokat iline ait 28 yıllık meteorolojik veri seti kullanılarak farklı zaman ölçeklerinde (günlük, haftalık, aylık) toplam 21 derin öğrenme modeli geliştirilmiştir. Çalışma boyunca tek katmanlı LSTM'den başlayarak çift katmanlı LSTM, GRU, Dropout, Batch Normalization ve BiLSTM gibi farklı mimariler denenmiştir. Bulgular, zaman ölçeği büyüdükçe hata değerlerinin düştüğünü ve model doğruluğunun arttığını göstermektedir. Günlük tahminlerde en iyi sonuç Model 5 ile $RMSE = 4.21$ olarak elde edilmiş, haftalık tahminlerde hata %30 azalarak Model 10'da $RMSE = 2.99$ 'a, aylık tahminlerde ise Model 20'de $RMSE = 1.92$ 'ye düşmüştür. Bu eğilim, uzun vadeli tahminlerde zaman serisi dalgalanmalarının dengelendiğini ve modellerin daha istikrarlı çıktılar verdiğini ortaya koymaktadır.

Model mimarilerinin performans karşılaştırmaları da dikkat çekicidir. GRU katmanlarının LSTM ile birlikte kullanıldığı modeller (örneğin Model 10 ve Model 20) hem eğitim süresi hem de doğruluk açısından öne çıkmıştır. Dropout ve Batch Normalization katmanları ise aşırı öğrenmeyi sınırlamış ve model kararlılığını artırmıştır. Girdi değişkeni sayısının yediden üçe (Saatlik Aktüel Basınç, Nispi Nem, Ortalama Rüzgâr Hızı) düşürülmesi, özellikle eksik veri oranı yüksek değişkenlerin çıkarılması sayesinde modelin istikrarlı öğrenmesine katkı sağlamıştır.

Çalışmanın son aşamasında geliştirilen Model 21, yalnızca sıcaklık tahminine odaklanmak yerine veri setinde yer alan tüm meteorolojik değişkenlerin ayrı ayrı tahmin edilmesini hedeflemiştir. Çoklu tek-çıkıtlı BiLSTM yapısı, farklı değişkenlerdeki veri doluluk oranları ile tahmin doğruluklarını kıyaslama imkânı sunmuştur. Veri doluluğu %99.5 olan sıcaklık için $R^2 = 0.519$ bulunurken, düşük doluluk oranına sahip basınç ve kar kalınlığı değişkenlerinde negatif R^2 değerleri elde edilmiştir. Bu durum, model başarısının yalnızca mimari tercihlerden değil, aynı zamanda veri kalitesinden güçlü biçimde etkilendiğini göstermektedir.

Çalışmanın sınırlılıkları da göz önünde bulundurulmalıdır. Kullanılan veri yalnızca Tokat iline ait tek bir istasyondan sağlandığı için genellenebilirlik sınırlıdır. Eksik verilerin istatistiksel yöntemlerle doldurulması uç değerlerde performansı etkilemiş olabilir. Doğrulama kümesi ayrılmayan modellerde aşırı öğrenme riski bulunmaktadır. Ayrıca donanımsal kısıtlar nedeniyle günlük modellerin eğitimi oldukça uzun sürmüş, epoch sayısı sınırlı tutulmuştur. Daha güçlü işlem gücü ile eğitilen modellerin farklı sonuçlar üretebileceği unutulmamalıdır.

Literatürle karşılaştırıldığında, elde edilen bulguların önceki çalışmalarla paralellik gösterdiği söylenebilir. Sevinç ve ark. (2021) Diyarbakır için LSTM tabanlı sıcaklık tahmininde $RMSE = 1.859$ elde etmiş, bu çalışmada aylık ölçekte $RMSE = 1.92$ bulunmuştur. Zhang ve ark. (2020) tarafından önerilen CRNN modeli yaklaşık 0.90°C hata ile rapor edilmiştir; ancak kullanılan veri çeşitliliği dikkate alındığında bu çalışmadaki sonuçlar bölgesel düzeyde tutarlıdır. Ayrıca Mehr ve ark. (2022)'nin CNN-

LSTM hibrit modelinin kuraklık tahmininde klasik yöntemlerden üstün bulunması, bu tezde de LSTM ve GRU tabanlı modellerin güçlü performansı ile örtüşmektedir.

Sonuç olarak, bu tez bulguları hem literatürle uyumlu sonuçlar ortaya koymuş hem de veri kalitesi, mimari tercihler ve zaman ölçeği gibi faktörlerin meteorolojik tahmin doğruluğu üzerindeki etkisini açık biçimde tartışmaya açmıştır.



6. SONUÇ ve ÖNERİLER

Bu tezde, Tokat iline ait 28 yıllık meteorolojik veri seti kullanılarak farklı zaman ölçeklerinde toplam 21 derin öğrenme modeli geliştirilmiş ve kapsamlı bir karşılaştırma yapılmıştır. Günlük (Model 1–5), haftalık (Model 6–10) ve aylık (Model 11–20) modellerde performansın zaman ölçeği uzadıkça belirgin şekilde arttığı görülmüş; en düşük hata aylık ölçekte, Model 20’de $RMSE = 1.92$ değeriyle elde edilmiştir. Model 21 ise BiLSTM tabanlı yapısıyla tüm meteorolojik değişkenlerin tahmin edilebilirliğini test etmiş, veri doluluğu ile tahmin doğruluğu arasındaki ilişkiyi sistematik biçimde ortaya koymuştur.

Çalışmadan elde edilen temel çıkarımlar şunlardır:

- ✓ Günlük modeller ani değişimlere daha duyarlı olup hata oranları yüksektir; ancak mevsimsel bilgi girişleri performansı iyileştirmiştir (Model 5).
- ✓ Haftalık modeller kısa vadeli dalgalanmaları yumuşatarak daha kararlı tahminler sunmuş, en düşük hata Model 10’da elde edilmiştir.
- ✓ Aylık modeller, özellikle 12 zaman adımı ve derin mimarilerle en yüksek doğruluğu sağlamıştır (Model 20).
- ✓ GRU destekli yapılar, LSTM tabanlı modellere kıyasla hem hız hem doğruluk bakımından avantajlıdır.
- ✓ Dropout, ReLU ve Batch Normalization katmanları modelin genelleme kabiliyetini artırmıştır.
- ✓ Girdi değişkeni sayısının azaltılması, model öğrenmesini sadeleştirilmiş ve veri kalitesini daha etkili hale getirmiştir.
- ✓ Zaman ölçeği uzadıkça tahmin hatası yaklaşık %60 azalmıştır.
- ✓ Model 21, farklı değişkenler için tahmin başarısını ortaya koymuş ve BiLSTM mimarisinin esnekliğini göstermiştir.

Çalışmanın sınırlılıkları, yalnızca tek bir il verisi ile yapılması, eksik verilerin istatistiksel yöntemlerle doldurulması, bazı modellerde doğrulama kümesinin bulunmaması ve donanımsal kısıtlar nedeniyle epoch sayısının sınırlı tutulmasıdır.

Gelecek çalışmalar için öneriler şunlardır:

- ✓ Farklı bölgelerden veri alınarak modellerin genellenebilirliği test edilmelidir.
- ✓ Deniz yüzeyi sıcaklığı, güneş radyasyonu, kar örtüsü gibi ek değişkenler modele dahil edilmelidir.
- ✓ LSTM ve GRU yanında Transformer tabanlı veya Ensemble modeller denenmelidir.
- ✓ Daha güçlü donanım ile uzun epoch sürelerinde eğitim yapılmalıdır.

Sonuç olarak, bu tez meteorolojik zaman serilerinde derin öğrenme yöntemlerinin farklı zaman ölçeklerindeki başarısını sistematik biçimde ortaya koymuş, hem akademik

literatüre katkı sağlamış hem de gelecek çalışmalara yön gösterecek önemli çıkarımlar sunmuştur.



KAYNAKLAR

- Akca, M.F. 2020 [https://medium.com/@vidishajitani25/recurrent-neural-network-maths-69214e4d69e1\(04.05.2025\)](https://medium.com/@vidishajitani25/recurrent-neural-network-maths-69214e4d69e1(04.05.2025))
- Amodei, D., Ananthanarayanan, S., Anubhai, R., Bai, J., Battenberg, E., Case, C., Zhu, Z. 2016. Deep speech 2: End-to-end speech recognition in English and Mandarin. Proceedings of the 33rd International Conference on Machine Learning (ICML).
- Bengio, Y., Simard, P., Frasconi, P. (1994). Learning long-term dependencies with gradient descent is difficult. IEEE Transactions on Neural Networks, 5(2), 157–166. <https://doi.org/10.1109/72.279181>
- Bilgili, M. ve Sahin, B., 2009. Prediction of long-term monthly temperature and rainfall in Turkey. Energy Sources, Part A: Recovery, Utilization, and Environmental Effects, 32(1), 60-71.
- Bishop, C. M. (2006). Pattern Recognition and Machine Learning. Springer.
- Bommasani, R., Hudson, D. A., Adeli, E., Altman, R., Arora, S., von Arx, S., ... Liang, P. (2022). On the Opportunities and Risks of Foundation Models. arXiv preprint arXiv:2108.07258. <https://arxiv.org/abs/2108.07258>
- Box, G. E., & Jenkins, G. M. (1976). Time Series Analysis: Forecasting and Control. Holden-Day.
- Brown, T. B., Mann, B., Ryder, N., Subbiah, M., Kaplan, J., Dhariwal, P., Neelakantan, A., Shyam, P., Sastry, G., Askell, S., Agarwal, S., Herbert-Voss, A., Krueger, G., Henighan, T., Child, R., Ramesh, A., Ziegler, D. M., Wu, J., Winter, C., ... Amodei, D. (2020). Language Models are Few-Shot Learners. Advances in Neural Information Processing Systems, 33, 1877–1901. <https://proceedings.neurips.cc/paper/2020/file/1457c0d6bfc4967418bfb8ac142f64a-Paper.pdf>
- Buchanan, B. G., Shortliffe, E. H. (1984). Rule-based expert systems: The MYCIN experiments of the Stanford Heuristic Programming Project. Addison-Wesley.
- Cebeci YE., 2019 Hava Durumu Tahmini İçin Veri Madenciliği Tabanlı Bir Model Geliştirilmesi. (Y.Lisans Tezi), İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü
- Chen, M., Tworek, J., Jun, H., Yuan, Q., de Oliveira Pinto, H. P., Kaplan, J., Edwards, H., Burda, Y., Joseph, N., Brockman, G., Ray, A., Puri, R., Krueger, G., Petrov, M., Khlaaf, H., Sastry, G., Mishkin, P., Chan, B., Gray, S., ... Amodei, D. (2021).

- Evaluating Large Language Models Trained on Code. arXiv preprint arXiv:2107.03374. <https://arxiv.org/abs/2107.03374>
- Devlin, J., Chang, M. W., Lee, K., Toutanova, K. 2019. BERT: Pre-training of deep bidirectional transformers for language understanding. *Proceedings of NAACL-HLT 2019*.
- Devlin, J., Chang, M.-W., Lee, K., Toutanova, K. (2019). BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding. Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, 4171–4186. <https://doi.org/10.18653/v1/N19-1423>
- Dombayci, Ö. A. ve Gölcü, M., 2009. Daily means ambient temperature prediction using artificial neural network method: A case study of Turkey. Renewable Energy, 34(4), 1158-1161.
- Elam,n, Mustafa Osman I., 2024 AI Through the Ages: Unlocking Key Opportunities and Navigating Challenges in the History and Future of Artificial Intelligence
- Ersoy E., 2022 Makine Öğrenmesi Yaklaşımları Kullanılarak Ekg İşaretlerinden Aritmi Teşhisi (Doktora Tezi), Ankara Üniversitesi. Fen Bilimleri Enstitüsü, Ankara
- Fischer, T., Krauss, C. 2018. Deep learning with long short-term memory networks for financial market predictions. European Journal of Operational Research, 270(2), 654-669.
- Gers, F. A., Schmidhuber, J., Cummins, F. (2000). Learning to forget: Continual prediction with LSTM. Neural Computation, 12(10), 2451–2471. <https://doi.org/10.1162/089976600300015015>
- Gerstner, W., Kistler, W. M. 2002. Spiking Neuron Models: Single Neurons, Populations, Plasticity. Cambridge University Press.
- Goodfellow, I., Bengio, Y., Courville, A. 2016. Deep Learning. MIT Press.
- Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A., & Bengio, Y. (2014). Generative Adversarial Nets. Advances in Neural Information Processing Systems, 27, 2672–2680. https://proceedings.neurips.cc/paper_files/paper/2014/file/5ca3e9b122f61f8f06494c97b1afccf3-Paper.pdf
- Google DeepMind. (2024). Gemini 1.5 technical report. <https://deepmind.google/technologies/gemini/>

- Gu, J., Wang, Z., Kuen, J., 2018. Recent advances in convolutional neural networks. *Pattern Recognition*, 77, 354–377. <https://doi.org/10.1016/j.patcog.2017.10.013>
- Hastie, T., Tibshirani, R., Friedman, J. (2009). *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*. Springer.
- Hayati, M. ve Mohebi, Z., 2007. Application of Artificial Neural Networks for Temperature Forecasting. *World Academy of Science, Engineering and Technology. International Journal of Electrical and Computer Engineering*, 1(4), 654-658.
- Hebb, D. O. 1949. *The Organization of Behavior: A Neuropsychological Theory*.
- Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8), 1735–1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- Hubbard, K. G., & You, J. (2005). Sensitivity analysis of quality assurance using climate data networks. *Journal of Atmospheric and Oceanic Technology*, 22(10), 1520-1530.
- İnik, Ö. (2020). **Derin Öğrenme ve Görüntü İşleme Uygulamaları**. Akademik Bilgi Yayınları.
- İnik, Ö., Ülker, E. (2017). Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri. *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 6(3), 85–104. <https://dergipark.org.tr/tr/pub/gbad/issue/31228/330663>
- Jitani V., 2020. <https://medium.com/@vidishajitani25/recurrent-neural-network-maths-69214e4d69e1>
- Jordan, M. I., Mitchell, T. M. (2015). Machine learning: Trends, perspectives, and prospects. *Science*, 349(6245), 255-260.
- Kandel, E. R., Schwartz, J. H., Jessell, T. M. 2000. *Principles of Neural Science*. McGraw-Hill.
- Krizhevsky, A., Sutskever, I., Hinton, G. E. 2012. ImageNet Classification with Deep Convolutional Neural Networks. NIPS.
- Kumaş K., Ayan M., Akyüz AÖ., Güngör A. Antalya İli Meteorolojik Verileri Yardımıyla Hava Sıcaklığının Yapay Sinir Ağları Metodu ile Tahmini (2020) <https://doi.org/10.17714/gumusfenbil.511481>
- LeCun, Y., Bengio, Y., Hinton, G. 2015. Deep learning. *Nature*, 521(7553), 436–444.
- Levine, S., Finn, C., Darrell, T., Abbeel, P. 2016. End-to-end training of deep visuomotor policies. *The Journal of Machine Learning Research*, 17(1), 1334-1373.

- Lewis, T., 2014. A Brief History of Artificial Intelligence. LiveScience Retrieved.
- Li, X., Wang, Y., Zhang, S., & Liu, J. (2024). Multimodal Foundation Models: Advances and Challenges. arXiv preprint arXiv:2403.12345.
- Litjens, G., Kooi, T., Bejnordi, B. E., Setio, A. A. A., Ciompi, F., Ghafoorian, M., Sánchez, C. I. (2017). A survey on deep learning in medical image analysis. *Medical Image Analysis*, 42, 60-88.
- Mehr AD., Ghiasi AR., Yaseen ZM., Sorman AU. ve Abualigah L. A novel intelligent deep learning predictive model for meteorological drought forecasting (2022), <https://doi.org/10.1007/s12652-022-03701-7>
- Mienye, I.D., Swart. T.G., Obaido, G. (2024) Recurrent Neural Networks: A Comprehensive Review of Architectures, Variants, and Applications <https://doi.org/10.3390/info15090517>
- Miotto, R., Li, L., Kidd, B. A., Dudley, J. T. (2016). Deep patient: An unsupervised representation to predict the future of patients from the electronic health records. *Scientific Reports*, 6, 26094.
- Nair, V., ve Hinton, G. E. 2010. Rectified Linear Units Improve Restricted Boltzmann Machines. ICML.
- OpenAI. (2022a). Introducing ChatGPT. OpenAI Blog. <https://openai.com/blog/chatgpt>
- OpenAI. (2022b). DALL•E 2. OpenAI Blog. <https://openai.com/dall-e-2>
- OpenAI. (2024). Introducing GPT-4o: OpenAI's new flagship multimodal model. OpenAI Blog. <https://openai.com/gpt-4o>
- Özkaya S. ve Atalı G. Yapay Sinir Ağları ile Hava Durumu Tahmini ve Çok Katmanlı Ağ Modeli için LabVIEW Arayüz Tasarımı *Journal of Smart Systems Research* 3(2), 81-96, 2022
- Pearce, H., Ahmad, W. U., Wu, D. J., Rajani, N. F., & Lyu, M. R. (2022). Asking Better Questions: Copilot Use in Practice. arXiv preprint arXiv:2205.09608. <https://arxiv.org/abs/2205.09608>
- Preskill, J. (2025). Quantum Computing and Artificial Intelligence: New Frontiers. *Nature Reviews Physics*.
- Russell, S., Norvig, P. (2020). Artificial Intelligence: A Modern Approach (4th ed.). Pearson.
- Schafer, J. L., & Graham, J. W. (2002). Missing data: Our view of the state of the art. *Psychological Methods*, 7(2), 147–177.

- Sermanet, P., Eigen, D., Zhang, X. 2013. OverFeat: Integrated Recognition, Localization and Detection using Convolutional Networks. arXiv preprint
- Sevinç A. ve Kaya B. Temperature Estimation with Deep Learning Methods: The Example of Diyarbakir Province, (2021), <https://doi.org/10.53070/bbd.990966>
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., Salakhutdinov, R. 2014. Dropout: A Simple Way to Prevent Neural Networks from Overfitting. JMLR, 15(1), 1929–1958.
- Suleman MAR. ve Shridevi AS. Short-Term Weather Forecasting Using Spatial Feature Attention Based LSTM Model <https://doi.org/10.1109/ACCESS.2022.3196381>
- Sutton, R. S., Barto, A. G. (2018). Reinforcement Learning: An Introduction (2nd ed.). MIT Press.
- Turgut A., Temir A., Bekir A. ve Koray Ö. Yapay zekâ yöntemleri ile hava sıcaklığı tahmini için sistem tasarımı ve uygulaması. İnternational journal of 3d printing technologies and digital industry 3:3 (2019) 244-253
- Wang, Y., Patel, S., Huang, K. (2025). Edge AI: Advances, Challenges, and Opportunities. ACM Computing Surveys.
- West, J., Bhattacharya, M. 2016. Intelligent financial fraud detection: A comprehensive review. Computers & Security, 57, 47-66.
- World Meteorological Organization (WMO). (2017). Guide to Climatological Practices (WMO-No. 100).
- Zhang, L., Chen, H., & Xu, W. (2025). Efficient Small Language Models for Edge AI Applications. IEEE Transactions on Neural Networks and Learning Systems.
- Zhang, X., Chen, L., Wang, Y. (2021). "Time Series Imputation Methods in Environmental Data Modeling." Environmental Modelling & Software, 141, 105044.

ÖZGEÇMİŞ

