

KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

HARİTA MÜHENDİSLİĞİ ANABİLİM DALI

KARADENİZ'DE DENİZ SEVİYESİ DEĞİŞİMLERİNİN
DERİN ÖĞRENME YÖNTEMLERİ İLE MODELLENMESİ

DOKTORA TEZİ

Ahmet YAVUZDOĞAN

EKİM 2025
TRABZON



**KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

HARİTA MÜHENDİSLİĞİ ANABİLİM DALI

**KARADENİZ'DE DENİZ SEVİYESİ DEĞİŞİMLERİNİN
DERİN ÖĞRENME YÖNTEMLERİ İLE MODELLENMESİ**

Ahmet YAVUZDOĞAN

**Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsünde
“DOKTOR (HARİTA MÜHENDİSLİĞİ)”
Unvanı Verilmesi İçin Kabul Edilen Tezdir.**

Tezin Enstitüye Verildiği Tarih : 15/09/2025

Tezin Savunma Tarihi : 17/10/2025

Tez Danışmanı : Prof. Dr. Emine TANIR KAYIKÇI

Trabzon 2025

KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Harita Mühendisliği Anabilim Dalında
Ahmet YAVUZDOĞAN Tarafından Hazırlanan

KARADENİZ'DE DENİZ SEVİYESİ DEĞİŞİMLERİNİN
DERİN ÖĞRENME YÖNTEMLERİ İLE MODELLENMESİ

başlıklı bu çalışma, Enstitü Yönetim Kurulunun 25/09/ 2025 gün ve 2121 sayılı
kararıyla oluşturulan jüri tarafından yapılan sınavda
DOKTORA TEZİ
olarak kabul edilmiştir.

Jüri Üyeleri

Başkan : Prof. Dr. Mualla YALÇINKAYA

Üye : Prof. Dr. Emine TANIR KAYIKÇI

Üye : Prof. Dr. Abdulaziz GÜNEROĞLU

Üye : Prof. Dr. Yasemin ŞİŞMAN

Üye : Doç. Dr. Mahmut Oğuz SELBESOĞLU

Prof. Dr. Asim KADIOĞLU
Enstitü Müdürü

ÖNSÖZ

“Karadeniz’de Deniz Seviyesi Değişimlerinin Derin Öğrenme Yöntemleri ile Modellenmesi” isimli bu tez Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü Harita Mühendisliği Anabilim Dalı, Doktora Programı’nda hazırlanmıştır.

Tez çalışmam boyunca hiçbir desteğini esirgemeyen ve bilim insanı olma yolundaki ilk adımlarımı atarken kıymetli bilgileriyle ve tecrübesiyle yolumu aydınlatan danışman hocam Sayın Prof. Dr. Emine TANIR KAYIKÇI ’ya teşekkürü bir borç bilirim. Ayrıca, yapıcı eleştirileri ve önerileri ile tezime büyük katkıları bulunan saygıdeğer hocam Sayın Prof. Dr. Mualla YALÇINKAYA’ya, eğitim öğretim hayatımda katkısı olan tüm hocalarıma ve ortak olarak çalışmalar yürüttüğümüz ve tez çalışması süresince hiçbir yardımdan kaçınmayan arkadaşlarım Dr. Öğretim Üyesi Samed ÖZDEMİR ve Dr. Öğretim Üyesi Zeynep AKBULUT ’a teşekkür ederim.

Doğduğum günden beri elimi hiç bırakmayan, hayatım boyunca aldığım tüm kararlarda bilgi ve tecrübelerinden faydalandığım ve her kararında arkamda olan, maddi ve manevi desteklerini hiçbir zaman esirgemeyen ve bugünlere gelmemde en büyük paya sahip olan anneme, babama ve sevgili kardeşime teşekkürü bir borç bilirim.

Son olarak, hayatımın her anında yanımda olan, sabrı ve desteğiyle bana güç veren sevgili eşime ve tez sürecinde bana ilham kaynağı olan canım kızım Masal’a minnettarlığımı ifade etmek isterim. Onların sevgisi, anlayışı ve desteği olmasaydı bu çalışmayı tamamlamak mümkün olmazdı.

Bu tez çalışmasının bundan sonraki çalışmalara katkı sağlamasını temenni ederim.

Ahmet YAVUZDOĞAN

Trabzon 2025

TEZ ETİK BEYANNAMESİ

Doktora Tezi olarak sunduđum “Karadeniz’de Deniz Seviyesi Deęiřimlerinin Derin Öğrenme Yöntemleri ile Modellenmesi” başlıklı bu çalışmayı baştan sona kadar danışmanım Prof. Dr. Emine TANIR KAYIKÇI ‘nın sorumluluğunda tamamladıđımı, analizleri kendim yaptıđımı, başka kaynaklardan aldıđım bilgileri metinde ve kaynakçada eksiksiz olarak gösterdiđimi, çalışma sürecinde bilimsel araştırma ve etik kurallara uygun olarak davrandıđımı ve aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiđimi beyan ederim. 17/10/2025

Ahmet YAVUZDOĞAN

İÇİNDEKİLER

	<u>Sayfa No</u>
ÖNSÖZ.....	III
TEZ ETİK BEYANNAMESİ.....	IV
İÇİNDEKİLER.....	V
ÖZET	VIII
SUMMARY	IX
ŞEKİLLER DİZİNİ	X
TABLolar DİZİNİ.....	XIII
SEMBOLLER VE KISALTMALAR DİZİNİ	XV
1. GENEL BİLGİLER	1
1.1. Giriş	1
1.2. Problemin Tanımı ve Motivasyon.....	3
1.3. Literatür Taraması ve Teorik Çerçeve.....	5
1.4. Tezin Amacı ve Kapsamı	9
1.5. Tezin Araştırma Soruları ve Hipotezler	13
1.6. Tezin Uygulanabilirliği ve Pratik Değeri.....	15
1.7. Tezin Yapısı ve Bölümlerin Özeti	16
1.8. Deniz Seviyesi Değişimleri: Tarihsel Perspektif ve Güncel Durum.....	17
1.9. Deniz Seviyesi Değişiminin Nedenleri ve İklim Değişikliği	18
1.10. Deniz Seviyesi Artışlarının Sebep Olduğu Çevresel Etkiler	19
1.11. Deniz Seviyesi Artışlarının İzlenmesi, Tahmini ve Modellenmesinin Önemi.....	20
1.12. Deniz Seviyesi Değişimi Ölçme Teknikleri ve Veri Kaynakları.....	21
1.13. İklim Değişikliği ve Erken Uyarı Sistemleri	24
2. METODOLOJİ	32
2.1. Makine Öğrenimi Yöntemleri.....	34
2.1.1. Çoklu Doğrusal Regresyon	35
2.1.2. Destek Vektör Regresyonu	36
2.1.3. Rastgele Orman Regresyonu.....	39
2.2. Yapay Sinir Ağları.....	41
2.2.1. İleri Yayılım (Forward Propagation).....	42
2.2.2. Aktivasyon Fonksiyonları	42

2.2.3. Öğrenme Süreci ve Geri Yayılım (Backpropagation)	43
2.2.4. Hata Fonksiyonu (Loss Function)	44
2.2.5. Optimizasyon Algoritmaları	46
2.3. Derin Öğrenme Yöntemleri	47
2.3.1. Tekrarlayan (Yinelemeli) Sinir Ağları.....	47
2.3.2. Uzun Kısa Süreli Bellek Ağları ve Mimarisi	50
2.3.3. Yığılmış (Stacked) Uzun Kısa Süreli Bellek Ağları.....	52
2.3.4. Oto-Kodlayıcı (Auto-Encoder) Modeller ve Mimarileri.....	54
2.3.5. Evrişimli Uzun Kısa Süreli Bellek Ağları ve Mimarisi.....	57
2.4. Derin Öğrenme Uygulamalarında Hiperparametre Optimizasyonu	59
2.4.1. Hiperparametre Optimizasyon Teknikleri	59
2.4.2. Derin Öğrenme Modellerinde Temel Hiperparametreler	64
2.5. Derin Öğrenme Uygulamalarında Verilerin Ön İşleme Süreçleri.....	68
2.6. Derin Öğrenme Uygulamalarında Model Performans Analizi ve Metrikler	75
2.6.1. Karesel Ortalama Hata-KOH (Root Mean Squared Error- RMSE)	77
2.6.2. Pearson Doğrusal Korelasyon Katsayısı (R).....	77
2.7. Derin Öğrenme Uygulamalarında Genelleştirme Analizi.....	78
3. VERİ SETLERİ VE YAPILAN ÇALIŞMALAR.....	80
3.1. Tez Çalışmasında Kullanılan Veri Setlerinin Tanıtımı ve Özellikleri	81
3.1.1. Veri Seti 1: Karadeniz DUACS Radar Altimetre Veri Seti	81
3.1.2. Veri Seti 2: Karadeniz CMEMS Radar Altimetre Veri Seti.....	83
3.1.3. Veri Seti 3: Karadeniz Mareograf Veri Seti.....	84
3.1.4. Ege Denizi Pilot Çalışma Veri Seti: Ege Denizi Mareograf ve Meteorolojik Gözlem Verileri	85
3.2. Derin Öğrenme Sürecine Hazırlık Ön Çalışma: Ege Denizi Pilot Modelleme Çalışması.....	86
3.2.1. Ege Denizi Pilot Uygulamada Kullanılan Makine Öğrenimi Yaklaşımları ve Uygulama Amacı	87
3.2.2. Ege Denizi Pilot Uygulamada Kullanılan Veri Setleri ve Çalışma Alanı	88
3.2.3. Ege Denizi Pilot Çalışma Veri Ön İşleme Süreçleri.....	88
3.2.4. Makine Öğrenimi Modellerinde Kullanılacak Öncül Bilgilerin (Öznitelik) Çıkarımı.....	95
3.2.5. Makine Öğrenimi Modellerinin Performanslarının Karşılaştırılması	98
3.2.6. Ege Denizi Pilot Çalışma Bulguları	98

3.2.7. Ege Denizi Pilot Çalışma Sonuçları	104
3.3. Karadeniz’de Derin Öğrenme Yöntemleri ile Deniz Seviyesi Değişimlerinin Modellenmesi.....	105
3.3.1. Derin Öğrenme Ağlarında Kullanılmak Üzere DUACS Veri Setinin Hazırlanması.....	106
3.3.2. Uygulama 1: Yığılmış Uzun Kısa Süreli Bellek Modeli ile Karadeniz’de Deniz Seviyesi Anomalilerinin Tahmini	112
3.3.3. Uygulama 2: Oto-Kodlayıcı Temelli Uzun Kısa Süreli Bellek Modeli ile Karadeniz’de Deniz Seviyesi Anomalilerinin Tahmini.....	121
3.3.4. Uygulama 3: Evrişimli Uzun Kısa Süreli Bellek Modeli ile Karadeniz’de Deniz Seviyesi Anomalilerinin Tahmini	127
3.3.5. Uygulama 4: Sönümlü Kalıcılık Modeli ile Karadeniz’de Deniz Seviyesi Tahmini.....	137
3.3.6. Modellerin Performans Karşılaştırması ve Analizi	140
3.3.7. Genelleştirme Kabiliyeti Analizi ve Model Validasyonu	146
3.4. Karadeniz Deniz Seviyesi Erken Uyarı Sisteminin Tasarımı ve Uygulaması:	
TideGuard Yazılımı.....	163
3.4.1. Sistem Mimarisi ve Fonksiyonları	164
3.4.2. Kullanıcı Arayüzü Tasarımı.....	164
3.4.3. Erken Uyarı Sisteminin Performans Analizi ve Simülasyonlar	166
3.5. Çevresel Modelleme İçin Açık Kaynak Kodlu Derin Öğrenme Yazılımı Tasarımı ve Uygulaması: Envilearn Yazılımı	174
3.5.1. Arayüz Tasarımı ve Geliştirme Süreci.....	175
4. TARTIŞMA VE DEĞERLENDİRME	182
4.1. Bulguların Literatürle Karşılaştırılması	182
4.2. Modellerin Genelleştirme ve Validasyon Performanslarının Karşılaştırılması	183
4.3. Erken Uyarı Sisteminin Performansının Tartışılması	185
5. SONUÇLAR VE ÖNERİLER.....	187
6. KAYNAKLAR	190
ÖZGEÇMİŞ	

Doktora Tezi

ÖZET

KARADENİZ’DE DENİZ SEVİYESİ DEĞİŞİMLERİNİN DERİN ÖĞRENME
YÖNTEMLERİ İLE MODELLENMESİ

Ahmet YAVUZDOĞAN

Karadeniz Teknik Üniversitesi
Fen Bilimleri Enstitüsü
Harita Mühendisliği Anabilim Dalı
Danışman: Prof. Dr. Emine TANIR KAYIKÇI
2025, 222 Sayfa

Küresel iklim değişikliğinin en yıkıcı sonuçlarından biri deniz seviyesi yükselmesidir. Termal genleşme ve buzulların erimesiyle hızlanan bu süreç, kıyı ekosistemlerini tahrip etmekte, altyapıyı tehdit etmekte ve milyonlarca insanın yerinden edilmesine yol açmaktadır. Bu risklerin önüne geçebilmek için deniz seviyesindeki değişimlerin hassas bir şekilde modellenmesi ve geleceğe yönelik güvenilir tahminler üretilmesi büyük önem taşımaktadır. Ancak mevcut literatürde kullanılan yöntemlerin sınırlılıkları nedeniyle daha güçlü ve geliştirilebilir modellere ihtiyaç duyulmaktadır. Bu bağlamda Karadeniz, jeostratejik konumu, kıyı yerleşimlerinin yoğunluğu, ekolojik hassasiyeti ve iklim değişikliğine karşı kırılganlığı nedeniyle önem taşımaktadır. Bu doktora tezinde Karadeniz’deki deniz seviyesi değişimlerinin modellenmesi için uydu radar altimetre verileri kullanılmıştır. Literatürde yaygın olan Yığılmış LSTM ve Sönümlü Kalıcılık yöntemlerine ek olarak, ilk kez ConvLSTM ve Oto-Kodlayıcı LSTM mimarileri bu amaçla uygulanmıştır. Ayrıca manuel hiperparametre optimizasyonu yerine Bayesyen otomatik hiperparametre optimizasyon yöntemi deniz seviyesi modelleme çalışmalarında ilk defa kullanılmıştır. Tez çalışmanın çıktısı olan deniz seviyesi erken uyarı sistemi, uluslararası veri merkezlerinden güncel verileri çekerek kullanıcı dostu bir arayüz üzerinden 15 günlük tahminler sunmaktadır. Bu tez, Türkiye’de deniz seviyesi modellemesine yönelik yapılan ilk kapsamlı çalışma olarak literatüre yeni derin öğrenme mimarileri kazandırmakta ve akademik çıktıları operasyonel bir erken uyarı sistemine dönüştürerek özgün katkılar sağlamaktadır.

Anahtar Kelimeler: Deniz Seviyesi, Derin Öğrenme, Karadeniz, Erken Uyarı, LSTM

PhD. Thesis

SUMMARY

MODELING SEA LEVEL VARIATIONS IN THE BLACK SEA USING DEEP LEARNING METHODS

Ahmet YAVUZDOĞAN

Karadeniz Technical University
The Graduate School of Natural and Applied Sciences
Departments of Geomatics Engineering
Supervisor: Prof. Dr. Emine TANIR KAYIKÇI
2025, 222 Pages

One of the most devastating consequences of global climate change is sea level rise. Accelerated by thermal expansion and the melting of glaciers, this process destroys coastal ecosystems, threatens infrastructure, and leads to the displacement of millions of people. To mitigate these risks, it is of great importance to model sea level changes precisely and to produce reliable future predictions. However, due to the limitations of the methods used in the current literature, there is a need for stronger and more generalizable models. In this context, the Black Sea is of particular importance due to its geostrategic position, dense coastal settlements, ecological sensitivity, and vulnerability to climate change. In this doctoral thesis, satellite radar altimetry data were used to model sea level changes in the Black Sea. In addition to the commonly used Stacked LSTM and Damped Persistence methods in the literature, ConvLSTM and Auto-Encoder LSTM architectures were applied for this purpose for the first time. Furthermore, instead of manual hyperparameter optimization, Bayesian automatic hyperparameter optimization was employed in sea level modelling studies for the first time. The outcome of the thesis is a sea level early warning system that retrieves up-to-date data from international data centers and offers 15-day forecasts through a user-friendly interface. As the first comprehensive study on sea level modelling in Turkey, this thesis introduces novel deep learning architectures to the literature and provides original contributions by transforming academic outputs into an operational early warning system.

Key Words: Sea Level, Deep Learning, Black Sea, Early Warning, LSTM

ŞEKİLLER DİZİNİ

Sayfa No

Şekil 1.	EGM 2008 Jeoidi.....	1
Şekil 2.	Uydu altimetresi tekniğiyle deniz seviyesi ölçümü.....	22
Şekil 3.	Deniz seviyesi erken uyarı sistemine sahip ülkeler	30
Şekil 4.	Yapay zeka, makine öğrenimi ve derin öğrenme yöntemlerinin ilişkisi	32
Şekil 5.	Destek vektör regresyonu	37
Şekil 6.	DVR algoritmasında çekirdek fonksiyonları.....	38
Şekil 7.	Rastgele orman regresyonu algoritması	40
Şekil 8.	Biyolojik sinir hücresi (solda) ve yapay sinir ağı (sağda)	42
Şekil 9.	Sıklıkla kullanılan aktivasyon fonksiyonları	43
Şekil 10.	RNN hücre yapısı	48
Şekil 11.	LSTM hücre yapısı	51
Şekil 12.	Yığılmış LSTM model yapısı.....	53
Şekil 13.	Oto-Kodlayıcı genel yapısı.....	55
Şekil 14.	ConvLSTM hücre yapısı	57
Şekil 15.	Hiperparametre optimizasyon döngüsü.....	63
Şekil 16.	Karadeniz DUACS deniz seviyesi anomali veri seti.....	81
Şekil 17.	Eğitim, doğrulama ve test veri setleri.....	83
Şekil 18.	Karadeniz CMEMS deniz seviyesi anomali veri seti.	84
Şekil 19.	TRAB mareograf istasyonu konumu.....	85
Şekil 20.	Ege Denizi'nde Menteş ve Bodrum istasyonlarının konumları.....	86
Şekil 21.	Bodrum istasyonu için mevsimsel bileşen ve gelgit bileşeni	93
Şekil 22.	Bodrum istasyonunda elde edilen uyşumsuz ölçüler.....	94
Şekil 23.	Menteş istasyonunda elde edilen uyşumsuz ölçüleri.....	94
Şekil 24.	Bodrum istasyonu hareketli ortalama doldurulan veri noktaları (Kırmızı x işareti doldurulan veri noktalarını göstermektedir.)	94
Şekil 25.	Menteş istasyonu hareketli ortalama doldurulan veri noktaları (Kırmızı x işareti doldurulan veri noktalarını göstermektedir.)	95
Şekil 26.	Yatay ve düşey rüzgar bileşenlerinin hesaplanması	97
Şekil 27.	Makine öğrenimi algoritmalarının eğitiminde kullanılan öncül bilgiler	97
Şekil 28.	ÇDR algoritması model tahminleri ve gözlemlenen deniz seviyesi değerleri....	99
Şekil 29.	ÇDR algoritması deniz seviyesi tahmin performansı.....	100

Şekil 30. DVR algoritması model tahminleri ve gözlemlenen deniz seviyesi değerleri .	101
Şekil 31. DVR algoritması deniz seviyesi tahmin performansı.....	101
Şekil 32. ROR algoritmasında ağaç sayısının tahmin performansına etkisi.....	102
Şekil 33. ROR algoritması model tahminleri ve gözlemlenen deniz seviyesi değerleri	103
Şekil 34. ROR algoritması deniz seviyesi tahmin performansı	103
Şekil 35. ÇDR, DVR ve ROR algoritmalarının karşılaştırılması	104
Şekil 36. Kayan pencere mekanizması	110
Şekil 37. Hiperparametre optimizasyonu döngüsü	113
Şekil 38. Yığılmış LSTM ağı model mimarisi	115
Şekil 39. Yığılmış LSTM ağı hata grafiği	117
Şekil 40. Yığılmış LSTM Ağı için karşılaştırmalı KOH haritaları.....	120
Şekil 41. Oto-Kodlayıcı LSTM ağı model mimarisi	123
Şekil 42. Oto-Kodlayıcı LSTM ağı hata grafiği	125
Şekil 43. Oto-Kodlayıcı LSTM ağı için karşılaştırmalı KOH haritaları	126
Şekil 44. DUACS veri setinin ConvLSTM mimarisi için ön işleme aşamaları	129
Şekil 45. ConvLSTM mimarisi için görüntü bloklarının oluşturulması.....	130
Şekil 46. ConvLSTM modelinde kullanılan SLA veri setinin yeniden yapılandırılması.	130
Şekil 47. ConvLSTM model mimarisi.....	131
Şekil 48. ConvLSTM modelinin eğitim ve doğrulama hata eğrisi	135
Şekil 49. ConvLSTM ağı için KOH dağılımı	137
Şekil 50. Sönümlü kalıcılık modeli için karşılaştırmalı KOH haritaları	139
Şekil 51. Farklı tahmin modellerinin seçilen noktadaki (a’da kırmızı işaretli nokta) SLA tahmin performansları	142
Şekil 52. Yığılmış LSTM, LSTM Oto-Kodlayıcı ve sönümlü kalıcılık modellerine ait 1 gün (üst), 2 gün (orta) ve 3 gün (alt) tahmin ufukları için KOH ve r değerlerinin kutu grafikleri.....	144
Şekil 53. CMEMS verisi üzerinde yığılmış LSTM modelinin KOH dağılımı (a – 1 gün ileri tahmin, b – 2 gün ileri tahmin, c – 3 gün ileri tahmin)	149
Şekil 54. CMEMS verisi üzerinde Oto-Kodlayıcı LSTM modelinin KOH dağılımı (a – 1 gün ileri tahmin, b – 2 gün ileri tahmin, c – 3 gün ileri tahmin)	152
Şekil 55. ConvLSTM modelinde kullanılan CMEMS veri setinin yeniden yapılandırılması.	155
Şekil 56. ConvLSTM modelinin CMEMS veri seti ile eğitimine ilişkin eğitim ve doğrulama hata eğrileri	157
Şekil 57. ConvLSTM Modeli CMEMS test veri seti hata haritası	158
Şekil 58. TRAB mareograf verisinde derin öğrenme model tahminleri.....	161

Şekil 59. Erken uyarı sisteminde kullanılan ardışık genişleyen pencere yaklaşımı	163
Şekil 60. Tideguard yazılımı arayüzü iş akışı.....	165
Şekil 61. Simülasyonlar sonucunda elde edilen korelasyon ısı haritası	167
Şekil 62. Simülasyonlar sonucunda elde edilen KOH ısı haritası	167
Şekil 63. Simülasyonlar sonucunda tahmin günlerine göre elde edilen ortalama korelasyon katsayıları	168
Şekil 64. Simülasyonlar sonucunda tahmin günlerine göre elde edilen ortalama KOH değerleri	169
Şekil 65. Simülasyonlar sonucunda elde edilen korelasyon sonuçlarının dağılımı.....	171
Şekil 66. Simülasyonlar sonucunda elde edilen KOH sonuçlarının dağılımı.....	171
Şekil 67. Simülasyonlar sonucunda elde edilen korelasyon sonuçlarının kümülatif dağılımı.....	172
Şekil 68. Simülasyonlar sonucunda elde edilen KOH sonuçlarının kümülatif dağılımı .	172
Şekil 69. Envilearn yazılımı veri yükleme sekmesi.....	176
Şekil 70. Envilearn yazılımında LSTM mimarisi ile derin öğrenme modelinin yapılandırıldığı Model Geliştirme sekmesinin arayüz görünümü.	177
Şekil 71. Envilearn yazılımı model eğitimi sekmesi	178
Şekil 72. Envilearn yazılımı model tahminleme sekmesi.....	179
Şekil 73. Envilearn yazılımı model performans sekmesi	180

TABLolar DİZİNİ

Sayfa No

Tablo 1. Deniz seviyesi tahmini üzerine yapılan çalışmalar ve kullanılan yöntemler	9
Tablo 2. Sıklıkla kullanılan aktivasyon fonksiyonları ve formülasyonları	43
Tablo 3. Bodrum istasyonu doğrusal trend bileşeni katsayı anlamlılık testi	89
Tablo 4. Menteş istasyonu doğrusal trend bileşeni katsayı anlamlılık testi	90
Tablo 5. Astronomik gelgit bileşenleri	90
Tablo 6. Menteş istasyonunda anlamlı sinyallerin frekans, genlik ve faz değerleri	92
Tablo 7. Bodrum istasyonunda anlamlı sinyallerin frekans, genlik ve faz değerleri	93
Tablo 8. Hiperparametre uzayı boyutları	110
Tablo 9. Farklı optimizasyon yöntemleriyle elde edilen en uygun hiperparametre Setleri	111
Tablo 10. Optimizasyon yöntemlerine göre model performansları	111
Tablo 11. Optimizasyon yöntemlerine göre işlem süreleri	111
Tablo 12. Yığılmış LSTM ağının hiperparametre optimizasyonu için parametre uzayı ...	114
Tablo 13. Yığılmış LSTM ağı için HPO sonucunda elde edilen optimal hiperparametre seti	115
Tablo 14. Yığılmış LSTM ağı test veri seti tahmin performansları	119
Tablo 15. Oto-Kodlayıcı LSTM ağı için hiperparametre uzayı boyutları	123
Tablo 16. Oto-Kodlayıcı LSTM ağı için HPO sonucunda elde edilen optimal hiperparametre seti	123
Tablo 17. Oto-Kodlayıcı LSTM ağı test veri seti tahmin performansları	125
Tablo 18. Test veri setinde ConvLSTM model performansları	136
Tablo 19. Test veri setinde sönümlü kalıcılık modeli için performans sonuçları	138
Tablo 20. Tahmin model performanslarının tahmin ufkuna göre performansları	141
Tablo 21. Farklı tahmin ufuklarında modellerin minimum ve maksimum KOH değerleri	143
Tablo 22. CMEMS veri seti üzerinde yığılmış LSTM modelinin 1 günlük tahmin performansı	148
Tablo 23. CMEMS veri seti üzerinde Oto-Kodlayıcı LSTM modelinin tahmin performansı	151
Tablo 24. CMEMS veri setinde ConvLSTM modelinin yeniden eğitim performansı	157
Tablo 25. TRAB bağıl deniz seviyesi zaman serisinde derin öğrenme modellerinin genelleştirme performansı	162

Tablo 26. Literatürdeki deniz seviyesi tahmin çalışmalarında kullanılan yöntemler ve performansları.....	182
--	-----



SEMBOLLER VE KISALTMALAR DİZİNİ

AI	: Artificial Intelligence (Yapay Zeka)
ANN	: Artificial Neural Network (Yapay Sinir Ağı)
ARIMA	: Autoregressive Integrated Moving Average (Bütünleşik Otoregresif Hareketli Ortalama)
ARMA	: Autoregressive Moving Average (Otoregresif Hareketli Ortalama)
BDTİM	: Bölgesel Deprem ve Tsunami İzleme ve Değerlendirme Merkezi
BN	: Batch Normalization (Yığın Normalizasyonu)
BPTT	: Backpropagation Through Time (Zamanla Geriye Yayılım)
CMEMS	: Copernicus Dünya Gözlem Programı
CNN	: Evrişimli Sinir Ağları
CSV	: Comma Separated Values (Virgülle Ayrılmış Değerler – Windows'ta Dosya Formatı)
CVAE	: Koşullu Varyasyonel Oto-Kodlayıcılar
DL	: Deep-Learning (Derin Öğrenme)
DNN	: Deep Neural Network (Derin Sinir Ağları)
DVM	: Destek Vektör Makineleri
DVR	: Destek Vektör Regresyonu
EKK	: En Küçük Kareler
EKKR	: En Küçük Kareler Regresyonu
ELM	: Extreme Learning Machine (Ekstrem Öğrenme Makineleri)
ESM	: Exponential Smoothing Method (Üstel Düzeltme Yöntemi)
FEWS	: Flood Early Warning System (Taşkın Erken Uyarı Sistemi)
FTP	: File Transfer Protocol (Dosya Aktarım Protokolü)
GFCS	: Global Framework for Climate Services (Küresel İklim Hizmetleri Çerçevesi)
GNSS	: Global Navigation Satellite System (Küresel Navigasyon Uydu Sistemleri)
GPU	: Graphics Processing Unit (Grafik İşlem Birimi)
GRNN	: General Regression Neural Network (Genel Regresyon Sinir Ağı)
GUI	: Graphical User Interface (Görsel Kullanıcı Arayüzü)
HPO	: Hiperparametre Optimizasyonu
ICG	: Intergovernmental Coordination Group (Hükümetlerarası Koordinasyon Grubu)
JMA	: Japan Meteorological Agency (Japonya Meteoroloji Ajansı)
KOH	: Karesel Ortalama Hata
KRDAE	: Kandilli Rasathanesi Deprem Araştırma Enstitüsü

LR	: Learning Rate (Öğrenme Oranı)
LSTM	: Long-Short Term Memory (Uzun Kısa Süreli Bellek)
MAE	: Mean Absolute Error (Mutlak Hatalar Ortalaması)
MAM	: Marmara Araştırma Merkezi
MHEWS	: Multi-Hazard Early Warning Systems (Çoklu Tehlike Erken Uyarı Sistemleri)
MHO	: Mutlak Hatalar Ortalaması
ML	: Machine Learning (Makine Öğrenimi)
MLP	: Multi-Layer Perceptron (Çok Katmanlı Algılayıcı)
MSE	: Mean Squared Error (Ortalama Karesel Hata)
NEMO	: Nucleus for European Modelling of the Ocean (Avrupa Okyanus Modellemesi Çekirdeği)
NLP	: Natural Language Processing (Doğal Dil İşleme)
NN	: Neural Network (Sinir Ağı)
NOAA	: National Oceanic and Atmospheric Administration (Amerikan Ulusal Okyanus ve Atmosfer Dairesi)
NOAH	: Nationwide Operational Assessment of Hazards (Ulusal Ölçekli Tehlike Operasyonel Değerlendirme Programı)
NWLON	: National Water Level Observation Network (Ulusal Su Seviyesi Gözlem Ağı)
OKH	: Ortalama Karesel Hata
PAGASA	: Filipinler Atmosferik, Jeofizik ve Astronomik Hizmetler İdaresi
PCA	: Principal Component Analysis (Temel Bileşen Analizi)
r	: Pearson Korelasyon Katsayısı
RMSE	: Root Mean Squared Error (Karesel Ortalama Hata)
RNN	: Recurrent Neural Network (Tekrarlayan Sinir Ağı)
ROR	: Rastgele Orman Regresyonu
RTF	: Radyal Temel Fonksiyon
RVM	: Regresyon Vektör Makineleri
SGD	: Stochastic Gradient Descent (Stokastik Gradyan İnişi)
SLA	: Sea Level Anomaly (Deniz Seviyesi Anomalisi)
SNR	: Signal-to-Noise Ratio (Sinyal-Gürültü Oranı)
SVR	: Support Vector Machine (Destek Vektör Makineleri)
TIFF	: Tagged Image File Format (Etiketli Görüntü Dosyası Biçimi)
TPU	: Tensor Processing Unit (Tensör İşleme Birimi)
TUDES	: Türkiye Ulusal Deniz Seviyesi İzleme Sistemi
UNDRR	: United Nations Office for Disaster Risk Reduction (Birleşmiş Milletler Afet Riskini Azaltma Ofisi)


UNISDR	: United Nations International Strategy for Disaster Reduction (Birleşmiş Milletler Afet Risklerinin Azaltılması Uluslararası Stratejisi)
VAE	: Variational Autoencoder (Varyasyonel Otokodlayıcı)
WMO	: World Meteorological Organization (Dünya Meteoroloji Örgütü)
YSA	: Yapay Sinir Ağı
ÇDR	: Çoklu Doğrusal Regresyon



1. GENEL BİLGİLER

1.1. Giriş

Jeodezi bilimi, Yer'in geometrisini, yerçekimi alanını ve bunların zaman içindeki değişimlerini inceleyerek gezegenimizin fiziksel özelliklerini anlamamıza olanak tanımaktadır. Jeodezik çalışmalar için referans alınan jeoid, durgun deniz yüzeylerine en yakın, karaların altından devam ettiği varsayılan, yerçekimi alanının eş potansiyel yüzeyi olarak tanımlanır (Vanicek, 1993) (Şekil 1).



Şekil 1. EGM 2008 Jeoidi (Bezdök & Sebera, 2013; Pavlis, Holmes, Kenyon, & Factor, 2012)

Ancak yapılan araştırmalar deniz seviyesinin genellikle düşünüldüğü gibi sabit bir eş potansiyelli yüzey olmadığını ortaya koymuştur (Hannah, 1989). Bu durum temelde 2 ana probleme yol açmaktadır. Birincisi, jeodezik referans sistemlerinin temel bir bileşeni olarak deniz seviyesinin düşey kontrol ağlarının referans yüzeyi olarak kullanılması sebebiyle, deniz seviyesindeki uzun vadeli değişimler referans yüzeyinin değişmesine neden olur. Bu değişimler, jeodezik referans sistemlerinin güncellenmesini ve jeodezik ölçüm tekniklerinin sürekli olarak iyileştirilmesini gerektirir (Siegismund, Köhl, Rummel, & Stammer, 2020).

İkincisi, deniz seviyesi uzun vadeli olarak değıştikçe, jeoidin řekli değışmekte, bu da yer çekimi alanı modellemelerini ve yeryüzü ölçümlerini etkilemektedir (Amin, Sjöberg, & Bagherbandi, 2019). Uzun vadeli deniz seviyesi değışimleri, jeodezik veri tabanlarının güncellenmesini gerektirmekte ve bu da büyük ölçüde dinamik bir jeoid modeli oluşturulmasını zorunlu kılmaktadır.

Deniz seviyesinin değışimi, atmosferik basınç değışiklikleri, okyanus akıntıları, yer çekimi değışiklikleri ve elbette iklim değışikliği gibi sebepler bağı olarak oluşmaktadır (Cazenave & Nerem, 2004). Özellikle, küresel ısınma sonucu kutuplardaki buzulların erimesi ve deniz sularının termal genişmesi, deniz seviyesinde uzun dönemli yükselmelere neden olmaktadır. Deniz suyunun sıcaklığı arttıkça, suyun hacmi genişler; bu termal genişme, deniz seviyesinde yükselmelere neden olur. Ayrıca küresel ısınma kutuplardaki buzulların ve Grönland ile Antarktika'daki buz tabakalarının erimesini hızlandırır. Bu erime, okyanuslara ek su akışı sağlar ve deniz seviyelerinin daha da yükselmesine yol açar. İşte bu iki süreç, son birkaç on yılda deniz seviyesinde gözlemlenen uzun vadeli yükselmelerin ana nedenleri arasında gösterilmektedir (Cazenave & Nerem, 2004).

İklim değışikliği kaynaklı deniz seviyesi değışiklikleri, jeodezik çalışmalar için birtakım zorluklar ve bununla birlikte araştırma fırsatları da sunmaktadır. Deniz seviyesi değışimlerini modellemek, jeodezik referans yüzeyi olan jeoidin daha dinamik ve güncel bir hale getirilmesine yardımcı olur. Bu sayede, yerçekimi alanı modellemeleri ve yeryüzü ölçümleri daha yüksek hassasiyetle yapılabilir. Deniz seviyesi değışimlerinin jeodezik modellere entegre edilmesi ve deniz seviyesi değışimlerine yönelik jeodezik çalışmaların devamı, daha doğru ve dinamik jeoid modellerinin geliştirilmesine olanak tanıyacaktır. Bu sayede hem bugünün hem de yarının jeodezik ihtiyaçlarına hizmet edecek modeller ve referans yüzeyleri elde edilebilecek, ayrıca kıyı bölgelerinin korunmasına ve iklim değışikliğiyle mücadelenin etkin bir şekilde yönetilmesine de önemli katkılar sağlanabilecektir.

Özellikle uydu teknolojilerinin gelişimi, uzaktan algılama teknolojileri ve gelişmiş yapay zeka modelleme teknikleri gibi yenilikler, deniz seviyesi modellerinin doğruluğunu önemli ölçüde artırmaktadır. Teknolojik ilerlemeler sayesinde, deniz seviyesinin daha doğru bir şekilde modellenmesi ve iklim değışikliği bağlamında jeodezik çalışmaların daha da önem kazanması beklenmektedir. Daha hassas deniz seviyesi modelleri, jeodezik araştırmalar için daha kapsamlı ve doğru bilgiler sağlayarak hem bugünkü hem de gelecekteki jeodezik ihtiyaçların karşılanmasında kritik bir rol oynayacaktır. Bu sayede, jeodezi bilimi, iklim

değişikliğiyle ilgili zorluklara daha etkin şekilde yanıt verebilmek ve sürdürülebilir bir gelecek için güçlü stratejiler geliştirebilmek adına sağlam bir temel oluşturabilir.

1.2. Problemin Tanımı ve Motivasyon

Deniz seviyesi değişimleri yer çekimi alanı modellemelerini ve yeryüzü ölçümlerini doğrudan etkilemekte, böylece jeodezik veri tabanlarının sürekli güncellenmesi gerektirmektedir. Özellikle iklim değişikliği kaynaklı deniz seviyesi yükselmeleri, bu süreçleri daha da karmaşık hale getirmekte ve jeodezik çalışmalar için yeni zorluklara neden olmaktadır. Bu durum, deniz seviyesi değişimlerinin hassas modellemesini ve jeodezik referans yüzeylerinin dinamik olarak güncellenmesini zorunlu kılmaktadır. Bu nedenle, deniz seviyesi modellerinin jeodezik modellere entegrasyonu daha doğru ve dinamik jeoid modellerinin geliştirilmesine olanak tanıyacaktır. Ayrıca iklim değişikliği nedeniyle deniz seviyesi yükselmesi, özellikle gelişmekte olan ülkelerde on milyonlarca insanın yerinden edilmesine ve ciddi ekonomik ve ekolojik zararlara neden olabilir (Dasgupta, 2009).

Bu bağlamda Türkiye gibi üç tarafı denizlerle çevrili bir ülkede deniz seviyesindeki değişimlerin hassas modellenmesi ve tahmini jeodezik, ekonomik, ekolojik ve hayati tehlikelerin önlenmesi bakımından önem taşımaktadır. Türkiye'nin kıyı bölgelerinde deniz seviyesi yükselmesi ve iklim değişikliğinin etkilerini anlamak ve buna uyum sağlamak için bölgesel ölçekte modelleme, tahmin ve erken uyarı sistemlerine ihtiyaç olduğu açıktır. Ancak, bilimsel literatür incelendiğinde Türkiye'de deniz seviyesindeki değişimlerin modellenmesi ve tahmini konusunda yapılan bir çalışmaya henüz rastlanmamıştır.

Ayrıca, uluslararası literatürde deniz seviyesi tahmini ve modellenmesi için yapılan çalışmaların ve kullanılan yöntemlerin çeşitli sınırlılıkları ve eksiklikleri de bulunmaktadır. (1) Deniz seviyesi tahmini için kullanılan doğrusal ve tek değişkenli yöntemler, karmaşık bağımlılık yapısına sahip olan deniz seviyesi modellemesinde yeterli parametre kapasitesine sahip olmadıkları için düşük tahmin doğrulukları sunmaktadır. (2) Deniz seviyesi tahmininde kullanılan gelişmiş makine öğrenimi ve derin öğrenme yöntemleri ise, genellikle manuel hiperparametre arama tekniklerine dayandığından, optimal hiperparametre setlerine ulaşmakta yetersiz kalmakta ve bu durum tahmin doğruluğunu olumsuz etkilemektedir. (3) Deniz seviyesi tahmini için yeni derin öğrenme tabanlı mimarilerin (örneğin ConvLSTM, oto-kodlayıcı yapılar) potansiyeli yeterince araştırılmamış, literatürde bu yönde sınırlı sayıda çalışma yapılmıştır. (4) Diğer taraftan geliştirilen deniz seviyesi modelleri akademik

literatürde yer almasına rağmen bu modeller, karar alıcıların, ilgili kurum ve kuruluşların ve araştırmacıların kullanabileceği pratik bir ürüne (Örn. Erken uyarı sistemleri, yazılımlar vs.) dönüştürülmemiştir.

Bu eksiklikler, farklı veri kaynaklarına uyum sağlayabilen, kompleks bağımlılıkları modelleyebilen ve daha yüksek doğruluk sunan yeni mimarilere duyulan ihtiyacı açıkça göstermektedir.

Bu tez çalışmasının motivasyonu, yalnızca mevcut literatürdeki boşlukların giderilmesi değil, aynı zamanda deniz seviyesi modelleme alanına yeni mimariler kazandırarak pratik uygulamalara dönüştürülebilecek çözümler geliştirmektir. Bu kapsamda literatürde kullanılan mevcut makine öğrenimi ve derin öğrenme yöntemlerinin yanı sıra, farklı alanlarda başarıyla uygulanmış ancak deniz seviyesi tahminine uyarlanmamış mimariler de değerlendirilmiştir. Ayrıca manuel hiperparametre arama yöntemlerinin yetersizliğini aşmak amacıyla, Bayesyen optimizasyona dayalı otomatik hiperparametre optimizasyonu bu çalışmada ilk kez deniz seviyesi tahmini için uygulanmıştır.

Bunlara ek olarak, geliştirilen modeller kullanılarak açık kaynak kodlu bir deniz seviyesi erken uyarı sistemi tasarlanmış ve böylece yalnızca akademik literatüre değil, aynı zamanda karar vericiler, kamu kurumları ve araştırmacılar için pratik bir ürün ortaya konulmuştur.

Tez çalışması kapsamında yapılan uygulamalar Türkiye ve çevre ülkeler için ekolojik, ekonomik ve sosyal yapılar üzerinde büyük etkilere sahip ve stratejik bir bölge olarak öne çıkan Karadeniz Bölgesi için gerçekleştirilmiştir. Tez çalışması kapsamında Karadeniz'in seçilmesinin temel nedenleri;

1. Karadeniz'in benzersiz iklim özellikleri, biyoçeşitliliği ve kıyısız alanlarındaki yoğun insan etkinlikleri nedeniyle, iklim değişikliğinin neden olduğu deniz seviyesi yükselmesinden kaynaklanan doğal afet risklerin yüksek olmasıdır.
2. Karadeniz özellikle kıyı erozyonu, sel ve altyapı üzerindeki etkileri açısından iklim değişikliğine karşı hassasiyeti yüksek bir bölge olmasıdır.

Bu nedenle, Karadeniz'deki deniz seviyesi değişimlerinin kapsamlı ve hassas modellenmesi, bölgenin iklim değişikliğine adaptasyon süreçlerini anlamak, ekonomik, ekolojik ve hayati tehlikelerin önlenmesi için önemli bir adım ve motivasyon unsurudur.

Sonuç olarak, bu tez çalışması; (i) Türkiye'de deniz seviyesi değişimlerinin modellenmesi ve tahmini üzerine yapılan ilk kapsamlı çalışma olmasıyla ulusal literatüre katkı sunmakta, (ii) uluslararası literatürde mevcut yöntemlerin sınırlılıklarını aşacak yeni

mimari ve optimizasyon yaklaşımları önermekte, (iii) Karadeniz özelinde kıyı risklerinin azaltılmasına yönelik pratik ürünler geliştirmektedir.

1.3. Literatür Taraması ve Teorik Çerçeve

Literatürde deniz seviyesi ile ilgili yapılan çalışmalar, küresel (global) ölçekte yapılan çalışmalar ve bölgesel ölçekte yapılan çalışmalar olmak üzere iki farklı kısımda gerçekleştirilmektedir. Deniz seviyesi çalışmalarının küresel ve bölgesel çalışmalar olarak iki farklı ölçekte yapılması, okyanus ve iç deniz dinamiklerinin birbirlerinden oldukça farklı olması sebebiyledir. Bu iç dinamikler çökme, okyanus akıntıları, arazi yüksekliğindeki değişiklikler, tuzluluk oranı ve bölgesel meteorolojik farklılıklar olarak sayılabilir (Cazenave, ve diğerleri, 2018). Küresel ölçekte yapılan çalışmalarda genellikle geleceğe yönelik yapılan tahminler birtakım kısıtlamalar (jeodezik, jeofiziksel, oşinografik kısıtlamalar) yüzünden yüksek doğruluğa sahip değildir. Ancak deniz seviyesindeki artışların yol açacağı küresel problemleri ve deniz seviyesi değişimindeki trendleri göstermek ve küresel önlemler sunmak için yeterli olmaktadır (Chen, ve diğerleri, 2017). Buna karşın bölgesel ölçekte yapılan çalışmalar daha sınırlı alanlarda yapılmaktadır. Bölgesel çalışmalarda denizlerin sahip olduğu iç dinamikler küresel çalışmalara kıyasla çok daha homojendir. Bu sebeple bölgesel çalışmalarda deniz seviyelerini tahmin etmek için oluşturulan tahmin modelleri küresel modellere kıyasla çok daha yüksek doğruluklar sunabilmektedir. Literatürde deniz seviyesi tahmini için kullanılan yöntemler tek değişkenli ve doğrusal tahminler yapan geleneksel yöntemler ve doğrusal olmayan karmaşık bağımlılık yapıları tahmini için makine öğrenimi yöntemleri olmak üzere iki farklı grupta incelenebilir.

Tek Değişkenli Doğrusal Tahmin Yapan Yöntemler;

- Üstel Düzeltme Yöntemi (Exponential Smoothing Method - ESM),
- Otoresif Hareketli Ortalama (Autoregressive Moving Average - ARMA),
- Bütünleşik Otoresif Hareketli Ortalama (Autoregressive Integrated Moving Average - ARIMA)
- Sönümlü-Kalıcılık (Damped-Persistence) gibi yöntemleridir (Srivastava, ve diğerleri, 2016).

Bu geleneksel tek değişkenli yöntemler, minimum hacimde veri seti ile kullanıma uygundur ve çok değişkenli bilgilerden yararlanamaz (Hewamalage, Bergmeir, & Bandara,

2021). Bu durum, diğer karmaşık makine öğrenme yöntemlerine kıyasla bu tekniklerde daha az sayıda parametrenin kullanıldığı anlamına gelir. Bu nedenle bu yöntemler, değerli bilgiler elde etme ve yüksek kaliteli tahmin sunma konusunda yetersiz kalmaktadır (Luaran, 2020). Genel olarak, bu yöntemler, diğer sinir ağları ve makine öğrenimi yöntemleri için bir kıyaslama yöntemi olarak kapsamlı bir şekilde kullanılmaktadır (Bandara, 2020). Geleneksel yöntemler ile deniz seviyesi tahmini için yapılan birçok çalışma mevcuttur (Vaziri, 1997; Srivastava, ve diğerleri, 2016; Fernandez, Po Iii, Montero, & Addawe, 2017; Tulus, Adytia, Subasita, & Tarwidi, 2020; Chi, 2020; Balogun & Adebisi, 2021).

Geleneksel yöntemlerden farklı olarak deniz seviyesi tahmini için kullanılan diğer yöntemler ise Yapay Sinir Ağları (Artificial Neural Network - ANN), Derin Öğrenme yöntemleri (Deep Learning- DL) ve diğer Makine Öğrenimi yöntemleridir (Machine Learning – ML). Özellikle geleneksel yöntemler ile yüksek doğrulukta tahmin edilemeyen doğrusal olmayan karmaşık bağımlılık yapılarındaki zaman serilerinin tahmininde makine öğrenimi yöntemleri büyük başarılar sağlamıştır. Bunun temel nedeni olarak makine öğrenimi yöntemlerinin bağımlı ve bağımsız değişkenler arasındaki doğrusal olmayan ilişkilerden doğrudan bilgi çıkarabilmesi gösterilebilir (Luaran, 2020). Doğrusal olmayan deniz seviyesi zaman serilerinde makine öğrenimi yöntemlerinin geleneksel yöntemlere göre çok daha yüksek doğrulukta tahmin sonuçları verdiği de birçok çalışmada gösterilmiştir (Vaziri, 1997; Imani, Kao, Lan, & Kuo, 2018; Balogun & Adebisi, 2021; Imani, You, & Kuo, 2014; Imani, You, & Kuo, 2013). Bu sebeplerle deniz seviyesi tahmin modelleri için makine öğrenimi yöntemleri giderek daha popüler hale gelmektedir. Bölgesel ölçekte makine öğrenimi yöntemleri ile yapılan çalışmalar incelendiğinde;

Yang (2020) tarafından yapılan çalışmada Çin Denizi kıyılarındaki 17 mareograf istasyonundan elde edilen deniz seviyesi verileri kullanılarak bir tahmin modeli Uzun Kısa Süreli Bellek ağı (Long-Short Term Memory-LSTM) ile geliştirilmiştir. Geliştirilen tahmin modeli sayesinde Tayvan kıyılarındaki deniz seviyeleri yaklaşık ± 5 cm karesel ortalama hata (KOH) ile tahmin edilmiştir.

Riazi (2020) tarafından yapılan çalışmada ise Avusturalya'nın Queensland Eyaletinde bulunan 6 farklı mareograf istasyonundan elde edilen deniz seviyesi verileri kullanılarak İleri Beslemeli tek katmanlı bir derin öğrenme ağı ile Queensland kıyısındaki deniz seviyesi değişimleri ± 4.8 ila ± 6.3 cm KOH ile tahmin edilmiştir.

Ishida (2020) tarafından yapılan çalışmada ise, Japon Denizi'nde bulunan mareograf istasyonundan elde edilen deniz seviyesi kullanılarak bir Uzun Kısa Süreli Bellek ağı ile

tahmin modeli geliştirilmiştir. Bu çalışmada derin öğrenme ağı girdi olarak sadece deniz seviyesi değerlerinden farklı olarak bazı meteorolojik parametreleri de kullanmıştır. Çalışma sonucunda Japon Denizi'nde deniz seviyesi değerleri ± 10 cm KOH ile tahmin edilmiştir.

Žust (2021) tarafından yapılan çalışmada Akdeniz'in bir kolu olan Adriyatik Denizi'nde deniz seviyesi değişimlerini tahmin etmek için topluluk-derin öğrenme yöntemine (Ensemble Deep Neural Network) dayanan yeni bir yöntem sunmuştur. Koper mareograf istasyonundan elde edilen deniz seviyesi verileri, rüzgar hızı ve hava basıncı verileri kullanarak Adriyatik Denizi'nde deniz seviyelerini ± 6.4 cm KOH ile tahmin edecek bir model geliştirmiştir.

Adebisi & Balogun (2021) tarafından yapılan çalışmada Malezya kıyılarındaki 21 farklı mareograf istasyonundan elde edilen deniz seviyesi verileri kullanılarak bir Uzun Kısa Süreli Bellek ağı ile deniz seviyesi tahmin modeli geliştirilmiştir. Bu tahmin modeli ile Malezya kıyılarındaki deniz seviyeleri yaklaşık $\pm 6.7 - \pm 8$ cm KOH ile tahmin edilmektedir.

Winona (2020) tarafından yapılan çalışmada Endonezya Bali kıyılarındaki deniz seviyesini tahmin etmek için Bali mareograf istasyonundan elde edilen deniz seviyesi değişimleri kullanılarak bir Uzun Kısa Süreli Bellek ağı ile deniz seviyesi tahmin modeli geliştirilmiştir. Bu model ile Bali kıyılarındaki deniz seviyesi değişimleri ± 2 cm KOH ile belirlenmiştir.

Accarino (2021) tarafından yapılan çalışmada ise yine bir Uzun Kısa Süreli Bellek ağı kullanılarak geliştirilen tahmin modeli ile Akdeniz içindeki İyonya Denizi ve Adriyatik Denizi'ndeki deniz seviyesi $\pm 1-2$ cm KOH ile belirlenmiştir. Literatürde bu bölüm içerisinde bahsedilmeyen başka bölgelerde yapılan birçok farklı çalışma da mevcuttur. Bu çalışmalar genel olarak deniz seviyelerini yüksek doğrulukta tahmin etmek için derin öğrenme yöntemlerini ve yapay sinir ağlarını kullanmaktadırlar. Söz konusu çalışmalarda birçok farklı ağ mimarileri ve farklı hiper-parametreler kullanılmaktadır.

Karadeniz özelinde ise, deniz seviyeleri ile ilgili yapılan birçok çalışma mevcuttur (Avsar, Jin, Kutoglu, & Gurbuz, 2016; Balabanov, 2007; Cazenave, Bonnefond, Mercier, Dominh, & Toumazou, 2002; Demirbağ, Gökaşan, Oktay, Şimşek, & Yüce, 1999; Korotaev, Ratner, Ivanchik, Kholod, & Ivanchik, 2016; Lericolais, Bulois, Gillet, & Guichard, 2009; Stanev & Peneva, 2001; Tsimplis, Josey, Rixen, & Stanev, 2004; Zalesny, ve diğerleri, 2012). Bu çalışmalar genellikle geçmişten günümüze elde edilen deniz seviyesi verilerinin çeşitli analizlerle incelenmesi ve istatistiksel sonuçlarının tartışılması ile mevcut durumun ortaya çıkarılması üzerinedir. Bir diğer sıklıkla çalışılan konu ise deniz seviyesi trendlerinin

belirlenmesi ile ilgilidir. Karadeniz'deki deniz seviyesi ile ilgili bazı hidrolojik parametrelerin modellenmesi üzerine olan çalışmalar da mevcuttur (Demyshev, 2012; Kordzadze & Demetrashvili, 2012; Kordzadze & Demetrashvili, 2011; Korotaev, Ratner, Ivanchik, Kholod, & Ivanchik, 2016; Kortcheva, Dimitrova, & Galabov, 2012; Kubryakov, ve diğerleri, 2012; Nacar, Bayram, Baki, Kankal, & Aras, 2020; Vandenbulcke & Barth, 2015; Zaitsev & Pelinovsky, 2011). Bu çalışmalarda genellikle hidrodinamik parametreler ve dalga boyları modellenmektedir.

Yavuzdoğan & Tanır Kayıkçı (2021) tarafından yapılan bir çalışmada ise ilk defa Karadeniz'deki deniz seviyesini modelleyen bir kapula temelli tahmin modeli geliştirilmiştir. Bu çalışma Karadeniz'de deniz seviyelerini modelleyen ilk çalışma olmasının yanında, kapula fonksiyonlarına dayanan yeni bir tahmin modeli yaklaşımını ilk kez literatüre kazandırmıştır. Çalışmada uydu temelli radar altimetre verileri kullanılarak deniz seviyesi ortalama ± 2.2 mm KOH ile tahmin edilmiştir.

Ayrıca bu tez çalışmasının bir çıktısı olarak yayınlanan Yavuzdoğan ve Tanır Kayıkçı (2024) çalışmasında ilk defa Karadeniz'de derin öğrenme temelli deniz seviyesi tahmin modelleri geliştirilmiş ve deniz seviyesi tahminleri yapılmıştır. Bu çalışmada Karadeniz'de deniz seviyesi anomalilerini tahmin etmek için 3 farklı mimari kullanılmış olup; ilk defa LSTM oto-kodlayıcı temelli yeni bir mimari deniz seviyesi tahmin çalışmalarında kullanılmıştır (Yavuzdoğan & Tanır Kayıkçı, 2024). Çalışma, bu yöntemin etkili bir deniz seviyesi tahmin aracı olabileceğini gösterilmiş ve böylece literatüre yeni bir deniz seviyesi tahmin mimarisi kazandırılmıştır. Bu çalışmalar dışında Karadeniz'de deniz seviyesi değişimlerini modelleme ve tahmin üzerine başka bir çalışma bulunmamaktadır. Literatürde deniz seviyesi tahmini ile ilgili yapılan çalışmalar, kullanılan yöntemler ve KOH metriği cinsinden tahmin performanslarını gösteren bir tablo aşağıda sunulmuştur (Tablo 1).

Tablo 1. Deniz seviyesi tahmini üzerine yapılan çalışmalar ve kullanılan yöntemler

Yapılan Çalışma	Yöntem	KOH (mm)	Hiperparametre Optimizasyon Yöntemi
(Makarynsky, Makarynska, Kuhn, & Featherstone, 2004)	ANN	151	Manuel
(Niedzielski & Kosek, 2009)	LS	35	-
	LS+AR	26	
(Imani, You, & Kuo, 2013)	HWES	70	Manuel
	ANN	60	
(Imani, You, & Kuo, 2014)	PCA+ARIMA	51	-
(Imani, You, & Kuo, 2014)	MLP	54	Manuel
	RBF	42	
	GRNN	59	
	ARMA	119	
(Imani, You, & Kuo, 2014)	SVR	35	Manuel
(Imani, Kao, Lan, & Kuo, 2018)	ELM	35	Manuel
	RBF	36	
	RVM	34	
	SVM	35	
(Fu, Zhou, Sun, & Tang, 2019)	EMD+SSA+LS	13	-
(Zhao, Cai, & Fan, 2019)	MLFF	18	Manuel
	RBF	16	
	GRNN	16	
	ARMA	28	
(Ishida, 2020)	LSTM	102	Manuel
(Riazi, 2020)	FFNN	48	-
(Yang, 2020)	LSTM	50	Manuel
(Winona, 2020)	LSTM	20	Manuel
(Yavuzdoğan & Tanır Kayıkçı, 2021)	CP Model	22	-
(Adebisi & Balogun, 2021)	LSTM	67	Manuel
(Accarino, 2021)	LSTM	11	Manuel
(Žust, 2021)	LSTM	64	Manuel
(Yavuzdoğan & Tanır Kayıkçı, 2024)	LSTM	5,2	Otomatik
	LSTM-AE	4,6	
	DP	11	

1.4. Tezin Amacı ve Kapsamı

Bu tez çalışmasının temel amacı, Karadeniz'deki deniz seviyesi değişimlerini yüksek doğrulukla modellemek, tahmin etmek ve deniz seviyesi tahminine dayalı bir erken uyarı

sistemi tasarlamaktır. Bu doğrultuda, literatürde deniz seviyesi modellemesi için yaygın olarak kullanılan derin öğrenme mimarileri (Yığılmış LSTM) ve istatistiksel yöntemler (Sönümlü Kalıcılık) uygulanmakta; ayrıca farklı alanlarda kullanılan derin öğrenme mimarilerinin deniz seviyesi tahmini için yeniden tasarlanması (katman sayıları, aktivasyon fonksiyonları ve hiperparametreler gibi yapısal unsurların değiştirilmesi) yoluyla yeni modeller geliştirilmekte ve böylece deniz seviyesi tahmini ve modellemesi literatürüne özgün katkılar sunulması hedeflenmektedir. Ayrıca bu tez çalışması, performans karşılaştırmaları, genelleştirme analizleri ve pratik uygulamaya dönük bir erken uyarı sistemi ile kullanıcı dostu bir modelleme yazılımının geliştirilmesini de kapsamaktadır. Bu amaca ulaşmak için belirlenen spesifik hedefler şunlardır:

Hedef 1: Literatürde deniz seviyesi modelleme için kullanılan mevcut derin öğrenme mimarilerini (Yığılmış LSTM) ve İstatistiksel Yöntemleri (Sönümlü Kalıcılık) Karadeniz veri setleri üzerinde uygulayarak ilk defa Karadeniz’e özgü deniz seviyesi tahmin modelleri geliştirmek ve yaklaşık 3–6 yıllık kısa dönem tahminlerde en fazla $KOH \leq \pm 5$ cm ve $R^2 \geq 0.90$ performans düzeyini hedeflemek.

Hedef 2: Literatürde başka uygulamalarda kullanılmış (video kare tahmini, yağış tahmini, anomali modellemesi gibi) ancak deniz seviyesi modellemesinde hiç kullanılmamış olan derin öğrenme mimarilerinin (ConvLSTM ve LSTM Oto-Kodlayıcı) yeniden tasarlanması (katman sayıları, aktivasyon fonksiyonları ve hiperparametreler gibi yapısal unsurların değiştirilmesi) ile özgün derin öğrenme tabanlı deniz seviyesi tahmin modelleri geliştirmek.

Hedef 3: Karadeniz’de hassas deniz seviyesi tahmini için en uygun model hiperparametrelerini daha önce deniz seviyesi tahmin modellerinde kullanılmayan Bayesyen Hiperparametre Optimizasyonu ile belirlemek.

Hedef 4: Tez çalışması kapsamında geliştirilen tahmin modellerinin farklı veri setlerine uyum kabiliyetini (genelleştirilebilirliğini) araştırmak.

Hedef 5: Tez çalışması kapsamında geliştirilen derin öğrenme modelleriyle açık kaynak kodlu, kullanıcı dostu bir deniz seviyesi erken uyarı sistemi tasarlamak; uluslararası veri merkezlerinden güncel verileri çekerek en az 10 günlük ileriye dönük tahminleri yüksek doğrulukla ($\approx \pm 5$ cm KOH) üretmek.

Hedef 6: Tez kapsamında elde edilen bilgi birikimini bir ürüne dönüştürmek amacıyla, tekrarlayan sinir ağı (RNN) tabanlı yöntemleri kullanan çevresel modelleme yazılımı geliştirmek; kullanıcıların kod bilgisine ihtiyaç duymaksızın veri ön işleme, model

eğitimi/testi, tahmin üretimi, performans analizi ve görselleştirme adımlarını uçtan uca gerçekleştirebilmelerini sağlamak.

Bu hedefler çerçevesinde tezde gerçekleştirilen çalışmalar ana hatlarıyla aşağıdaki gibi sıralanabilir;

- Hassas Deniz Seviyesi Tahmini için Yeni Derin Öğrenme Mimarilerinin Geliştirilmesi (Hedef 2 ve Hedef 3)

Bu amaçla tez çalışmasında, Karadeniz'deki deniz seviyesi değişimlerini modellemek amacıyla literatürde deniz seviyesi tahmini ve modellemesinde daha önce kullanılmayan derin öğrenme mimarileri Oto Kodlayıcı LSTM (Auto-Encoder LSTM) ve Evrişimli Uzun Kısa Süreli Bellek (ConvLSTM) olmak üzere iki farklı derin öğrenme mimarisinin etkinliğini ve kullanılabilirliğini araştırmak hedeflenmiştir. Geliştirilen bu modellerin tahmin performansı farklı metriklerle (Karesel Ortalama Hata - (KOH) ve Pearson Korelasyon Katsayısı - r) araştırılarak, deniz seviyesi tahmini için kullanılabilirliği ve uygunluğu incelenmiştir. Geliştirilen bu yeni model mimarilerinden Oto Kodlayıcı LSTM model mimarisi sadece zamansal bağımlılıkları modelleyen bir mimari olmasına rağmen zaman serisi verilerindeki örüntüleri ve ilişkileri öğrenmek için bir giriş dizisini sıkıştırma (kodlama) ve daha sonra bu sıkıştırılmış bilgiyi kullanarak diziyi yeniden oluşturma (kod çözme) işlemlerini gerçekleştiren bir derin öğrenme modelidir. Bu mimari, özellikle gürültülü verilerden önemli özellikleri çıkararak veri setlerindeki karmaşık zaman serisi dinamiklerini modellemek için kullanılmaktadır. Geliştirilen bir diğer yeni model mimarisi olan ConvLSTM mimarisi hem zamansal hem de konumsal ilişkileri işleyebilen, özellikle video ve hava durumu tahmini gibi konumsal özelliklerin önemli olduğu zaman serisi verileri için geliştirilmiş bir derin öğrenme mimarisidir. ConvLSTM, Uzun Kısa Süreli Bellek ağlarının hafıza özelliklerini korurken, evrişim katmanları aracılığıyla konumsal bilgileri de etkin bir şekilde işleyebilir.

- Karadeniz için En Uygun Derin Öğrenme Mimarisinin Belirlenmesi (Hedef 1, Hedef 2 ve Hedef 3)

Bu bölümde geliştirilen yeni mimarilerin (ConvLSTM ve LSTM Oto Kodlayıcı) tahmin performansları literatürde son zamanlarda deniz seviyesi tahmininde en çok kullanılan derin öğrenme model mimarisi olan Yığılmış (Stacked) LSTM ve Sönümlü Kalıcılık İstatistiksel Modeli ile karşılaştırılmıştır (Tablo 1). Yığılmış LSTM, birden fazla LSTM katmanının üst üste yığıldığı bir derin öğrenme modelidir. Bu yapı, modelin zaman serisi verileri üzerinde daha karmaşık özellikleri ve desenleri öğrenmesine olanak tanır.

Yığılmış LSTM'ler, özellikle sıralı veri işleme, zaman serisi tahmini, dil modellemesi ve metin üretimi gibi alanlarda sıklıkla kullanılmaktadır. Özellikle son zamanlarda deniz seviyesi değişimleri gibi karmaşık bağımlılıkların olduğu zaman serilerinde de sıklıkla kullanılan etkin bir yöntem halini almıştır. Öyle ki son yapılan çalışmalarda geleneksel makine öğrenimi temelli modellere (Örn. Destek vektör regresyonu, rastgele orman regresyonu ve oto-regresif hareketli ortalama gibi) göre daha yüksek doğruluklar elde etmiştir (Tablo 1). Literatür incelendiğinde deniz seviyesi tahmin çalışmalarında en yüksek doğruluklara yığılmış LSTM model mimarileri ile ulaşıldığı görülmüş ve yeni geliştirilen model mimarilerinin tahmin performansı bu sebeple deniz seviyesi tahmininde literatürdeki en güçlü araç olan yığılmış LSTM modeli ile karşılaştırılmıştır (Tablo 1). Böylece Karadeniz için geliştirilen ConvLSTM ve LSTM Oto Kodlayıcı deniz seviyesi tahmin modellerinin etkinliği karşılaştırmalı olarak incelenmiştir. Bu inceleme sonucunda Karadeniz için deniz seviyesi tahmininde en uygun derin öğrenme model mimarisinin belirlenmesi hedeflenmiştir.

- Modellerin Genelleştirme Kabiliyetinin Analizi (Hedef 4)

Bu bölümde, deniz seviyesi tahmininde kullanılan modellerin genelleştirme kabiliyeti kapsamlı bir şekilde incelenmiştir. Genelleştirme kabiliyeti, eğitilmiş modellerin eğitim sırasında karşılaşmadıkları yeni ve önceden görülmemiş veri setleri üzerinde ne kadar iyi tahmin gerçekleştirdiklerinin performansını ölçer. Bu yeteneğe sahip modeller, sadece eğitildikleri veri setlerinde değil, aynı zamanda tamamen farklı ve yeni veri setleri üzerinde de doğru tahminler yapabilir. Yüksek genelleştirme kabiliyetine sahip modeller, pratik uygulamalarda daha esnek ve kullanışlı hale gelir. Tez çalışmasında, bu analiz hem yüksek çözünürlüklü uydu altimetre veri setleri hem de mareograf verileri üzerinde gerçekleştirilmiştir. Yüksek çözünürlüklü uydu altimetre verileri üzerinde yapılan bu analiz, düşük çözünürlüklü veri setleri üzerinde eğitilmiş modellerin, yüksek çözünürlüklü veri setleri üzerindeki performanslarını değerlendirerek, bu modellerin çeşitli konumsal çözünürlüklerdeki verilere adaptasyon yetenekleri test edilmiştir. Mareograf verileri ile yapılan analizle ise, modellerin farklı veri kaynaklarından elde edilen veriler üzerindeki performansını değerlendirilmiştir. Uydu altimetre veri seti üzerinde eğitilmiş modellerin mareograf verileri gibi farklı kaynaklardan elde edilen veriler üzerindeki tahmin doğrulukları incelenmiştir. Bu analizler, modellerin deniz seviyesi tahmininde kullanılabilecek farklı veri kaynaklarına ne kadar iyi uyum sağlayabildiğini ortaya koymaktadır.

- Deniz Seviyesi Erken Uyarı Sistemi Geliştirme (Hedef 5)

Bu bölümde tez çalışması kapsamında geliştirilen ConvLSTM model mimarisi kullanılarak, Karadeniz bölgesi için derin öğrenme tabanlı, özel olarak tasarlanmış bir deniz seviyesi erken uyarı sisteminin geliştirilmesi hedeflenmiştir. Geliştirilmesi hedeflenen bu erken uyarı sistemi ile, yüksek deniz seviyesi anomalileri önceden belirlenerek kıyı taşkınlarının önüne geçilmesi ve risklerin azaltılması amaçlanmaktadır. Aynı zamanda, su yönetimi, kıyı koruma ve bakım stratejileri gibi konularda karar vericilere kritik destek sağlanması hedeflenmiştir. Kullanıcı dostu bir arayüzün geliştirilmesiyle, son kullanıcıların kolay erişimi sağlanmıştır. Bu sistemin, güncel (son bir aylık) deniz seviyelerini uluslararası veri merkezlerinden çekerek, gelecekteki en az 10 günlük deniz seviyesi tahminlerini yüksek doğruluk ile yapabilecek kapasitede olması hedeflenmiştir. Sistemin tahmin doğruluğunu analiz etmek için birçok tahmin simülasyonu farklı tarih aralıklarında gerçekleştirilmiş ve sistemin etkinliği incelenmiştir.

- Çevresel Modelleme Yazılımı Geliştirme (Hedef 6)

Bu tez kapsamında elde edilen bilgi birikimi kullanılarak çevresel parametrelerin modellenmesi ve tahmini için, tekrarlayan sinir ağı (RNN) temelli derin öğrenme yöntemleri (LSTM ve ConvLSTM) kullanan bir modelleme yazılımı da geliştirilmiştir. Bu modelleme yazılımı ile (1) kullanıcılar kodlama bilgisi gerektirmeksizin tekrarlayan sinir ağı temelli yöntemleri kullanarak derin öğrenme modelleri geliştirebilirler. (2) hem zaman serisi hem de zaman bağılı görüntü verileri için çeşitli ön işleme (preprocessing) aşamaları (Örn: Verilerin normalizasyonu, Aykırı ve uyuşumsuz verilerin eliminasyonu, eğitim validasyon ve test veri setlerinin hazırlanması gibi) otomatik olarak gerçekleştirilebilir. (3) ön işleme aşamasının ardından istenilen mimarilere sahip LSTM ve ConvLSTM modelleri oluşturularak eğitilebilir. (4) eğitilmiş modeller test veri setleri üzerinde test edilerek performansları incelenebilir. (5) Eğitilmiş modeller kullanılarak tahminler yapılabilir. (6) Tüm işlem aşamalarına ait çeşitli veri görselleştirme araçları da bu yazılımda sunulur. Tez çalışması kapsamında bu yazılım ile elde edilen bilgi birikimi kullanılarak pratik uygulamalar için erişilebilir araçlar geliştirmek hedeflenmiştir.

1.5. Tezin Araştırma Soruları ve Hipotezler

Bölüm 1.4'te ayrıntılı olarak sunulan amaç ve hedefler doğrultusunda tezin araştırma soruları ve hipotezleri aşağıdaki gibi oluşturulmuştur;

- Araştırma Soruları

- AS₁ Oto-Kodlayıcı LSTM ve ConvLSTM mimarileri, deniz seviyesi tahmininde mevcut literatürde yaygın olarak kullanılan ve en doğru sonuçları veren Yığılmış LSTM yönteminden daha üstün performans gösterebilir mi?
- AS₂ Karadeniz'deki deniz seviyesi değişimlerini tahmin etmek için Oto Kodlayıcı LSTM ve ConvLSTM gibi derin öğrenme mimarileri etkili bir araç olabilir mi?
- AS₃ Karadeniz'de deniz seviyesi değişimlerini modellemek için en uygun derin öğrenme yöntemi ve mimarisi nasıl olmalıdır?
- AS₄ Düşük çözünürlüklü uydu altimetre verisi kullanılarak eğitilen modeller yüksek çözünürlüklü uydu altimetre verisinde de yüksek tahmin doğrulukları verebilir mi?
- AS₅ Uydu altimetre veri seti kullanılarak eğitilen modeller mareograf verilerine de uyum sağlayabilir mi?
- AS₆ Geliştirilen modeller kullanılarak gelecekteki 15 günlük deniz seviyeleri yüksek doğrulukta tahmin edilebilir mi?
- AS₇ Geliştirilen deniz seviyesi erken uyarı sistemi, Karadeniz bölgesindeki kıyı taşkınları riskini azaltmada etkili bir araç olabilir mi?

- Hipotezler

- H₁ LSTM Oto Kodlayıcı ve ConvLSTM mimarileri, deniz seviyesi tahmininde mevcut literatürde yaygın olarak kullanılan Yığılmış LSTM modeline göre daha üstün performans (daha yüksek doğruluk ve genelleştirme kabiliyeti) gösterir.
- H₂ LSTM Oto Kodlayıcı ve ConvLSTM mimarileri, Karadeniz'deki deniz seviyesi değişimlerini etkin bir şekilde tahmin edebilir.
- H₃ Karadeniz için deniz seviyesi değişimlerini modellemek üzere özelleştirilmiş LSTM Oto Kodlayıcı ve ConvLSTM mimarileri, mevcut derin öğrenme yöntemleri ve mimarileri arasında en yüksek tahmin performansını sağlar.
- H₄ Düşük çözünürlüklü uydu altimetre verisi üzerinde eğitilen modeller, yüksek çözünürlüklü uydu altimetre verisinde de yüksek tahmin doğrulukları sağlayabilir, bu da modellerin genelleştirme kabiliyetinin yüksek olduğunu gösterir.
- H₅ Uydu altimetre veri seti kullanılarak eğitilen modeller, mareograf verileri üzerinde de yüksek tahmin doğrulukları sağlayarak, farklı veri kaynaklarına iyi bir şekilde uyum sağlayabilir.

- H₆ Geliştirilen LSTM Auto-Encoder ve ConvLSTM mimarileri kullanılarak, gelecekteki 15 günlük deniz seviyeleri yüksek doğrulukla tahmin edilebilir, bu da modellerin pratik uygulamalarda etkin bir şekilde kullanılabileceğini gösterir.
- H₇ Karadeniz bölgesi için geliştirilen deniz seviyesi erken uyarı sistemi, kıyı taşkınları riskini azaltmada etkili bir araç olup, erken uyarı sağlama konusunda yüksek güvenilirlik ve doğruluk sunar.

1.6. Tezin Uygulanabilirliği ve Pratik Değeri

Bu tez çalışması, Karadeniz bölgesindeki deniz seviyesi değişimlerini derin öğrenme yöntemleri ile hassas bir şekilde modellemeye ve bu bağlamda yeni modelleme yaklaşımlarının ve mimarilerinin geliştirilmesi ve uygulanması üzerine odaklanmaktadır. Elde edilen bulguların uygulanabilirliği ve pratik değeri hem akademik araştırmalarda hem de güncel çevresel uygulamalarda önemli etkilere sahiptir.

Tez kapsamında geliştirilen ConvLSTM modeli, Karadeniz bölgesinde yüksek deniz seviyesi anomalilerinin önceden belirlenmesi için kullanılabilecek erken uyarı sisteminin temel taşı oluşturmaktadır. Bu sistemler, kıyı taşkınları gibi doğal afetlerden kaynaklanan riskleri azaltma konusunda kritik öneme sahiptir. Neredeyse gerçek zamanlı (1 Gün gecikmeli) tahmin yetenekleri sayesinde, bu sistemler afet öncesi hazırlık süreçlerinde karar vericilere değerli bilgiler sunabilir ve toplulukların zamanında tahliye ve hazırlık yapmalarına olanak tanıyabilir.

Tez kapsamında geliştirilen erken uyarı sistemi, meteorolojik tahmin modelleri ile birleştirilerek afet hazırlık ve müdahale planlarının geliştirilmesine entegre edilebilir. Bu sistemler, afet anında operasyonel karar verme süreçlerini ve kaynak dağılımını iyileştirebilir. Ayrıca, toplulukların afetlere karşı daha dayanıklı hale getirilmesi için eğitim ve bilinçlendirme programlarında bu teknolojilerden yararlanılabilir.

Deniz seviyesi tahmininde yapay zeka ve makine öğrenimi teknolojilerinin kullanımı, çevresel bilimlerdeki uygulamaların geleceğini şekillendirmektedir. Bu tez çalışmasından elde edilen bilgi birikimi, açık kaynak kodlu yazılımlar ve araçlar aracılığıyla sektör temsilcileri, akademisyenler ve politika yapıcılar tarafından kolaylıkla kullanılabilir özelliktedir. Böylece, deniz seviyesi tahmini ve kıyı yönetimi alanında yeni çözümlerin geliştirilmesine katkıda bulunulması hedeflenmiştir.

1.7. Tezin Yapısı ve Bölümlerin Özeti

Tez çalışması beş ana bölümden oluşmaktadır:

- Bölüm 1. Genel Bilgiler bölümünde, deniz seviyesi değişimleri ve jeodezi bilimi üzerine bir giriş yapılarak, deniz seviyesi değişimlerinin tarihsel arka planı, nedenleri ve iklim değişikliği ile ilişkisi açıklanmıştır. Bu bölümde, deniz seviyesi artışlarının çevresel ve sosyal etkileri, izlenmesi, tahmini ve modellemesinin önemi vurgulanmıştır. Ayrıca, tez çalışmasının önemi, literatür taraması ve teorik çerçevesi ile birlikte araştırmanın amacı ve kapsamı detaylı bir şekilde anlatılmıştır.
- Bölüm 2. Metodoloji bölümünde, araştırmanın temelini oluşturan Yapay Sinir Ağları, Tekrarlayan Sinir Ağları, Uzun-Kısa Süreli Bellek Ağları ve bunların mimarileri üzerine bilgiler sunulmuştur. Bu yöntemlerin deniz seviyesi değişimlerinin modellemesinde nasıl kullanıldığı açıklanarak, verilerin ön işleme ve model oluşturma süreci detaylandırılmıştır.
- Bölüm 3. Veri Setleri ve Yapılan Çalışmalar bölümünde, öncelikle kullanılan veri setleri ve geliştirilen modellerin tasarımı, eğitimi ve performans analizleri yer almaktadır. Farklı modellerin performans karşılaştırmaları yapılmış, genelleştirme kabiliyetleri değerlendirilmiştir. Bunun yanı sıra Karadeniz için tasarlanan deniz seviyesi erken uyarı sistemi (Tideguard) ile çevresel modelleme yazılımı (Envilearn) tanıtılmış, yazılımların mimarisi, arayüzleri ve uygulama örnekleri açıklanmıştır.
- Bölüm 4. Tartışma ve Değerlendirme bölümünde, araştırmanın bulguları kapsamlı bir şekilde değerlendirilmiş, kullanılan yöntemsel yaklaşımlar eleştirilmiş ve çalışmanın potansiyel etkileri ile uygulama alanları tartışılmıştır. Bu bölümde elde edilen sonuçların bilimsel ve pratik önemi vurgulanmıştır.
- Bölüm 5. Sonuçlar ve öneriler bölümünde, araştırmanın ana bulguları ve araştırma bulgularının değerlendirilmesi tartışılmıştır. Ayrıca, gelecek araştırmalar için öneriler ve yönlendirmeler sunulmuştur. Bu bölüm, tezin kapsamlı bir özetini ve araştırmanın önemini vurgulamaktadır.

1.8. Deniz Seviyesi Değişimleri: Tarihsel Perspektif ve Güncel Durum

Deniz seviyeleri tarih boyunca hem global hem de bölgesel ölçekte büyük değişimler yaşamıştır. Deniz seviyesi değişimlerinin tarihsel kayıtları incelendiğinde, özellikle buzul ve ara buzul dönemlerinin deniz seviyeleri üzerinde kritik bir rolü vardır. Shackleton (1987) tarafından yapılan bir çalışma, son buzul döngüsü boyunca deniz seviyesinin detaylı kayıtlarını ve oksijen izotoplarının analizini sunmakta; buz hacmi ve deniz seviyesi arasında önemli bir bağlantı kurulmaktadır (Shackleton, 1987). Bu çalışma, Pleistosen boyunca (yaklaşık son 2.5 milyon yıl) deniz seviyelerindeki değişimleri ve buz hacimlerini detaylı bir şekilde incelemiştir. Bu dönemlerde, deniz seviyeleri önemli ölçüde değişim göstermiştir. Özellikle, geç Pleistosen dönemi boyunca (yaklaşık son 126,000 yıl) büyük buzul dönemleri meydana gelmiştir. Buzul dönemleri sırasında, dünya çapında büyük buz tabakaları ve buzullar oluşmuştur. Bu buzullar, okyanuslardan büyük miktarda suyu emerek kara üzerinde donmuş halde tutmuşlardır. Sonuç olarak, deniz seviyeleri önemli ölçüde düşmüştür. Bu çalışmaya göre, bu dönemlerde deniz seviyeleri, mevcut seviyelerden önemli ölçüde daha düşük olmuştur. Buzul dönemlerinde deniz seviyelerinin mevcut seviyelerden 100 metreye kadar daha düşük olabileceği değerlendirilmiştir. Ara buzul dönemlerinde ise, buzulların erimesiyle deniz seviyeleri tekrar yükselmiştir. Ancak bu çalışmanın bulgularına göre, ara buzul dönemlerdeki deniz seviyeleri, Holosen dönemindeki (yaklaşık son 11,700 yıl) seviyelere tam olarak ulaşmamıştır. Bu durum, ara buzul dönemlerinde de deniz seviyelerinin mevcut günümüzdeki seviyelerden daha düşük olduğunu göstermektedir. Bu dönemsel değişimler, deniz seviyelerinin iklim ile yakından ilişkili olduğunu göstermektedir. Boer ve diğerleri (2013) tarafından yapılan bir diğer çalışma, geç Pleistosen dönemi boyunca küresel buz hacmi değişimlerinin ve bunların deniz seviyeleri ile suyun oksijen izotopları üzerindeki etkilerini incelemiştir (de Boer, 2013). Bu dönem, yaklaşık son 2.5 milyon yıl içindeki büyük buzul dönemlerini ve ara buzul dönemlerini kapsar. Araştırma, özellikle Avrasya ve Kuzey Amerika'daki büyük buzulların erimesi ve büyümesi süreçlerini ve bu süreçlerin deniz seviyeleri ve okyanus suyu kimyası üzerindeki etkilerini incelemiştir. Simülasyon sonuçları, deniz seviyelerindeki değişimlerin ve suyun oksijen izotoplarında gözlemlenen değişikliklerin büyük kısmının Avrasya ve Kuzey Amerika'daki buzulların hacim değişikliklerinden kaynaklandığını göstermiştir. Buzulların erimesi, okyanuslara ek suyun katılmasına ve böylece deniz seviyelerinin yükselmesine yol açmıştır. Sonuç olarak, bu çalışma, deniz seviyelerindeki değişikliklerin büyük kısmının buzulların hacim

değişikliklerinden kaynaklandığını ortaya koymuş, ancak bu değişimlerin kesin miktarları hakkında ayrıntılı bilgi vermemiştir. Literatürde yer alan çalışmalar, tarih boyunca deniz seviyelerinin hem global hem de bölgesel ölçekte büyük değişimler yaşadığını ortaya koymaktadır; bu değişimler bazen yükselişler, bazen de düşüşler şeklinde gerçekleşmiştir.

Deniz seviyelerindeki tarihsel değişimler büyük ölçüde doğal iklim döngüleri ve buzul-holosen dönemleri gibi süreçlerle açıklanabilirken, modern dönemdeki değişimler bu tarihsel eğilimlerden belirgin bir şekilde ayrılmaktadır. Özellikle 18. yüzyılın sonlarında başlayan Endüstri Devrimi ile birlikte, insan kaynaklı faaliyetlerin iklim üzerindeki etkisi, deniz seviyelerindeki değişimlerin en önemli itici gücü haline gelmiştir. Doğal süreçler uzun jeolojik zaman dilimlerinde meydana gelirken, insan faaliyetleri sonucunda oluşan değişimler daha kısa zaman aralıklarında ciddi etkiler yaratmaktadır. Bu nedenle, tarihsel süreçler boyunca doğal faktörlerle şekillenen deniz seviyesi değişimlerinin, Endüstri Devrimi sonrası dönemde insan kaynaklı etkilerle nasıl değiştiğini incelemek önem arz etmektedir.

Özellikle Endüstri Devrimi'nin ardından, artan fosil yakıt kullanımı, atmosferdeki karbondioksit (CO₂) seviyelerini önemli ölçüde arttırmıştır. CO₂ konsantrasyonları, Endüstri Devrimi'nin başlangıcından bu yana 280 ppm'den 385 ppm'e yükselmiş durumdadır. Bu durum, okyanusların pH değerini düşürerek asitlenmesine yol açmıştır (Turley, 2008). Ayrıca artan CO₂ konsantrasyonları sera gazı etkisi nedeniyle dünya genelinde sıcaklık artışlarına neden olmuş ve buzulların erimesine ve okyanus sularının genleşmesine yol açmıştır. Dolayısıyla, Endüstri Devrimi sonrası dönemde insan kaynaklı faaliyetler, iklim sistemi üzerinde derin bir etkiye sahiptir. Bu durum deniz seviyelerinde görülen önemli yükselmelerle net bir şekilde gözlemlenmiştir (Leinfelder, 1993). Bu yükselişler hem ekosistemler için hem de kıyı bölgelerinde yaşayan insan toplulukları için ciddi sonuçlar doğurmuştur.

1.9. Deniz Seviyesi Değişiminin Nedenleri ve İklim Değişikliği

Son yıllarda yapılan gözlemler ve araştırmalar, deniz seviyesi değişimlerinin çeşitli nedenlerden kaynaklandığını ortaya koymuştur. Bu nedenler arasında gel-git etkileri, meteorolojik faktörler (atmosfer basıncı ve hava sıcaklığı değişiklikleri gibi), oşinografik etkiler (tuzluluk değişiklikleri gibi), ve iklim değişikliğinden kaynaklanan faktörler (buzulların erimesi, deniz sularının termal genleşmesi) bulunmaktadır (Simav, 2007;

Cazenave & Nerem, 2004). Özellikle iklim değışiklięi ile ilgili faktörler, deniz seviyesindeki değışimleri daha karmaşık ve düzensiz hale getirmektedir.

Deniz seviyesinin sürekli yükselmesinin başlıca nedenleri arasında okyanusların termal genişlemesi ve kara buzullarının erimesi gibi iklim değışiklięinden kaynaklanan etkenler yer almaktadır. Küresel ısınmanın neden olduęu okyanus sıcaklıklarındaki artış, deniz sularının hacmini artırarak deniz seviyesinin yükselmesine sebep olmakta ve daę buzullarının artan hava sıcaklıkları nedeniyle erimesi, okyanuslara tatlı su kütlelerinin girişine ve dolayısıyla deniz seviyesinin yükselmesine yol açmaktadır (Cazenave & Nerem, 2004).

Özellikle 1993'ten beri global deniz seviyesindeki iklimle ilgili değışimler (yılda yaklaşık 2.85 ± 0.35 mm) ve altimetre tabanlı deniz seviyesi yükselmesi (yılda yaklaşık 3.3 ± 0.4 mm) neredeyse eş değerde olup, gözlemlenen yükselme oranının yaklaşık %30'u okyanusların termal genişlemesinden ve yaklaşık %55'i kara buzullarının erimesinden kaynaklanmaktadır (Cazenave & Llovel, 2010). Bu durum, deniz seviyesi değışimleri ile ilgili çalışmalarda gel-git, meteorolojik ve oşinografik etkilerin yanı sıra, iklimle ilgili bu faktörlerin de dikkate alınmasını gerektirmektedir. Deniz seviyesinin değışimine sebep olan bu karmaşık etkileşimler, deniz seviyesi değışimlerinin izlenmesi, modellenmesi ve tahmin edilmesindeki zorlukları da arttırmaktadır.

1.10. Deniz Seviyesi Artışlarının Sebep Olduęu Çevresel Etkiler

Küresel ısınma ve iklim değışiklięi, deniz seviyelerindeki artışları hızlandırmakta ve bu durum, birçok çevresel, ekonomik ve sosyal sorunu beraberinde getirmektedir. 2100 yılına kadar deniz seviyesinin yaklaşık 1 metre yükseleceęi tahmin edilmektedir (Gornitz, 1995). 1993'ten günümüze kadar küresel deniz seviyesinin ortalama oranı yılda 3.1 mm artış ve yıllık 0.1 mm hızlanma göstermiştir (Wouters, 2018). Bu artışlar özellikle kıyı bölgelerinde birçok soruna sebep olmaktadır. Deniz seviyesi artışlarının devam edeceęi göz önüne alındığında sorunların daha da artması beklenmektedir. Bu sorunların başlıcaları aşağıdaki gibi sayılabilir:

- Kıyı taşkınlarının artması: Deniz seviyelerindeki artış, özellikle alçak kıyı bölgelerinin su baskınına maruz kalmasına ve fırtına dalgalarının şiddetlenmesine yol açarak, bu alanlarda bileşik kıyı taşkınlarının meydana gelmesine neden olmaktadır. Böylece, yolların kapanması ve altyapının bozulması gibi ekonomik

kayıplara ve kamu sağılığı riskleri ortaya çıkmaktadır (Moftakhari, ve diğlereri, 2015).

- Kıyı Bitki Türlerine Etki: Kıyı bitki türleri üzerinde deniz seviyesi artışının ve iklim değışikliğinin ciddi etkileri olması beklenmektedir. Bu durum, bitki türlerinin yaşam alanlarının değışmesine ve bazı türlerin yok olmasına yol açabilir (Garner, ve diğlereri, 2015).
- Toprak Tuzluluğunun Artması: Deniz seviyesi artışı, kıyı bölgelerde toprak tuzluluğunun artmasına yol açarak tarım arazileri, sulak alanlar ve diğler ekosistemler için ciddi bir tehdit oluşturmaktadır (Mazhar, Pellegrini, Contin, Bravo, & De Nobili, 2022).
- Altyapı Bozulması: Deniz seviyesi artışı nedeniyle artan sık ve ciddi sel olayları, altyapıyı ve atık su arıtma tesislerini tehdit etmektedir (Azevedo de Almeida & Mostafavi, 2016)
- Küresel ve Bölgesel İklim Üzerindeki Etkiler: Deniz seviyesindeki değışimler, küresel ve bölgesel iklim sistemlerini de etkilemektedir. Örneğın, yükselen deniz seviyeleri, kıyı bölgelerinin hava sıcaklığını ve nem seviyesini etkileyerek, bu bölgelerdeki iklim desenlerinde değışikliklere neden olabilir. Bunun yanı sıra, deniz seviyesi yükselmesi, fırtına dalgalarının etkisini artırarak kıyı erozyonunu ve taşkınları şiddetlendirebilir, bu da yerel iklim koşullarını daha da zorlayıcı hale getirebilir (Luque, Gómez-Pujol, Marcos, & Orfila, 2021).

1.11. Deniz Seviyesi Artışlarının İzlenmesi, Tahmini ve Modellenmesinin Önemi

Deniz seviyesindeki artışlar, kıyı bölgelerinde birçok olumsuz etkiye sebep olmakta ve bu durum, kıyı yapılarını ve kıyıda yaşayan popölasyonları ciddi şekilde tehlikeye atmaktadır. Bu nedenlerle deniz seviyelerinin tahmini için oluşturulan tahmin modelleri inşaat mühendisliğı, klimatoloji, meteoroloji, jeodezi, kıyı mühendisliğı gibi birçok farklı disiplin için oldukça önemlidir. Jeodezik perspektiften, deniz seviyesi, uzun yıllar boyunca sabit kaldığı varsayılan eş potansiyelli bir yüzey olarak düşey kontrol ağlarının referans yüzeyi olarak kullanılmaktadır. Ancak yapılan araştırmalar deniz seviyesinin genellikle düşünöldüğü gibi sabit bir eş potansiyelli yüzey olmadığını ortaya koymuştur (Hannah, 1989). Böylece aslında jeodezik olarak da düşey kontrol ağlarının datumunun güncellenmesi

sorunu da ortaya çıkmaktadır. Dolayısıyla, deniz seviyesi değişimlerinin modellenmesi, jeodezik açıdan da büyük bir önem taşımaktadır. Ayrıca, deniz seviyesi değişimlerini izlemek ve modellemek, iklim değişikliğine karşı mücadelede ve uyum stratejileri geliştirmede de hayati öneme sahiptir. İz (2018) çalışmasında, deniz seviyesi tahminlerinin gelecek iklim tartışmaları için gerekli olduğunu ve ampirik modellerin yüksek çözünürlüklü güvenilir tahminler sağlayabileceğini belirtmektedir (İz, 2018). Bu tahminler, kıyı risk değerlendirmesinde politika geliştirme için rehberlik etme kapasitesine sahiptir. Örneğin, Avrupa Birliği'nin Dünya Gözlem Programı olan Copernicus, deniz seviyesi değişikliklerini izleyerek, kıyı deniz seviyesi yükselmesinin risklerini değerlendirmek ve uyum stratejilerini desteklemek için gereken altyapı ve verileri sağlamaktadır (Melet, ve diğerleri, 2021; Copernicus, 2025).


1.12. Deniz Seviyesi Değişimi Ölçme Teknikleri ve Veri Kaynakları

Deniz seviyesi değişimi belirlenmesinde temelde geleneksel mareograf (yerinde gözlem) istasyonlarından yararlanılmaktadır. Bir diğer temel teknik olan uydu altimetride ise yerin gravite merkezine göre deniz seviyesi ölçülmekte olup yer merkezli etkilere maruz kalmamaktadır. Bu iki temel tekniğe ilave olarak, son yıllarda hızla ilerleyen GNSS teknolojisi ile deniz seviyesi gibi yüzey değişikliklerini izlemek için GNSS-IR tekniği de kullanılmaktadır (Beşel, 2023).

- **Mareograf Verileri (Yerinde Gözlem):** Mareograf verileri, deniz seviyesi değişimlerini takip etmek için kıyı bölgelerinde konumlandırılan gözlem istasyonlarından elde edilen yerinde ölçümlerdir. Bu istasyonlar, deniz seviyesinin sürekli olarak kaydedilmesini sağlar ve uzun vadeli değişikliklerin izlenmesinde kritik bir rol oynarlar. Mareograf verileri, özellikle lokal ölçekte deniz seviyesi değişimlerini yakalamada önemlidir. Ayrıca, bu veriler, deniz seviyesi modellenmesi ve uydu altimetresi verilerinin doğrulanması ve kalibrasyonu için temel bir kaynak olarak hizmet eder. Ancak, mareograf verilerinin elde edilmesi sırasında, ölçümler karadaki sabit bir referans noktasına göre yapılır. Bu durum, deniz seviyesi değişim sinyallerinin düşey yönlü kara hareketlerinden etkilendiği anlamına gelir. Böylece, düşey yönlü kara hareketlerini içeren deniz seviyesi sinyalleri 'bağıl deniz seviyesi değişimi' olarak adlandırılır. Diğer yandan, düşey yönlü kara hareketlerinden arındırılmış deniz seviyesi değişim sinyalleri ise

'mutlak deniz seviyesi deęiřimi' olarak tanımlanır. Bu mutlak deniz seviyesi deęiřimleri, genellikle mareograf istasyonunun yakınına konumlandırılan GNSS (Global Navigation Satellite System) alıcıları sayesinde elde edilir.

- Uydu Altimetre Teknięi: Deniz seviyesi ölçümünde kullanılan en önemli uzaktan algılama yöntemlerinden biri uydu altimetresi teknięidir. Bu teknik, yeryüzü ile uydu arasındaki mesafeyi yüksek doğrulukla ölçerek deniz yüzeyindeki yükseklik deęiřimlerini tespit etmeye olanak tanır (řekil 2).



řekil 2. Uydu altimetresi teknięiyle deniz seviyesi ölçümü

Uydu altimetresi sistemleri, genellikle radar ya da lazer temelli altimetre cihazlarıyla donatılmıştır ve küresel ölçekte sürekli veri sağlayarak okyanus dinamiklerinin anlaşılmasında kritik bir rol oynamaktadır (Shum, 1995; Cazenave et al., 2018).

Uydu altimetresiyle deniz seviyesi ölçümü genel olarak ařaęıdaki işlem basamaklarıyla gerçekleştirilir.

Altimetre Sinyalinin Yayımlı: Uydu üzerinde bulunan altimetre cihazı, belirli aralıklarla Dünya yüzeyine doğru yüksek frekanslı elektromanyetik sinyaller (genellikle mikrodalga) gönderir. Radar altimetreleri bu amaçla en yaygın kullanılan sistemler olup, sinyalin iletim ve dönüş sürelerini nanosaniyeye varan hassasiyetle kaydeder.

Sinyalin Yansıması ve Geri Alımı: Gönderilen sinyal, deniz yüzeyinden yansıyıp tekrar uyduya geri döner. Bu yansıma süresi, sinyalin çıkış ve dönüş zamanları arasındaki fark olarak ölçülür ve deniz yüzeyinin o andaki konumu hakkında doğrudan bilgi sağlar.

Yükseklik (Mesafe) Hesaplaması: Gidip gelen sinyalin süresi, elektromanyetik dalgaların vakumda ışık hızında ilerlediği varsayımıyla çarpılarak uydu ile deniz yüzeyi arasındaki mesafe hesaplanır. Bu mesafe, altimetre yüksekliği (range) olarak adlandırılır.

Uydu Yüksekliğinin Belirlenmesi: Uyduya ait yörünge bilgileri doğrultusunda, uydu ile referans jeoid arasındaki konum bilgisi kesin olarak belirlenir. Bu sayede, uydu konumu ile altimetre sinyaliyle ölçülen mesafe farkı, deniz yüzeyinin yüksekliğini verir.

Düzeltilmelerin Uygulanması: Ölçüm doğruluğunu artırmak amacıyla, ham sinyal verilerine çeşitli atmosferik ve fiziksel düzeltilmeler uygulanır. Bu düzeltilmeler arasında; iyonosferik ve troposferik gecikmeler, gelgit etkileri, kara etkisi, atmosferik basınç kaynaklı sapmalar ve deniz yüzeyi rüzgarlarının etkisi yer alır.

Ortalama Deniz Seviyesi Hesaplaması: Altimetre ile elde edilen yükseklik değerleri, zaman içinde ortalamaya alınarak belirli bir referans seviyeye (örneğin, jeoid ya da elipsoidal yüzey) göre deniz seviyesi anomalileri elde edilir. Bu anomaliler hem küresel iklim değişikliği analizlerinde hem de bölgesel deniz seviyesi eğilimlerinin belirlenmesinde kritik öneme sahiptir.

Uydu altimetresi verileri, yüksek konumsal ve zamansal çözünürlüğe sahip olmaları sayesinde, deniz seviyesi yükselmesi, El Niño olayları, okyanus akıntıları ve gelgit etkileri gibi pek çok oşinografik ve klimatolojik süreç üzerinde yapılan çalışmalarda yaygın olarak kullanılmaktadır.

- **GNSS – IR Tekniğı:** GNSS İnterferometrik Reflektometri (GNSS-IR), GNSS sinyallerinin doğrudan ve yansıyan bileşenlerinin etkileşimini analiz ederek çevresel parametrelerin belirlenmesini sağlayan yenilikçi bir tekniktir. Bu yöntem,

özellikle deniz seviyesi değişimlerinin izlenmesinde önemli bir potansiyele sahiptir. GNSS-IR, GNSS antenine ulaşan doğrudan ve yansıyan sinyallerin girişim desenlerini inceleyerek çalışır. Bu girişim desenleri, sinyal-gürültü oranı (SNR) verilerinde periyodik modülasyonlar oluşturur. SNR verilerinin spektral analizi ile yansıyan sinyalin frekansı belirlenir ve bu frekans, anten ile yansıtıcı yüzey (örneğin, deniz yüzeyi) arasındaki mesafenin hesaplanmasında kullanılır. Bu mesafe, deniz seviyesinin belirlenmesine olanak tanır. GNSS-IR yöntemi, deniz seviyesinin izlenmesinde geleneksel mareograf ölçümlerine alternatif veya tamamlayıcı bir teknik olarak kullanılmaktadır. Özellikle deniz kıyısındaki GNSS istasyonları, yeterli açık görüş açısına sahip olduklarında, deniz yüzeyinden yansıyan sinyalleri alabilirler. Bu sayede, deniz seviyesi değişimleri GNSS-IR yöntemiyle izlenebilir.

Her üç veri kaynağı da deniz seviyesi değişimlerini izlemek için avantajlar ve sınırlamalar sunmaktadır. Mareograf verileri, yerel ölçekli değişimleri yüksek hassasiyetle gözlemlene imkanı tanırken, uydu altimetresi verileri, küresel ve bölgesel deniz seviyesi değişimlerini geniş çapta ve sürekli olarak izleme avantajına sahiptir. GNSS-IR verileri ise, mevcut GNSS altyapısını kullanarak deniz seviyesinin izlenmesine katkı sağlar. Bu üç yöntem, birbirini tamamlayıcı nitelikte olup, deniz seviyelerinin daha kapsamlı bir şekilde analiz edilmesi ve modellenmesi için birlikte kullanılabilir. Bu nedenle, gelecekte geliştirilecek deniz seviyesi modellerinin, tüm bu veri kaynaklarından elde edilen bilgileri entegre edecek şekilde tasarlanması, deniz seviyelerindeki değişimlerin daha doğru ve kapsamlı bir şekilde anlaşılmasını sağlayacaktır.

1.13. İklim Değişikliği ve Erken Uyarı Sistemleri

Erken uyarı sistemleri, yaklaşmakta olan tehlikeler veya doğal afetler hakkında önceden bilgi sağlayarak toplumların ve bireylerin bu tehlikelere karşı hazırlıklı olmalarını sağlamak amacıyla kullanılan teknoloji ve süreçler bütünüdür. Bu sistemler, tehlikelerin zamanında tespiti, izlenmesi ve bu bilgilerin ilgili makamlara ve halka etkin bir şekilde iletilmesi sürecini içerir. Birleşmiş Milletler Afet Riskini Azaltma Stratejisi 2012 Raporu'nda erken uyarı sistemleri, "Bir tehlike tarafından tehdit edilen bireylerin, toplulukların ve kuruluşların hazırlanabilmesi ve zarar veya kayıp olasılığını azaltacak

şekilde zamanında ve anlamlı uyarı bilgilerini oluşturmak ve yaymak için gereken yetenekler seti" olarak tanımlamıştır (UNISDR, 2012).

Erken uyarı sistemleri, doğal afetlerin ve tehlikelerin etkilerini minimize etmek için çeşitli bileşenlerden oluşur. Bu bileşenler, tehlikelerin zamanında ve doğru bir şekilde tespit edilmesini, etkili bir şekilde izlenmesini, tahmin edilmesini, risklerin değerlendirilmesini ve bu bilgilerin ilgili taraflara zamanında iletilmesini kapsar (WMO, 2022).

Afet Risk Bilgisi: Tehlikelerin ve bu tehlikelerin potansiyel etkilerinin anlaşılması ve tanımlanması sürecidir. Bu bileşen, risk değerlendirmesi ve geçmiş olayların analizini içerir.

Tehlikelerin İzlenmesi, Analizi ve Tahmini: Doğal tehlikelerin sürekli izlenmesi ve tahmin edilmesi sürecidir. Bu süreç, meteorolojik, hidrolojik ve jeofiziksel verilerin toplanması ve analizini kapsar. Özellikle kıyı taşkınları gibi olayların modellenmesi ve tahmin edilmesi bu bileşenin bir parçasıdır.

Uyarıların Yayılması ve İletişimi: Erken uyarı bilgilerinin ilgili kurumlara ve topluluklara zamanında ve etkili bir şekilde iletilmesi sürecidir. Bu bileşen, iletişim sistemlerinin ve ekipmanlarının kullanılmasını içerir ve halkın doğru bilgiye erişimini sağlar.

Hazırlık ve Müdahale Kapasiteleri: Toplulukların ve ilgili kurumların olası tehlikelere karşı hazırlıklı olmasını ve uygun yanıt verebilmesini sağlamak amacıyla kapasite geliştirme ve eğitim faaliyetlerini içerir. Bu bileşen, topluluk eğitim programlarını ve acil durum planlarını kapsar.

İklim değişikliği, kıyı taşkınları gibi doğal tehlikelerin sıklığını ve şiddetini artırarak, erken uyarı sistemlerinin önemini daha da artırmaktadır. Erken uyarı sistemleri, iklim değişikliğinin etkilerini azaltmak ve toplulukların bu etkilerle başa çıkabilmesini sağlamak için kritik bir araçtır.

Son yıllarda, iklim değişikliğinin etkileriyle mücadele etmek amacıyla erken uyarı sistemlerinin geliştirilmesine yönelik birçok çalışma yapılmıştır. Dünya Meteoroloji Örgütü (WMO), Küresel İklim Hizmetleri Çerçevesi'ni (Global Framework for Climate Services, GFCS) başlatarak dünya genelinde iklim hizmetlerinin, özellikle erken uyarı sistemlerinin iyileştirilmesini hedeflemiştir (WMO, 2014). Bu çerçeve, iklim değişikliğinin risklerinin daha iyi yönetilmesi için iklim bilgilerinin, planlama, politika ve uygulamalara entegrasyonunu amaçlamaktadır.

Birleşmiş Milletler Afet Riskini Azaltma Ofisi (UNDRR) ve WMO tarafından hazırlanan raporlar, iklim değişikliği bağlamında çoklu tehlike erken uyarı sistemlerinin (Multi-Hazard Early Warning Systems, MHEWS) önemini vurgulamaktadır (WMO, 2018).

Çoklu tehlike erken uyarı sistemleri, çeşitli tehlikeler, hassasiyetler ve kapasiteler hakkındaki bilgileri entegre ederek kapsamlı risk değerlendirmeleri ve uyarılar sağlar. Bu yaklaşım, birden fazla iklimle ilişkili tehlikenin eşzamanlı veya ardışık olarak meydana geldiği bölgelerde kritik öneme sahiptir.

Teknolojik ilerlemeler, uydu verileri ve uzaktan algılama teknikleri kullanılarak deniz seviyesi değişiklikleri ve aşırı hava olaylarını izlemek için sofistike erken uyarı sistemlerinin geliştirilmesine olanak tanımıştır. Bu teknolojik iyileştirmeler, uyarıların doğruluğunu ve zamanlamasını artırarak daha iyi hazırlık ve müdahaleye imkan tanımaktadır.

Küresel düzeyde, Birleşmiş Milletler, iklim değişikliğiyle ilişkili afet risklerini azaltmada erken uyarı sistemlerinin rolünü vurgulayarak, 2015-2030 Sendai Afet Riskini Azaltma Çerçevesi kapsamında erken uyarı sistemlerinin uygulanması çağrısında bulunmuştur (UNISDR, 2015). Bu çerçeve, ülkelerin afet risklerini azaltmak için erken uyarı sistemlerini ve risk bilgisi yayılımını güçlendirmesini teşvik etmektedir.

Dünya üzerinde birçok ülke iklim değişikliği etkileri ile mücadele etmek için erken uyarı sistemleri kullanmaktadır. Özellikle deniz seviyesinin değişimi ve buna bağlı olarak artan kıyı taşkınları riski, iklim değişikliğinin en önemli etkilerinden biridir. Bu nedenle, birçok ülke deniz seviyesi değişikliklerini izlemek ve olası afetlere karşı hazırlıklı olmak amacıyla erken uyarı sistemleri geliştirmiştir. Aşağıda, deniz seviyesi ile ilgili erken uyarı sistemlerine sahip olan ülkeler ve bu sistemlerin altyapıları ile metodolojileri ayrıntılı olarak açıklanmaktadır.

- Hollanda

Hollanda, deniz seviyesinin altında bulunan geniş arazileri nedeniyle su yönetimi ve taşkın önleme konusunda dünyanın en ileri ülkelerinden biridir. "Flood Early Warning System" (FEWS) adı verilen sistem, deniz seviyesi, nehir akışları, gelgitler ve hava durumu verilerini entegre ederek gerçek zamanlı tahminler yapar. Sistem, Rijkswaterstaat ve Deltares gibi kurumlar tarafından yönetilir ve gelişmiş hidrolik modeller, radar verileri ve uydu gözlemleri kullanır (Van Alphen, 2016).

Hollanda ayrıca "Delta Works" gibi büyük ölçekli altyapı projeleriyle fiziksel savunma sistemleri kurmuştur. Erken uyarı sistemi, bu altyapıların etkin bir şekilde yönetilmesini ve olası taşkın risklerine karşı önlemlerin zamanında alınmasını sağlar.

- Bangladeş

Bangladeş, yükselen deniz seviyeleri ve siklonlar nedeniyle ciddi taşkın riskleriyle karşı karşıyadır. Ülke, deniz seviyesi değişikliklerini ve fırtına dalgalanmalarını izlemek için

bir erken uyarı sistemi geliřtirmiřtir. Bangladeř Meteoroloji Departmanı, deniz seviyesi verilerini, hava durumu tahminlerini ve radar verilerini kullanarak tařkın uyarıları retir (Paul & Dutt, 2010). lke, siklon ve sel riskine karřı topluluk tabanlı erken uyarı sistemleri de geliřtirmiřtir (Paul & Rahman, 2006). Bangladeř Meteoroloji Departmanı, radyo, televizyon ve cep telefonu aęları zerinden uyarılar yayımlar. Ayrıca, Kızılhaç ve Kızılay gibi kuruluřların desteęiyle yerel gnlller aracılıęıyla kırsal blgelere uyarıların iletilmesi saęlanmaktadır.

- Amerika Birleřik Devletleri (ABD)

ABD, zellikle doęu ve gney kıyılarında deniz seviyesi ykselmesi ve fırtına dalgalanmalarına karřı erken uyarı sistemlerine sahiptir. Ulusal Okyanus ve Atmosfer İdaresi (NOAA), "Ulusal Su Seviyesi Gzlem Aęı, National Water Level Observation Network - (NWLON)" aracılıęıyla deniz seviyesi verilerini toplar ve izler (Miller & Luscher, 2018). Ayrıca, ABD Ulusal Kasırğa Merkezi tarafından geliřtirilen Fırtına Dalgalanması Uyarı Sistemi (Storm Surge Warning System), yaklařan fırtınaların ve kasırgaların neden olabileceęi deniz seviyesi artıřlarını tahmin eder. Bu sistem, meteorolojik verileri, deniz seviyesi lmlerini ve hidrodinamik modelleri kullanarak olası tařkın blgelerini ve risk seviyelerini belirler (NHC, 2024).

- Japonya

Japonya, deniz seviyesinin ykselmesi, tsunami ve tayfun risklerine karřı kapsamlı erken uyarı sistemlerine sahiptir. Japonya Meteoroloji Ajansı (JMA), "Sea Level Monitoring System" aracılıęıyla deniz seviyesi deęiřikliklerini gerek zamanlı olarak izler (Hasegawa, ve dięerleri, 2012). Tsunami erken uyarı sistemi, deniz tabanı sismometreleri, basın sensrleri ve uydu iletiřimi kullanarak birkaç dakika iinde uyarılar retir. Deniz seviyesinin ani ykselmesi durumunda, sistem otomatik olarak tahliye uyarıları ve risk deęerlendirmeleri yapar (Uchiike & Hosono, 1995).

- Avustralya

Avustralya, zellikle kıyı blgelerinde deniz seviyesinin ykselmesi ve fırtına dalgalanmalarına karřı erken uyarı sistemleri geliřtirmiřtir. Avustralya Meteoroloji Brosu ve Geoscience Australia iř birlięiyle Avustralya Tsunami Uyarı Sistemi (Australian Tsunami Warning System) iřletilmektedir (Australian Government, 2024). Deniz seviyesi gzlem istasyonları, gelgit lerler ve deniz tabanı basın sensrleri kullanılarak deniz seviyesindeki deęiřiklikler izlenir. Sistem, meteorolojik verilerle birlikte hidrodinamik modeller kullanarak olası tařkın risklerini ve etkilenecek blgeleri tahmin eder.

- Birleşik Krallık

Birleşik Krallık, deniz seviyesinin yükselmesi ve kıyı taşkınları riskine karşı erken uyarı sistemleri uygulamaktadır. Çevre Ajansı ve Meteoroloji Ofisi tarafından yönetilen "Flood Forecasting Centre", deniz seviyesi, gelgit, hava durumu ve nehir akış verilerini entegre ederek taşkın uyarıları üretir (Agency, 2024). Birleşik Krallığa ait Kıyı Taşkın Uyarı Sistemi, özellikle fırtına dalgalanmalarına ve yüksek gelgitlere karşı uyarılar sağlar. Sistem, gelişmiş hidrodinamik modeller ve gerçek zamanlı veri akışı kullanarak risk değerlendirmeleri yapar.

- Maldivler

Maldivler, neredeyse tüm ülkenin deniz seviyesi yüksekliğinde bulunması nedeniyle deniz seviyesi değişimine karşı varoluşsal bir tehdit altındadır. Ülke, deniz seviyesi değişikliklerini izlemek ve olası afetlere karşı hazırlıklı olmak için erken uyarı sistemleri geliştirmiştir. Maldivler Meteoroloji Servisi, deniz seviyesi ve hava durumu verilerini toplayarak uyarılar üretir (Shaig, 2011). Uluslararası kuruluşların desteğiyle, uydu tabanlı izleme sistemleri ve otomatik istasyonlar kurulmuştur. Toplum katılımı ve eğitim programları, halkın olası risklere karşı bilinçlendirilmesini sağlar.

- Yeni Zelanda

Yeni Zelanda, deniz seviyesinin yükselmesi ve tsunami riskine karşı erken uyarı sistemleri uygulamaktadır. "GeoNet" adlı sistem, sismik aktiviteleri ve deniz seviyesindeki değişiklikleri izler (GeoNet, 2024). Deniz seviyesi ölçüm istasyonları ve tsunami şamandıraları, deniz tabanındaki hareketleri ve su sütunundaki basınç değişikliklerini tespit eder. Sistem, hızlı bir şekilde uyarılar üreterek halkın tahliye ve hazırlık süreçlerine yardımcı olur.

- Almanya

Almanya, Kuzey Denizi kıyılarında deniz seviyesi yükselmesi ve fırtına dalgalanmalarına karşı erken uyarı sistemleri geliştirmiştir. "Almanya Su Yönetimi Bilgi Sistemi - WasserWirtschafts-WetterInformations-System (WaWIS)", deniz seviyesi, hava durumu ve nehir akış verilerini kullanarak taşkın tahminleri yapar (BfG, 2024).

Sistem, hidrodinamik modeller ve coğrafi bilgi sistemleri kullanarak risk alanlarını belirler ve ilgili kurumlara ve halka uyarılar iletilir.

- Kanada

Kanada, özellikle Atlantik ve Pasifik kıyılarında deniz seviyesi değişikliklerini ve fırtına dalgalanmalarını izlemek için erken uyarı sistemleri uygulamaktadır. Kanada Çevre

ve İklim Değişikliği Bakanlığı, deniz seviyesi gözlem istasyonları ve meteorolojik verileri kullanarak tahminler yapar (ECCC, 2024). "Deniz Durumu Uyarı Sistemi" aracılığıyla olası taşkın riskleri hakkında uyarılar yayımlanır.

- Fransa

Fransa, Atlantik ve Akdeniz kıyılarında deniz seviyesinin yükselmesi ve kıyı taşkınlarına karşı erken uyarı sistemleri geliştirmiştir. "Vigilance Météo" sistemi, Météo-France tarafından yönetilir ve deniz seviyesindeki değişiklikler, hava durumu ve gelgit verileri kullanılarak uyarılar sağlar (Borretti, Degrace, & Cova, 2012). "Kıyı Riski Önleme Planları" kapsamında, hidrodinamik modeller ve coğrafi bilgi sistemleri kullanılarak risk alanları belirlenir ve halkın bilinçlendirilmesi sağlanır.

- Hindistan

Hindistan, özellikle Bengal Körfezi ve Arap Denizi kıyılarında deniz seviyesi yükselmesi ve siklonlara bağlı taşkın riskine karşı erken uyarı sistemleri uygulamaktadır. Hindistan Meteoroloji Departmanı ve Ulusal Okyanus Bilimi Enstitüsü, deniz seviyesi verilerini ve hava durumu tahminlerini kullanarak uyarılar üretir (INCOIS, 2024). "Indian Tsunami Early Warning Centre", deniz tabanı sismometreleri ve deniz seviyesi ölçüm istasyonları aracılığıyla tsunami ve fırtına dalgalanmalarını izler.

- Filipinler

Filipinler, deniz seviyesinin yükselmesi ve tropikal fırtınalar nedeniyle yüksek risk altındadır. Filipinler Atmosferik, Jeofizik ve Astronomik Hizmetler İdaresi (PAGASA), deniz seviyesi ve hava durumu verilerini izleyerek uyarılar sağlar (PAGASA, 2024). "Project NOAH" (Nationwide Operational Assessment of Hazards), uydu verileri, radar görüntüleri ve hidrodinamik modeller kullanarak taşkın risklerini değerlendirir ve halka iletir.


- Endonezya

Endonezya, deniz seviyesinin yükselmesi, tsunami ve fırtına dalgalanmalarına karşı erken uyarı sistemleri geliştirmiştir. "InaTEWS" (Indonesia Tsunami Early Warning System), sismik ağlar ve deniz seviyesi ölçüm istasyonları kullanarak uyarılar üretir (Rudloff, Lauterjung, Münch, & Tinti, 2009). Deniz seviyesi değişiklikleri sürekli izlenerek, olası afetlere karşı hazırlıklı olunması sağlanır.

- Norveç

Norveç, kuzey kutup bölgelerinde deniz seviyesinin yükselmesi ve buzulların erimesi nedeniyle oluşabilecek risklere karşı erken uyarı sistemleri uygulamaktadır. Norveç Meteoroloji Enstitüsü ve Norveç Su Kaynakları ve Enerji Müdürlüğü, deniz seviyesi ve

buzul koşullarını sürekli olarak izlemektedir (Institute, 2024). Şekil 3’te deniz seviyesi erken uyarı sistemine sahip ülkeler verilmiştir.



Şekil 3. Deniz seviyesi erken uyarı sistemine sahip ülkeler

Bu ülkelerin erken uyarı sistemleri genellikle aşağıdaki ortak özelliklere sahiptir:


- Gerçek Zamanlı Veri Toplama: Mareograf istasyonları, radarlar ve uydu verileri kullanılarak sürekli veri akışı sağlanır.
- Gelişmiş Modelleme Teknikleri: Hidrodinamik ve atmosferik modeller kullanılarak deniz seviyesi değişiklikleri ve taşkın riskleri tahmin edilir.
- Çoklu Tehlike Entegrasyonu: Deniz seviyesi değişiklikleri, hava durumu olayları ve sismik aktiviteler gibi farklı tehlikeler entegre bir şekilde değerlendirilir.
- İletişim ve Uyarı Yayılımı: Uyarılar, ilgili kurumlara ve halka hızlı ve etkili bir şekilde iletilir. SMS, e-posta, sirenler ve medya gibi çeşitli iletişim kanalları kullanılır.
- Toplum Katılımı ve Eğitim: Halkın bilinçlendirilmesi ve afet risklerine karşı hazırlıklı olması için eğitim programları ve tatbikatlar düzenlenir.

Türkiye’de deniz seviyesi ve meteorolojik olayların izlenmesi ile erken uyarı sistemlerinin geliştirilmesine yönelik çalışmalar, çeşitli kurumlar tarafından yürütülmektedir. Harita Genel Müdürlüğü (HGM), Türkiye Ulusal Deniz Seviyesi İzleme Sistemi (TUDES) kapsamında, Türkiye ve Kuzey Kıbrıs Türk Cumhuriyeti kıyılarına dağılmış toplam 20 sayısal mareograf istasyonu ile deniz seviyesi değişimlerini izlemektedir (HGM, 2024). TÜBİTAK Marmara Araştırma Merkezi (MAM), deniz ve kıyı sularında

izleme faaliyetleri gerçekleştirmekte ve DEN-İZ Programı gibi projelerle deniz kirliliği ve ekosistem sağlığını izlemektedir (TUBITAK, 2024). Ayrıca, Boğaziçi Üniversitesi Kandilli Rasathanesi ve Deprem Araştırma Enstitüsü, Marmara Denizi'nde tsunami erken uyarı sistemleri kurarak, depremler sonrası oluşabilecek tsunamileri çok disiplinli bir yaklaşımla takip etmeyi hedeflemektedir. Kandilli Rasathanesi ve Deprem Araştırma Enstitüsü (KRDAE) bünyesinde kurulan Bölgesel Deprem ve Tsunami İzleme ve Değerlendirme Merkezi (BDTİM), ülkemizi çevreleyen denizlerde meydana gelebilecek depremler ve tsunamiler için hızlı bilgi üreten ve gerçek zamanlı gözlemler yapan ulusal bir merkezdir. 2012 yılından bu yana, UNESCO'nun Kuzey-Doğu Atlantik, Akdeniz ve Bağlantılı Denizler Tsunami Erken Uyarı Sistemi'ne (ICG/NEAMTWS) dahil olarak Tsunami Hizmet Sağlayıcı statüsünde faaliyet göstermektedir (KRDAE, 2024). *TUDES* kapsamında, Harita Genel Müdürlüğü ile iş birliği içinde deniz seviyesi ölçüm istasyonları geliştirilmiştir. Ayrıca, Ortadoğu Teknik Üniversitesi ile iş birliği içinde tsunami modelleme çalışmaları yürütülmekte ve afet yönetim birimleriyle entegre bir şekilde olası senaryolar için erken uyarılar sağlanmaktadır. Ancak, sistemlerin etkinliğini artırmak için özellikle kıyı taşkınlarına yönelik verilerin uzun vadeli izlenmesi ve modelleme kapasitesinin güçlendirilmesi gerekmektedir. Tüm bunların yanı sıra doğrudan kıyı taşkınları için hazırlanan tahmin modelleri ve erken uyarı sistemleri mevcut değildir.

2. METODOLOJİ

Yapay zekâ (AI), makinelerin öğrenme, problem çözme ve karar verme gibi insan zekâsını taklit etme yeteneği olarak tanımlanır (Poole, Goebel, & Mackworth, 1998). Bu teknoloji, sağlık hizmetlerinden finansa, eğitimden üretim sektörüne kadar birçok alanda devrim yaratma potansiyeline sahiptir. Yapay zekanın pratik uygulamaları, basit görevlerin otomatikleştirilmesinden karmaşık karar verme süreçlerine kadar geniş bir yelpazeyi kapsar ve araştırma konuları sürekli olarak genişlemektedir. Yapay zekâ tarihi, 1950'lerde başlayan ve günümüze kadar uzanan bir evrime tanık olmuştur. Bu süreçte, yapay zekâ (AI) içinde makine öğrenimi (ML), öznelik öğrenimi ve derin öğrenme (DL) gibi çeşitli yaklaşımlar ortaya çıkmıştır (Şekil 4).



Şekil 4. Yapay zeka, makine öğrenimi ve derin öğrenme yöntemlerinin ilişkisi

Makine öğrenimi, 1950'lerden itibaren yapay zekâ (AI) alanında önemli bir araştırma dalı olarak ortaya çıkmıştır. ML, algoritmaların ve istatistiksel modellerin insan müdahalesi olmadan veri setlerinden öğrenmesini sağlar, bu da otomatik tahmin yapma ve karar verme süreçlerinde devrim yaratmıştır (Jordan & Mitchell, 2015). Makine öğrenimi sistemleri öğrenme türlerine göre;

- Denetimli öğrenme,
- Denetimsiz öğrenme,
- Yarı denetimli öğrenme,

şeklinde üç ana kategoriye ayrılır.

- Denetimli öğrenme; etiketlenmiş veri setlerini kullanarak bir modelin eğitilmesini içerir. Bu yöntemde, her veri noktası bir girdi ve bir çıktı (etiket) içerir ve model bu girdi-çıkı ilişkisini genellemeyi öğrenir. Denetimli öğrenme, spam e-posta filtreleme ve görüntü sınıflandırma gibi alanlarda etkili olarak kullanılmaktadır ve yapay zekânın en yaygın uygulama alanlarından biridir (LeCun, Bengio, & Hinton, 2015).
- Denetimsiz öğrenme; etiketlenmemiş veri setlerini analiz etmek için kullanılır. Bu yöntem, veriler içindeki gizli yapıları veya örüntüleri kümeleme (clustering) ve boyut indirgeme (dimensionality reduction) gibi tekniklerle keşfetmeye çalışır. Denetimsiz öğrenme, büyük ve karmaşık veri setlerinde anlamlı bilgiler elde etmek için kullanılsa da elde edilen sonuçların yorumlanması ve doğrulanması zor olabilir (Jordan & Mitchell, 2015).
- Yarı denetimli öğrenme hem etiketlenmiş hem de etiketlenmemiş verileri kullanarak model eğitimi gerçekleştirir. Bu yaklaşım, genellikle etiketlenmiş verinin sınırlı olduğu, ancak büyük miktarda etiketlenmemiş verinin mevcut olduğu durumlarda kullanışlıdır. Yarı denetimli öğrenme, doğal dil işleme ve görüntü tanıma gibi alanlarda uygulama bulmuştur, çünkü bu teknik, sınırlı etiketli veriden maksimum faydayı sağlamayı amaçlar (Zhu & Goldberg, 2022).

Makine öğrenimi yapay zekâ alanında devrim yaratmış olmasına rağmen, karşılaştığı temel zorluklar arasında öznitelik seçimi ve çıkarımı önemli bir yer tutmaktadır. Makine öğreniminde öznitelik çıkarımı, ham verilerden anlamlı bilgilerin (özniteliklerin) elde edilmesi sürecidir. Geleneksel makine öğrenimi yöntemleri, genellikle özellik çıkarma süreçlerine önemli miktarda manuel müdahale gerektirir. Bu süreçte, veri bilimcileri ve analistleri, modelin öğrenme sürecinde kullanılacak önemli özellikleri manuel olarak belirler ve hazırlar. Bu yaklaşım, özellikle düşük ve orta düzeyde karmaşıklığa sahip veri setlerinde etkili olabilir, ancak yüksek boyutlu verilerle çalışırken zaman alıcı ve zorlayıcı olabilir (Jordan & Mitchell, 2015). Öznitelik çıkarımı süreci, özellikle heterojen ve yapılandırılmamış veri setlerinde, önemli bilgileri belirleme ve bu bilgileri modelin anlayabileceği şekilde ifade etme konusunda zorluklar içerir. Öznitelik çıkarımı, veri ön işleme, gürültünün azaltılması ve boyut indirgeme gibi adımları içerebilir. Bu sürecin karmaşıklığı, doğru özniteliklerin seçilmesini ve modellerin etkili bir şekilde eğitilmesini zorlaştırabilir (Khalid, Khalil, & Nasreen, 2014). Öznitelik seçimi ise, algoritmanın eğitimi için kullanılacak en uygun ve etkili özniteliklerin belirlenmesi sürecidir. Bu süreç, modelin

doğruluğu ve performansı üzerinde doğrudan etkiye sahiptir ve gereksiz, yanıltıcı veya düşük bilgi içeren özniteliklerin modelden çıkarılmasını amaçlar (Guyon & Elisseeff, 2003). Öznitelik seçimi, yüksek boyutlu veri setlerinde özellikle önemlidir, çünkü boyutların laneti (Curse of Dimensionality) olarak bilinen problem, modelin eğitim sürecini yavaşlatabilir ve genelleme yeteneğini olumsuz etkileyebilir.

Derin öğrenme (DL), makine öğreniminin öznitelik seçimi ve çıkarımı ile zorluklarını aşma konusunda büyük bir potansiyel sunar. Derin öğrenme yöntemleri, öznitelik seçimi ve çıkarımı süreçlerini otomatikleştirerek, yüksek boyutlu verilerle çalışırken karşılaşılan zorlukları önemli ölçüde azaltır (LeCun, Bengio, & Hinton, 2015). Derin öğrenme modelleri, ham verileri doğrudan girdi olarak kullanabilir ve gerekli özellikleri otomatik olarak öğrenebilirler. Bu yeteneği ile derin öğrenme modelleri, özellikle görüntü ve ses tanıma, doğal dil işleme gibi alanlarda, karmaşık veri setlerinden karmaşık örüntüler ve ilişkileri öğrenebilir (LeCun, Bengio, & Hinton, 2015).

Yapay zekâ, makine öğrenimi ve derin öğrenme temelde birbirlerini tamamlamaktadırlar. Makine öğrenimi, yapay zekânın bir alt kümesi olarak görülebilirken, derin öğrenme, makine öğreniminin daha ileri bir formu olarak kabul edilir (Gupta, ve diğerleri, 2021).

2.1. Makine Öğrenimi Yöntemleri

Makine öğrenimi terimi, ilk olarak 1959 yılında IBM çalışanı ve bilgisayar oyunları ve yapay zeka alanında öncü olan Arthur Samuel tarafından ortaya atılmıştır (Samuel, 1959). Makine öğrenimi terimi, mevcut verilerden türetilen modellere dayanarak, desen tanıma, sınıflandırma ve tahmin yapmayı kolaylaştıran algoritmaların oluşturulması ve değerlendirilmesi ile ilgili konuları kapsayan bir dizi konuyu ifade eder (Tarca, Carey, Chen, Romero, & Drăghici, 2007). Makine öğreniminin asıl amacı, veriden modele giden bir yol oluşturarak, insan zekasının da başvurduğu model oluşturma sürecini taklit etmektir (Samuel, 1959). Bugün makine öğrenimi, büyük dil modellerinden bilgisayarlı görüye, konuşma tanımadan çevresel modellemeye kadar birçok alanda kullanılmaktadır.

Makine öğrenimi süreci, modelin başarılı bir şekilde eğitilip değerlendirilmesini sağlamak için bir dizi kritik adımı içerir:

- Veri Toplama ve Hazırlık: Modelin eğitilebilmesi için ham verilerin toplanması ve işlenmesi gerekmektedir. Bu aşama, eksik verilerin doldurulması, gürültülü

verilerin temizlenmesi ve verilerin uygun bir formata dönüştürülmesi gibi adımları içerir.

- **Model Seçimi:** Makine öğrenimi modelleri, çeşitli öğrenme görevlerini yerine getirebilmek için tasarlanmıştır. Bu görevler, sınıflandırma, regresyon ve kümeleme gibi farklı problemleri çözmeyi içerebilir. Bu tez çalışmasında regresyon problemi kapsamında çoklu doğrusal regresyon, destek vektör regresyonu ve rastgele orman regresyonu gibi yöntemler ele alınmıştır. Bir modelin seçimi, belirlenen amaç ve kullanılacak veri setinin niteliklerine bağlı olarak yapılır. Bu seçim süreci, projenin hedeflerine en uygun algoritmanın belirlenmesini içerir ve modelin başarısında kritik bir rol oynar.
- **Hiperparametre Optimizasyonu:** Makine öğrenimi modellerinin etkinliği, belirli hiperparametrelerin ayarlanması ile önemli ölçüde artırılabilir. Hiperparametreler, modelin öğrenme sürecini ve genel davranışını etkileyen, eğitim öncesi belirlenen parametrelerdir.
- **Eğitim:** Model eğitimi aşaması, algoritmanın veri seti üzerindeki örüntüleri ve ilişkileri öğrenmesini içerir. Bu süreçte, modelin ağırlıkları iteratif olarak güncellenir, bu da algoritmanın tahminlerinin giderek daha doğru hale gelmesini sağlar. Ağırlıkların güncellenmesi, genellikle geri yayılım algoritması gibi yöntemler kullanılarak gerçekleştirilir ve bu süreç modelin eğitim veri setindeki performansının sürekli olarak iyileştirilmesini sağlar.
- **Doğrulama ve Test:** Modelin performansını değerlendirmek için, eğitim sürecinden bağımsız olarak doğrulama ve test aşamaları gerçekleştirilir. Bu süreç, modelin daha önce görmediği veriler üzerindeki performansını ölçmek için tasarlanmıştır. Çeşitli metrikler kullanılarak yapılan bu değerlendirme, modelin gerçek dünya verileri üzerindeki etkinliğini ve güvenilirliğini test eder.

2.1.1. Çoklu Doğrusal Regresyon


Çoklu doğrusal regresyon (ÇDR), bir bağımlı değişkenin değerini, iki veya daha fazla bağımsız değişkenin bir kombinasyonu olarak tahmin etmeyi amaçlayan bir makine öğrenimi yöntemidir. Bu modelde, bağımsız değişkenler ile bağımlı değişken arasındaki ilişki,

$$Y + v = a_0 + a_1X_1 + a_2X_2 + \dots + a_nX_n \quad (1)$$

şeklinde doğrusal bir denklemle ifade edilmektedir. Burada Y bağımlı değişkeni, X_i bağımsız değişkenleri, a_i katsayıları, v bağımlı ve bağımsız değişkenler arasındaki ilişkiyi tanımlayan denklem sisteminde düzeltmeyi ifade eder. Ancak bu yöntemde birçok varsayım da bulunmaktadır. Bu varsayımlar bağımlı ve bağımsız değişkenler arasındaki ilişkinin doğrusal olduğu, düzeltmelerin birbirinden bağımsız olması gerektiği, düzeltmelerin sabit varyansa sahip olması gerektiği, düzeltmelerin normal dağılıma sahip olması gerektiği, bağımsız değişkenler arasında düşük korelasyon olması gerektiği şeklinde varsayımlardır (Osborne & Waters, 2002). Bu varsayımların sağlanması, modelin doğruluk ve güvenilirliğini önemli ölçüde etkiler. Varsayımların ihlal edilmesi durumunda, modelin tahminleri yanıltıcı olabilir ve yanlış sonuçlara yol açabilir. Modelin katsayıları a_i , bağımsız değişkenlerin bağımlı değişken üzerindeki etkisini gösterir. Bu katsayılar, değişkenlerin önem derecesini ve ilişkinin yönünü (pozitif veya negatif) belirler (Osborne & Waters, 2002).

2.1.2. Destek Vektör Regresyonu

Destek Vektör Regresyonu (DVR), sınıflandırma odaklı Destek Vektör Makineleri (DVM) algoritmasının regresyon analizlerine uyarlanmış bir versiyonudur. DVM, öncelikle Cortes ve Vapnik tarafından 1995 yılında tanıtılmış bir sınıflandırma algoritması olup, zaman içinde hem sınıflandırma hem de regresyon sorunlarını çözmek için yaygın olarak tercih edilen bir yöntemle dönüşmüştür (Cortes & Vapnik, 1995). Regresyon analizleri için özel olarak geliştirilen DVR, Drucker ve diğerleri tarafından 1997 yılında literatüre eklenmiştir (Drucker, Burges, Kaufman, Smola, & Vapnik, 1997). Bu yöntemin temel amacı, belirlenen bir marj aralığı içerisinde (ϵ) mümkün olan en az hata ile en fazla veri noktasını kapsayacak şekilde bir doğru ya da eğri fonksiyonu tespit etmektir (Şekil 5).




Şekil 5. Destek vektör regresyonu (Chanklan vd., 2018; Yavuzdogan ve Kayıkçı, 2021)

Destek Vektör Regresyonunun uygulanışı, veri setindeki her bir noktayı iki boyutlu bir uzayda temsil eden ve bu noktaları ayırmak için optimal bir hiper-düzlem ya da ayırıcı eğri bulmayı amaçlayan bir süreci içerir. Optimal ayırıcı, veri noktaları arasındaki maksimum marjı bulmayı ve böylece regresyon fonksiyonunun genellemesini en üst düzeye çıkarmayı hedefler.

Destek Vektör Regresyonu algoritmasının uygulanmasında, çekirdek (kernel) fonksiyonunun seçimi, modelin veri üzerindeki performansını ve tahmin etme kabiliyetini doğrudan etkileyen kritik bir faktördür. Çekirdek fonksiyonları, regresyon modelinin veriler arasındaki ilişkiyi nasıl yorumlayacağını ve bu ilişkileri nasıl modelleyeceğini belirlemektedir.

Doğrusal çekirdek fonksiyonu tercih edildiğinde, DVR algoritması değişkenler arasındaki doğrusal ilişkileri modellemek üzere tasarlanır. Bu, özellikle değişkenler arası ilişkinin basit ve doğrusal olduğu durumlarda tercih edilir. Ancak, gerçek dünya verileri genellikle karmaşık ve doğrusal olmayan yapılar sergilediğinden, polinomal veya Radyal Temel Fonksiyon (RTF – Radial Basis Function) gibi doğrusal olmayan çekirdek fonksiyonları daha geniş bir kullanım alanına sahiptir. Polinomal çekirdek, veriler arasındaki ilişkileri daha karmaşık polinomlar aracılığıyla modellemeyi mümkün kılmaktadır.

Radyal Temel Fonksiyon (RTF) çekirdeği ise, özellikle değişkenler arasındaki ilişkilerin oldukça karmaşık olduğu durumlarda kullanılmaktadır. RTF, veri noktaları arasındaki mesafeye bağlı olarak değişen esneklik sağlayarak, modelin veri setindeki ince desenleri ve yapıları yakalayabilmesine olanak tanır (Şekil 6). Bu esneklik, modelin eğitim sürecinde veri setindeki gürültüye karşı daha dirençli olmasını ve genelleştirme yeteneğinin artmasını sağlamaktadır.



Şekil 6. DVR algoritmasında çekirdek fonksiyonları (Yavuzdoğan ve Kayıkçı, 2021).

Çekirdek fonksiyonlarının seçimi, modelin karmaşıklığı, veri setinin boyutu ve değişkenler arasındaki ilişkilerin doğası gibi faktörlere bağlı olarak yapılmalıdır. Doğru çekirdek fonksiyonunun seçilmesi, DVR algoritmasının veri üzerinde yüksek doğrulukla regresyon tahminleri yapabilmesi için temel bir adımdır.

Bir destek vektör regresyonu aşağıdaki aşamaları içermektedir (Smola & Schölkopf, 2004; Mohandes, Halawani, Rehman, & Hussain, 2004):

- Verilerin Yüksek Boyutlu Uzaya Taşınması: Veri noktaları x , bir dönüşüm fonksiyonu ϕ kullanılarak, daha yüksek boyutlu bir öznitelik (feature) uzayına taşınır. Bu işlem, veri noktaları arasındaki doğrusal olmayan ilişkileri yakalamayı amaçlar.
- Doğrusal Regresyon Modelinin Kurulması: Yüksek boyutlu öznitelik uzayında,

$$f(x) = \sum_{i=1}^D w_i \phi_i(x) + b \quad (2)$$

şeklinde ifade edilir. Burada, w_i ve b modelin öğrenmesi gereken parametreleridir. w_i ağırlık vektörünü, b ise sapma (bias) terimini temsil eder.

- Maliyet Fonksiyonu ve Optimizasyon Süreçleri: Modelin performansını değerlendirmek için kullanılan maliyet (cost) fonksiyonu

$$R[w] = \frac{1}{N} \sum_{i=1}^N (f(x_i) - y_i)^2 + \lambda \|w\|^2 \quad (3)$$

şeklindedir. Burada, λ düzenleme (regularization) parametresi olup modelin karmaşıklığını kontrol eder. N veri noktalarının sayısıdır. Bu fonksiyon, modelin tahminlerinin gerçek değerlerden ne kadar sapabileceğini (v) ve aynı zamanda modelin ne kadar karmaşık olabileceğini (λ) dikkate alır.

- Çekirdek Fonksiyonu: DVR, çekirdek (kernel) fonksiyonlarını kullanarak yüksek boyutlu hesaplamaları kolaylaştıran bir yapıya sahiptir. DVR modeli, Lagrange çarpanları (α, α^*) kullanılarak çözülür ve

$$f(x_\alpha, \alpha^*) = \sum_{i=1}^N (\alpha_i - \alpha_i^*)k(x_i, x) + b \quad (4)$$

formunu alır. Burada, $k(x_i, x)$ çekirdek fonksiyonudur ve D -boyutlu özellik uzayında iç çarpımı tanımlar.


- Lagrange Çarpanları ve Optimizasyon Süreci: Optimizasyon aşaması,

$$R(\alpha^*, \alpha) = -\varepsilon \sum_{i=1}^N (\alpha_i^* + \alpha_i) + y_i(\alpha_i^* - \alpha_i) - \frac{1}{2} \sum_{i,j=1}^N (\alpha_i^* + \alpha_i)(\alpha_j^* - \alpha_j)k(x_i, x_j) \quad (5)$$

şeklindeki amaç fonksiyonu ile uygulanır. DVR model yapısı ve optimizasyon süreçleri hakkında daha ayrıntılı bilgiler (Smola & Schölkopf, 2004) çalışmasından elde edilebilir.

2.1.3. Rastgele Orman Regresyonu

Rastgele orman, birden fazla ağaç modelinin bir araya gelerek oluşturduğu bir sistemdir (Segal, 2004). Her bir ağaç modeli, $h(x; \theta_k)$ şeklinde ifade edilir ve $k = 1, \dots, K$ olacak şekilde numaralandırılır. Burada x , gözlemlediğimiz girdi verilerinin oluşturduğu bir vektördür ve bu vektör p uzunluğundadır. Bu vektör, belirli bir veri noktasının özelliklerini (kovaryantlar) temsil eder. θ_k ise, her bir ağaç modeli için rastgele seçilen parametrelerdir ve bu parametreler birbirinden bağımsızdır ve aynı dağılıma sahiptir. Bu sistemde, her bir ağaç kendi içinde bağımsız bir tahmin yapar ve sonuçta elde edilen tahminler bir araya getirilerek nihai bir tahmin oluşturulur (Şekil 7).



Şekil 7. Rastgele orman regresyonu algoritması (Yavuzdoğan ve Kayıkçı, 2021)

Eğitim için kullanılan veriler, her biri bir dizi öznelilik (X) ve bu özneliliklere karşılık gelen bir sonuç (Y) içeren, birbirinden bağımsız olarak seçilmiş veri noktalarından oluşur. Toplamda, bu veri noktaları $(x_1, y_1), \dots, (x_n, y_n)$ şeklinde n adet özellik ve sonuç ikilisini içerir, burada n toplam veri sayısını ve p ise her bir veri noktasındaki özellik sayısını belirtir. Regresyon durumunda, rastgele ormanın tahmini, koleksiyondaki tüm ağaçların basit ortalaması alınarak:

$$\bar{h}(x) = (1/K) \sum_{k=1}^K h(x; \theta_k) \quad (6)$$

şeklinde hesaplanır (Segal, 2004). Burada K , ağaç sayısını temsil eder. K sonsuza yaklaştıkça, Büyük Sayılar Yasası sayesinde, $E_{X,Y}(Y - \bar{h}(X))^2$ ifadesi $E_{X,Y}(Y - E_{\theta}h(X; \theta))^2$ ifadesine yakınsar. Sağ taraftaki değer, rastgele ormanın tahmin (veya genelleme) hatasını ifade eder ve PE_f^* ile gösterilir. Bu yakınsama, rastgele ormanların aşırı uyuma (overfit) yol açmadığını gösterir. Bir tek ağaç modeli için ortalama tahmin hatası $h(X; \theta)$,

$$PE_t^* = E_{\theta} E_{X,Y}(Y - h(X; \theta))^2 \quad (7)$$

şeklinde tanımlanır. Eğer her bir ağaç modeli gerçek değerlerle tam olarak örtüşecek şekilde önyargısız tahminler yapabiliyorsa, yani ağacın tahmin ettiği değerlerin ortalaması gerçek

değerlerin ortalamasına eşitse, o zaman rastgele ormanın genel tahmin hatası, tek bir ağacın tahmin hatasının bir fonksiyonu haline gelir. Bu durumda, rastgele ormanın tahmin hatası (PE_f^*), tek bir ağacın tahmin hatası (PE_t^*) ile çarpılan $\bar{\rho}$ (rho) değerine eşit veya ondan küçük olabilir.


$$PE_f^* \leq \bar{\rho} PE_t^* \quad (8)$$

Burada $\bar{\rho}$, farklı ağaç modelleri arasındaki tahmin farklılıklarının ne kadar benzer olduğunu ölçen bir değerdir; yani, iki farklı ağaç modelinin hataları arasındaki ilişkinin gücünü ifade eder. Eğer bu hatalar birbirinden bağımsız ve çeşitliyse (yani, birbirleriyle düşük korelasyona sahipse), $\bar{\rho}$ değeri düşük olur ve bu da rastgele ormanın genel tahmin hatasının tek bir ağacın tahmin hatasından daha düşük olabileceğini gösterir. Başka bir deyişle, rastgele orman algoritması, birbirleriyle fazla benzer olmayan birçok ağacın tahminlerini birleştirerek daha doğru sonuçlar elde edebilir (Segal, 2004).

2.2. Yapay Sinir Ağları

Yapay sinir ağları (YSA), biyolojik sinir hücrelerini model olarak geliştirilen ve verilerden öğrenmeye dayalı hesaplama sistemleridir (Han, Kim, Kim, & Youn, 2018). Biyolojik sinir hücrelerinde (nöronlar) olduğu gibi, yapay sinir ağlarında da bilgi, nöronlar arasında ağırlıklar (weights) üzerinden aktarılır ve nöronların birbirine bağlanması sinapsları taklit eden bağlantılarla sağlanır (Şekil 8). Literatürde en yaygın kullanılan model, çok katmanlı algılayıcı (Multi-Layer Perceptron, MLP) yapısıdır. MLP, girdi katmanı (input layer), bir veya birden fazla gizli katman (hidden layers) ve çıkış katmanından (output layer) oluşur (Bishop, 2016). İki veya daha fazla gizli katmana sahip ağlar derin sinir ağları (deep neural networks) olarak adlandırılır.

Her bir yapay nöron, kendisine gelen girdileri belirli bir ağırlıklandırma işleminden geçirir ve ardından bir aktivasyon fonksiyonu aracılığıyla çıktı üretir. Bu çıktı diğer nöronlara giriş olarak aktarılır ve bu şekilde ağ içerisinde ileri yayılım (forward propagation) adı verilen süreç gerçekleşir.



Şekil 8. Biyolojik sinir hücresi (solda) ve yapay sinir ağı (sağda)

2.2.1. İleri Yayılım (Forward Propagation)

İleri yayılım, yapay sinir ağının veri işleyerek çıktı ürettiği aşamayı tanımlar. Ağa verilen girdi verileri (örneğin $x_1, x_2, \dots, x_n$) katmanlar boyunca ilerlerken, her nöron bu girdi değerlerini kendi ağırlıkları w_i ve sapma değeri b ile birleştirerek

$$z = \sum_{i=1}^n w_i x_i + b \quad (9)$$

şeklinde bir toplam girişi hesaplar. Buradaki z , nöronun aktivasyon fonksiyonuna girecek lineer kombinasyon değeridir. Aktivasyon fonksiyonu $f(\cdot)$ ile çıktı:

$$y = f(z) = f(\sum_{i=1}^n w_i x_i + b) \quad (10)$$

şeklinde bulunur. Bu işlem, ağ içindeki her katmanda tekrarlanır. Ağın son katmanında üretilen çıktılar, ağın o anki tahmin (veya çıktı) değerlerini temsil eder (Goodfellow, Bengio, & Courville, 2016). Böylece ileri yayılım aşamasında ağın girdi verisi için oluşturduğu çıktı hesaplanmış olur.


2.2.2. Aktivasyon Fonksiyonları

Yapay sinir ağlarının lineer olmayan problemleri çözebilme kapasitesi, aktivasyon fonksiyonlarının kullanımı sayesinde ortaya çıkar (LeCun, Bengio, & Hinton, 2015). Aktivasyon fonksiyonları, bir nöronun girdilerinin lineer bileşimini doğrusal olmayan bir çıktıya dönüştürür. Yaygın olarak kullanılan aktivasyon fonksiyonları arasında sigmoid, tanh, ReLU (Dikdörtgensel Lineer Birim) ve softmax fonksiyonları bulunur (Şekil 9) (Tablo 2).

Tablo 2. Sıklıkla kullanılan aktivasyon fonksiyonları ve formülasyonları

Fonksiyon Adı	Fomülasyon	Açıklama
Sigmoid	$\sigma(x) = \frac{1}{1 + e^{-x}}$	Çıktıları 0 ile 1 arasına sıkıştırır.
Tanh	$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$	Çıktıları -1 ile 1 arasına sıkıştırır.
ReLU	$f(x) = \max(0, x)$	Negatif değerler için 0, pozitif değerler için doğrusal çıktı üretir.
Softmax	$\text{Softmax}(z_i) = \frac{e^{z_i}}{\sum_j e^{z_j}}$	Çok sınıflı sınıflandırma problemlerinde kullanılır. Çıktıları olasılık dağılımına dönüştürür.

Aktivasyon fonksiyonlarının seçimi, ağın performansında belirleyici rol oynar. Her fonksiyonun farklı avantaj ve dezavantajları bulunduğundan, problemin türüne ve veri setine bağlı olarak en uygun seçimin yapılması önemlidir (Goodfellow, Bengio, & Courville, 2016).



Şekil 9. Sıklıkla kullanılan aktivasyon fonksiyonları

2.2.3. Öğrenme Süreci ve Geri Yayılım (Backpropagation)

Yapay sinir ağları, sahip oldukları ağırlıkların ve sapma değerlerinin öğrenme adı verilen bir iteratif optimizasyon süreci ile düzenlenmesi sonucu hedef fonksiyona göre iyileştirilir. Bu süreçte hedef, ağıın çıktıları ile gerçek değerler arasındaki farkı en aza

indirmektir. Öğrenme, iteratif (tekrarlamalı) bir optimizasyon süreci şeklinde ilerler. Öğrenme döngüsü şu adımlardan oluşur:

1. İleri yayılım (forwardpropagation): Girdi verisi ağdan geçirilir ve tahminler ($\hat{y}$) üretilir.
2. Hata hesaplama: Gerçek değerler (y) ile tahminler ($\hat{y}$) karşılaştırılarak hata fonksiyonu hesaplanır.
3. Geri yayılım (backpropagation): Hata fonksiyonunun her bir ağırlığa göre türevleri zincir kuralı ile hesaplanarak her bir ağırlığın hataya katkısı bulunur.
4. Parametre güncelleme: Gradyanlar kullanılarak ağırlıklar optimize edilir.

Örneğin herhangi bir w ağırlığı için güncelleme:

$$w^{(t+1)} = w^{(t)} - \eta \cdot \frac{\partial E}{\partial w} \quad (11)$$

şeklinde. Burada η öğrenme hızını (learning rate), $\frac{\partial E}{\partial w}$ ise hata fonksiyonunun ilgili ağırlığa göre gradyanını ifade eder. Bu işlem tüm katmanlarda tekrarlanarak ağırlık parametreleri kademeli şekilde güncellenir (Rumelhart, Hinton, & Williams, 1986).

2.2.4. Hata Fonksiyonu (Loss Function)

Öğrenme sırasında ilk adım, hata (loss) veya maliyet (cost) fonksiyonunun tanımlanmasıdır. Bu fonksiyon, eğitim sırasında eğitim ve doğrulama aşamalarında ağırlık ürettiği çıktı (model tahmini) ile beklenen gerçek çıktılar (gözlem değerleri) arasındaki farkı sayısal olarak ölçer. Aşağıda bu tez çalışmasında kullanılan hata fonksiyonu olan Ortalama Kare Hata ile birlikte yaygın olarak kullanılan bazı diğer hata fonksiyonları da formülasyonlarıyla açıklanmıştır:

- Ortalama Karesel Hata (OKH) (Mean Squared Error, MSE)

Regresyon problemlerinde sıklıkla kullanılır. Hesaplaması ve türev alması görece kolay olduğundan geri yayılım algoritmalarında sıklıkla tercih edilen ortalama kare hata,

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

şeklinde hesaplanır.

- Mutlak Hatalar Ortalaması (MHO) (Mean Absolute Error – MAE)

Gerçek ve tahmin edilen değerler arasındaki farkların mutlak değerlerinin ortalamasını alır. OKH'ye kıyasla uç değerlere karşı daha az duyarlıdır:

$$MHO = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (13)$$

- Huber Kaybı (Huber Loss)

OKH ve MHO fonksiyonlarının avantajlarını birleştirmeyi amaçlayan bir fonksiyondur. Hatalar küçük olduğunda OKH gibi, büyük olduğunda ise MHO gibi davranır. Huber Kaybı,

$$L_{\delta}(a) = \begin{cases} \frac{1}{2}a^2 & \text{eğer } |a| \leq \delta \\ \delta(|a| - \frac{1}{2}\delta) & \text{eğer } |a| > \delta \end{cases} \quad (14)$$

şeklinde hesaplanır. Bu tez çalışmasında hata fonksiyonu olarak OKH tercih edilmiştir. Diğer hata fonksiyonları ise farklı veri yapıları, model türleri ve hedefler doğrultusunda tercih edilebilir. Bu fonksiyonlara ilişkin daha fazla detay için temel çalışmalara bakılabilir (Goodfellow, Bengio, & Courville, 2016; Rumelhart, Hinton, & Williams, 1986).

Ağın çıktı katmanında hesaplanan hata değeri, geri yayılım algoritması yardımıyla katmanlar arasından ters yönde dağıtılır. Temel mantık, zincir kuralı (chain rule) kullanılarak her bir ağırlığın hata fonksiyonuna katkısını kademeli olarak bulmaktır. Böylece her nöronun ağırlıkları ve sapma değerleri, ağın son çıktısındaki hatanın ne kadarlık bölümünden sorumlu olduğu ölçüsünde güncellenebilir.

Örnek olarak, herhangi bir ağırlık w için ağırlık güncellemesi,

$$w_{\text{yeni}} = w_{\text{eski}} - \eta \frac{\partial E}{\partial w} \quad (15)$$

şeklinde yapılır. Burada η öğrenme hızı (learning rate) olarak adlandırılan, tipik olarak küçük değerler alan bir sabittir. $\frac{\partial E}{\partial w}$, ilgili ağırlığın toplam hataya göre kısmi türevidir. Geri yayılım sürecinde her katmandaki tüm ağırlıklar bu kural temelinde güncellenir (LeCun, Bengio, & Hinton, 2015). Öğrenme hızı (η) hiperparametresi, güncelleme adımlarının büyüklüğünü belirler. Çok büyük bir öğrenme hızı, eğitim sürecinde dalgalanmalara ve hatta ağın

sapmasına neden olabilirken, çok küçük bir öğrenme hızı ise eğitim sürecini gereksiz yere uzatabilir ve yerel minimumlarda takılma riskini artırabilir (Goodfellow, Bengio, & Courville, 2016).

2.2.5. Optimizasyon Algoritmaları

Öğrenme sürecinde geri yayılım sadece gradyanın hesabıyla sınırlı kalmaz; ağırlıkların nasıl ve ne hızla güncelleneceğini belirleyen optimizasyon algoritmaları da kritik öneme sahiptir. En temel yöntem Stokastik Gradyan İnişi (Stochastic Gradient Descent, SGD) olmakla birlikte, yaygın olarak kullanılan bazı optimizasyon algoritmaları aşağıda özetlenmiştir.

- Stokastik Gradyan İnişi (SGD): SGD, her iterasyonda küçük bir örnek kümesi (mini-batch) üzerinden hesaplanan gradyanları kullanarak ağırlıkları günceller. Bu yöntem basit ve hesaplaması görece kolaydır; ancak genellikle dengesiz ve dalgalı güncellemeler yapabilir (Goodfellow, Bengio, & Courville, 2016).
- Momentum: Momentum, SGD'yi ivmelendirmek için önceki adımlardan gelen gradyan bilgisini bir momentum terimiyle birleştirir. Böylece lokal minimumlarda sıkışma veya dalgalı güncellemeler azaltılarak daha kararlı ve hızlı yakınsama elde edilir.
- RMSProp: RMSProp, her bir ağırlık için gradyan karelerinin ortalamasını takip ederek güncelleme adımını adaptif hale getirir. Böylece öğrenme hızı her parametreye göre ayrı ayrı ayarlanır ve dalgalanmalar kontrol altına alınır (Tieleman & Hinton, 2017).
- Adam (Adaptive Moment Estimation): Adam, Momentum ve RMSProp yöntemlerinin avantajlarını birleştirerek hem birinci (ortalama) hem de ikinci (varyans) momentleri izler. Birçok problemde hızlı ve kararlı yakınsama sağlaması nedeniyle sıklıkla tercih edilen bir yöntemdir (Kingma & Ba, 2017).
- Adadelta: Adagrad'ın öğrenme hızının zamanla çok fazla küçülmesi sorununa çözüm olarak önerilen Adadelta, güncelleme boyutunu sabit tutmayı hedefler (Zeiler, 2012). Her ağırlık için adaptif bir ölçek faktörü kullanarak hem yığılma (accumulation) problemini hafifletir hem de yerel minimumlarda hareket kabiliyetini artırır (Zeiler, 2012; Ruder, 2016).

- AdamW: AdamW, Adam algoritmasına ağırlık çürütme (weight decay) terimini daha doğru şekilde ekleyerek aşırı uyumu (overfitting) azaltır. Temel Adam yönteminin düzenlileştirme (regularization) ile daha tutarlı bir şekilde birleşimi olarak görülebilir (Loshchilov & Hutter, 2017).

2.3. Derin Öğrenme Yöntemleri

Derin öğrenme, yapay sinir ağlarının çok katmanlı yapılarla genişletilmesiyle geliştirilen ve verilerdeki karmaşık örüntüleri öğrenme kapasitesi yüksek olan bir makine öğrenmesi alt alanıdır. Özellikle büyük veri kümeleriyle çalışırken, klasik yöntemlerin çıkarım gücünü aşan performanslar sergileyebilmesi nedeniyle günümüzde görüntü işleme, doğal dil işleme, konuşma tanıma ve zaman serisi analizi gibi birçok alanda yaygın olarak kullanılmaktadır. Derin öğrenme modelleri, veriden otomatik olarak anlamlı özellikler öğrenerek manuel özellik (öznitelik) çıkarımı ihtiyacını azaltır ve veriye özgü örüntüleri kendiliğinden keşfedebilir. Bu bölümde, derin öğrenme yaklaşımlarından özellikle sıralı veri modellemede kullanılan yöntemlere odaklanılacaktır.


2.3.1. Tekrarlayan (Yinelemeli) Sinir Ağları

Tekrarlayan veya yinelemeli sinir ağları (Recurrent Neural Networks, RNN'ler) zaman serisi verileri, doğal dil işleme ve her türlü sıralı veri ile çalışmak için özellikle tasarlanmış olan yapay sinir ağlarıdır (Elman, 1990). Bu ağların temel özelliği, her adımda gelen bilgiyi önceki adımların bilgisiyle (gizli durum – hidden state) birleştirerek işleme yeteneğidir. Bu yetenek, RNN'leri zaman serisi verisi, doğal dil metinleri, konuşma sinyalleri gibi sıralı ve zamanla ilişkili veriler için uygun bir araç haline getirmektedir. RNN'ler, her bir zaman adımında gelen girdi ile birlikte, önceki adımdan elde edilen durum bilgisini de kullanarak

$$h_t = f(W_{xh}x_t + W_{hh}h_{t-1} + b) \quad (16)$$

şeklinde çıktı üretir. Burada h_t zaman adımı t 'deki gizli durum, x_t zaman adımı t 'deki girdi, W_{xh} girdiden gizli katmana ağırlıklar, W_{hh} önceki gizli durumdan şu anki gizli duruma ağırlıklar, b sapma terimi, f aktivasyon fonksiyonudur. Bu formülasyonla, h_{t-1} önceki zaman

adımının gizli durumu, mevcut girdi x_t ile birleştirilir ve yeni bir gizli durum h_t üretilir (Şekil 10).



Şekil 10. RNN Hücre Yapısı

Bu süreç, ağı her bir zaman adımında tekrarlanır. İşte bu gizli durum yani "hafıza" mekanizması, RNN'leri diğer yapay sinir ağlarından ayıran en belirgin özelliktir ve onlara geçmiş bilgileri anlamlandırma ve gelecek tahminlerinde bulunma kapasitesi verir (Elman, 1990). İleri beslemeli sinir ağları (Feedforward Neural Networks) ve evrişimli sinir ağları (CNN) genellikle sabit boyutlu girdi ve çıktıları işlerken, RNN'ler değişken uzunluktaki veri dizilerini işleyebilme esnekliğine de sahiptir.

RNN'lerin öğrenme süreci, geri yayılım algoritması kullanılarak gerçekleştirilir; ancak, zaman serisi verisi ile çalışıldığı için, bu süreç "zamanla geriye yayılım" (Backpropagation Through Time, BPTT) olarak adlandırılır. BPTT, ağı hata gradyanlarını hem zaman hem de katmanlar boyunca geriye doğru yayarak ağırlıkları günceller. Gradyan, çok değişkenli bir fonksiyonun her bir değişkenine göre türevlerinin vektörüdür. Makine öğrenmesi ve derin öğrenme bağlamında, gradyanlar bir hata fonksiyonunun (loss function) ağırlıklara (model parametrelerine) göre türevlerini ifade eder. Gradyan, modelin eğitimi sırasında ağırlıkların nasıl güncellenmesi gerektiğini belirler ve böylece modelin performansını iyileştirmeyi amaçlar. Makine öğrenmesinde, genellikle bir modelin eğitimi sırasında bir hata fonksiyonunun minimumunu bulmak hedeflenir. Hata fonksiyonu, modelin tahminlerinin gerçek değerlerden ne kadar farklı olduğunu ölçer. Modeli eğitirken amaç, bu kaybı minimize ederek modelin tahminlerini gerçek değerlere mümkün olduğunca yaklaştırmaktır. Gradyanlar, işte bu optimizasyon sürecinde kritik bir rol oynar. Bir hata fonksiyonu $L(\theta)$ ve model parametreleri θ (ağırlıklar) olduğunda, θ 'ya göre L 'nin gradyanı

$$\nabla_{\theta} L(\theta) \quad (17)$$

şeklinde ifade edilir. Burada ∇_{θ} gradyan operatörüdür ve $L(\theta)$ 'nin her bir θ_i parametresine göre kaski türevlerini içeren bir vektördür. Bu vektör, hata fonksiyonunun parametre uzayındaki en dik iniş yönünü gösterir. Gradyan iniş (gradient descent) yöntemiyle, ağırlıklar

$$\theta_{yeni} = \theta_{eski} - \eta \nabla_{\theta} L(\theta) \quad (18)$$


şeklinde güncellenir. Burada η öğrenme hızıdır ve adım büyüklüğünü belirler. Gradyanın (∇_{θ}) işareti, hata fonksiyonunun ($L(\theta)$) minimumuna doğru olan yönü gösterirken, gradyanın büyüklüğü adımın ne kadar büyük olacağını belirler. Öğrenme hızı, bu adımın büyüklüğünü ayarlamak için kullanılır.

Tekrarlayan Sinir Ağları (RNN), sıralı veriler üzerinde etkileyici performanslar sergileyebilmelerine rağmen, uzun dönemli bağımlılıkları öğrenme konusunda ciddi zorluklarla karşılaşabilirler. Bu zorlukların en önemlilerinden ikisi, "patlayan" ve "yok olan" gradyan problemleridir. Bu sorunlar, RNN'lerin eğitim sürecini zorlaştırır ve modelin performansını olumsuz etkiler. Eğitim sırasında, ağırlık çıktısındaki hata, ağırlık matrisleri aracılığıyla geriye doğru yayılırken, gradyanlar zamanla azalabilir. Bu durum, özellikle uzun dizilerde, ağırlık başlangıç kısımlarına doğru gradyanların neredeyse sıfıra inmesine ve dolayısıyla bu kısımlardaki ağırlıkların güncellenememesine neden olur. Sonuç olarak, model uzun dönemli bağımlılıkları öğrenmekte zorlanır. Matematiksel olarak, aktivasyon fonksiyonu olarak sigmoid veya tanh kullanıldığında, bu fonksiyonların türevleri 0 ile 1 (veya -1 ile 1) arasında değerler alır (Hochreiter & Schmidhuber, 1997). Zamanla geriye yayılım sırasında, bu türevlerin çarpımı hızla küçülür ve gradyanlar yok olur. Yok olan gradyan problemine benzer şekilde patlayan gradyan problemi ise, gradyanların aşırı büyüyerek sayısal istikrarsızlıklara neden olması durumudur (Pascanu, Mikolov, & Bengio, 2013). Bu problem, özellikle derin RNN yapılarında ve uzun dizilerle çalışırken görülür. Patlayan gradyanlar, ağırlık güncellemelerinin aşırı büyük olmasına ve modelin öğrenememesine veya istenmeyen davranışlar sergilemesine yol açar. Her iki sorun da RNN'lerin etkinliğini ciddi şekilde sınırlar ve bu sorunların üstesinden gelmek için geliştirilen uzun-kısa süreli bellek (LSTM) gibi mimariler, derin öğrenme alanında önemli ilerlemelere yol açmıştır.

2.3.2. Uzun Kısa Süreli Bellek Ağları ve Mimarisi

Uzun Kısa Süreli Bellek (Long Short-Term Memory - LSTM) ağlarının tarihsel gelişimi ve temel fikri, 1990'ların ortalarına, özellikle Hochreiter ve Schmidhuber'in (1997) bu modeli önermesine dayanır. Bu öncü çalışma, RNN'lerin uzun vadeli bağımlılıkları öğrenirken yaşadığı sorunları çözmek amacıyla geliştirilmiştir, özellikle uzun süreli bilgileri saklama ve ihtiyaç duyulduğunda bu bilgilere ulaşma yeteneğini geliştirmek üzerine odaklanmıştır. LSTM ağları bilgiyi uzun süreler boyunca hatırlayabilen ve unutma mekanizması sayesinde gereksiz bilgileri silebilen özel bir bellek hücresine sahiptir. Bu özellikler LSTM ağlarını zaman serisi tahmini, konuşma tanıma ve doğal dil işleme gibi birçok alanda popüler bir seçenek haline getirmiştir. Bir LSTM modeli uzun vadeli bağımlılıkları öğrenebilen özel bir Tekrarlayan Sinir Ağları (RNN) sınıfıdır (Hochreiter & Schmidhuber, 1997). Geleneksel RNN'ler teorik olarak herhangi bir uzunluktaki sekans (zamana bağlı) bağımlılıklarını öğrenebilme kapasitesine sahip olmalarına rağmen, pratikte yok olan gradyan veya patlayan gradyan problemleri nedeniyle uzun vadeli bağımlılıkları öğrenmekte zorlanırlar. Öte yandan LSTM ağları, geleneksel RNN'lerin bu zorluklarını aşmak için özel olarak tasarlanmıştır. LSTM birimleri hücre içerisinde bilgiyi uzun süreler boyunca saklayabilen bir yapıya sahiptir. Bu yapının temel bileşenleri, unutma kapısı (forget gate), giriş kapısı (input gate) ve çıkış kapısı (output gate)'dir (Şekil 11). Unutma kapısı, hücrenin eski bilgileri ne kadarının unutulacağını belirler; giriş kapısı, yeni bilginin hücre durumuna (cell state) ne kadar ekleneceğine karar verir; çıkış kapısı ise hücre durumundan hangi bilgilerin sonraki katmanlara veya çıktıya aktarılacağını kontrol eder (Chung, Gulcehre, Cho, & Bengio, 2014). Bu kapılar sayesinde LSTM ağları uzun vadeli bağımlılıkları etkili bir şekilde öğrenebilir ve kaybolan gradyan probleminden pek fazla etkilenmez.

LSTM ağlarının bu özellikleri sayesinde doğal dil işleme, konuşma tanıma, zaman serisi tahmini gibi birçok alanda geleneksel RNN'lere göre daha etkili bir araç haline gelmiştir. LSTM'lerin geliştirilmesi, sekans verileriyle çalışırken karşılaşılan uzun vadeli bağımlılık problemlerine yenilikçi bir çözüm sunmuş ve derin öğrenme modellerinin uygulama alanlarını genişletmiştir. Bu avantajlar, LSTM ağlarını geleneksel RNN'lerin ötesine geçen ve daha karmaşık sekans bağımlılıklarını modelleyebilen güçlü araçlar haline getirir.



Şekil 11. LSTM Hücre Yapısı

Giriş Kapısı (I_t), çıkış kapısı (O_t), unut kapısı (F_t), gizli durum (h_t) ve hafıza hücresine (C_t) ait eşitlikler,

$$F_t = \sigma(W_{fh}h_{t-1} + W_{fx}x_t + b_f) \quad (19)$$

$$I_t = \sigma(W_{ih}h_{t-1} + W_{ix}x_t + b_i) \quad (20)$$

$$O_t = \sigma(W_{oh}h_{t-1} + W_{ox}x_t + b_o) \quad (21)$$

$$C_t = f_t \cdot c_{t-1} + i_t \cdot \tilde{c}_t \quad (22)$$

$$h_t = o_t \cdot \tanh(C_t) \quad (23)$$


şeklinde verilmiştir (Yu, Si, Hu, & Zhang, 2019). Denklem 18’de Unutma kapısı (F_t), geçmiş hücre durumundan (c_{t-1}) hangi bilgilerin silineceğini belirleyen bir mekanizmadır. Burada σ sigmoid fonksiyonunu, W_{fh} ve W_{fx} unutma kapısı ağırlıklarını, h_{t-1} önceki gizli durumu, x_t mevcut girdiyi ve b_f unutma kapısına ait sapmayı temsil eder. Denklem 19’da Giriş kapısı (I_t), mevcut girdi ve önceki gizli durumun birleşiminden elde edilen bilginin, ne kadarının hücre durumuna aktarılacağını belirler. Burada, W_{ih} ve W_{ix} giriş kapısı ağırlıkları, b_i ise giriş kapısına ait sapmayı temsil eder. Denklem 20’de çıkış kapısı (O_t), sonraki gizli durumun (h_t) hesaplanmasında kullanılacak hücre durumunun (C_t) ne kadarının dışarı aktarılacağını kontrol eder. Burada W_{oh} ve W_{ox} çıkış kapısı ağırlıkları, b_o ise çıkış kapısına ait sapmayı temsil eder. Denklem 21’de hücre durumu (C_t), geçmiş hücre durumu (c_{t-1}) ve mevcut hücre adayı ($\tilde{c}_t$) arasında bir birleşimdir. burada f_t unutma kapısı çıktısı, i_t giriş kapısı çıktısıdır. Denklem 22’de son gizli durum h_t , çıkış kapısı çıktısı o_t ve hücre durumunun (c_t) tanh fonksiyonu ile aktivasyonu kullanılarak hesaplanır (Yu, Si, Hu, & Zhang, 2019).

2.3.3. Yığılmış (Stacked) Uzun Kısa Süreli Bellek Ağları

Yığılmış LSTM ağları, birden fazla LSTM katmanını içeren derin öğrenme modelleridir. Bu yapı, her bir katmanın önceki katmandan gelen bilgiyi daha ileri bir seviyeye taşımasını ve daha karmaşık özelliklerin öğrenilmesini sağlar. Bu ağlar, geleneksel tek katmanlı LSTM modellerine kıyasla, daha yüksek düzeyde soyutlama ve veri içerisindeki daha karmaşık desenleri tanıma kabiliyetine sahiptir (Hochreiter & Schmidhuber, 1997; Chung, Gulcehre, Cho, & Bengio, 2014).

Yığılmış LSTM'ler, özellikle doğal dil işleme (NLP), konuşma tanıma, zaman serisi tahmini ve video işleme gibi alanlarda avantajlıdır. Bu modeller, uzun vadeli bağımlılıkları ve karmaşık zamansal bağımlılık yapılarını öğrenmede tek katmanlı LSTM'lere göre daha etkili olduğu birçok çalışmada gösterilmiştir (Chen, ve diğerleri, 2022; Westhausen & Meyer, 2020).

Yığılmış LSTM modelinde genel olarak bir katmanın LSTM hücrelerinin çıktısı, başka bir katmanın LSTM hücrelerine girdi görevi görmektedir. Bu süreç, modele daha derin bir öğrenme kapasitesi kazandırır ve verilerde mevcut olan karmaşık ilişkilerin daha ayrıntılı öğrenilmesine yardımcı olur. Modelin ilk katmanı, verileri girdi olarak alır ve bir sonraki katmana iletilecek öznitelik vektörleri üretir. Bu sırada LSTM hücrelerinin kapı mekanizmaları hangi bilginin unutulacağına, neyin hatırlanacağına karar verir. Her ara katman, zaman serisi verilerinin daha karmaşık özelliklerini öğrenmek için önceki katmandan gelen bilgileri daha da işler. Ara katmanların sayısı modelin karmaşıklığı ve öğrenme kapasitesiyle doğrudan ilişkilidir. Son katman, bir LSTM katmanı veya bir yoğun (dense) katmanı olabilir. Ara katmanlardan bilgiler son katmana akar ve çıktı katmanı bu bilgilerden nihai çıktıyı üretir. Bir yığılmış LSTM modelinin genel yapısı Şekil 12'de verilmiştir.



Şekil 12. Yığılmış LSTM model yapısı

Yığılmış LSTM ağlarının eğitimi, derin öğrenme projelerinde karşılaşılan en zorlu süreçlerden biridir. Bu süreçte modelin karmaşık zamansal (sekans) verilerinden bilgi öğrenmesi ve genelleme yapabilmesi amaçlanır. Ancak, model eğitimi sırasında aşırı uyum (overfitting), yetersiz uyum (underfitting) ve uzun eğitim süreleri gibi zorluklarla karşılaşılabilir. Bu zorlukların üstesinden gelmek için çeşitli stratejiler geliştirilmiştir.

- Eksiltme (Dropout) Stratejisi: Aşırı uyum, modelin eğitim veri setindeki gürültüyü veya ayrıntıları fazla öğrenmesi ve bu nedenle yeni verilere iyi genelleme yapamaması durumu olarak belirtilir. Bu sorunu çözmek için eksiltme (dropout) teknikleri yaygın olarak kullanılır. Eksiltme, eğitim sırasında rastgele seçilen nöronların etkinliğini geçici olarak durdurarak, modelin belirli nöronlara aşırı bağımlı hale gelmesini önler. Bu yöntem, modelin daha genel bir yapıda olmasını sağlar ve genelleme kabiliyetini artırır.

- Gradyan Kesme (Gradient Clipping): Patlayan gradyan, eğitim sırasında gradyanların kontrolsüz bir şekilde büyümesi ve model ağırlıklarının aşırı değerlere ulaşması durumudur. Bu problem, modelin istikrarsızlaşmasına ve öğrenme sürecinin bozulmasına neden olabilir. Gradyan kesme, gradyanların belirli bir eşik değerini aşmasını önleyerek bu sorunu çözmek için kullanılan bir tekniktir. Bu yöntem, gradyanların belirli bir maksimum değere sınırlanmasını sağlar ve böylece modelin daha stabil bir şekilde öğrenmesine katkıda bulunur.

- Ağırlık Düzenlemeleri: Model ağırlıklarının düzenlenmesi, aşırı uyumun önlenmesine yardımcı olabilir. L1 ve L2 düzenleme (regularization), makine öğrenimi modellerinde aşırı uyumu önlemek için kullanılan tekniklerdir. Bu


düzenlileştirmeler, modelin ağırlıklarına ceza puanı uygulayarak ağırlıkların çok büyük değerlere ulaşmasını engeller. L1 düzenlileştirmesi, ağırlıkların mutlak değerlerinin toplamını ceza puanı olarak eklerken, L2 düzenlileştirmesi, ağırlıkların karelerinin toplamını kullanır. Bu yöntemler, modelin daha dengeli ve genelleme kabiliyeti yüksek olmasını sağlar. Bu iyileştirme stratejileri, yığılmış LSTM ağlarının eğitimi sırasında modelin performansını optimize etmek ve daha iyi sonuçlar elde etmek için büyük öneme sahiptir. Modelin eğitim sürecini ve sonuçlarını iyileştirmek için bu tekniklerin doğru bir şekilde uygulanması, derin öğrenme modellerinin başarısında önemli bir faktördür.

- **Hiperparametre Optimizasyonu:** Bu aşamada yığılmış LSTM modellerinin performansını doğrudan etkileyen hiper parametrelerinin optimizasyonu konu alınır. Bu aşama, modelin veri üzerinde nasıl öğrendiğini ve nasıl genelleme yaptığını önemli ölçüde etkileyebilir. Özellikle katman sayısı, hücre sayısı, öğrenme oranı ve yığın (batch) boyutu gibi hiperparametreler, modelin karmaşıklığını ve eğitim sürecinin verimliliğini doğrudan etkiler.

2.3.4. Oto-Kodlayıcı (Auto-Encoder) Modeller ve Mimarileri

Oto-kodlayıcı modeller girdi verisini bir temsil veri (latent representation) düzeyine indirgeyen ve ardından bu temsili kullanarak orijinal girdiyi yeniden oluşturmaya çalışan ağlar olarak tanımlanabilir (Goodfellow, Bengio, & Courville, 2016). Oto-kodlayıcı modeller ilk olarak Kramer tarafından Temel Bileşen Analizinin (Principal Component Analysis, PCA) lineer olmayan bir genelleştirmesi olarak sunulmuştur (Kramer M. A., 1991). İlk uygulaması ise 1993 yılında Hinton ve Zemel tarafından veri setlerinden öznitelik çıkarımı ve boyut indirgeme amacıyla kullanılmıştır (Hinton & Zemel, 1993). Oto-kodlayıcıların yapay sinir ağları ve derin öğrenme alanındaki yeri ve önemi zamanla artmıştır. Başlangıçta basit öznitelik çıkarma araçları olarak görülürken, günümüzde derin öğrenme modellerinin önemli bir bileşeni haline gelmişlerdir (Bengio, Courville, & Vincent, 2013). Derin öğrenme alanındaki ilerlemelerle birlikte, oto-kodlayıcılar daha karmaşık veri yapılarını öğrenebilir ve çeşitli uygulama alanlarında etkili çözümler sunabilir hale gelmiştir (Brand, Seiler, & Kaup, 2021; Gong, Mansour, Venkatesh, & Hengel, 2019). Özellikle görüntü işleme, dil modelleme, anomali tespiti, gürültü azaltma gibi alanlarda kritik roller üstlenmişlerdir. Son yıllarda, oto-kodlayıcıların yapısı üzerine de çeşitli iyileştirmeler yapılmıştır. Örneğin, varyasyonel oto-kodlayıcılar (VAE'ler) ve koşullu varyasyonel oto-

kodlayıcılar (CVAE'ler), modelin gizli temsil alanını daha iyi yönetmesine olanak tanır. Bu modifikasyonlar, oto-kodlayıcıların daha geniş bir uygulama alanına sahip olmasını sağlamıştır (Kim, Kong, & Son, 2021; Yin, Zhang, Wang, & Xiong, 2020). Genel bir oto-kodlayıcı yapısı Şekil 13'te verilmiştir.



Şekil 13. Oto-kodlayıcı genel yapısı

- Kodlayıcı (Encoder) Mimari

Kodlayıcı mimari girdi olarak aldığı yüksek boyutlu veri setlerini daha düşük boyutlu bir temsil alanına (latent space) dönüştürme işlevi görmektedir. Bu dönüşüm sırasında verinin özünü veya en önemli özniteliklerini sıkıştırılmış bir formatta korur. Kodlayıcı mimari tarafından gerçekleştirilen bu dönüşüm modelin veri setindeki karmaşıklığı anlamasına ve önemli öznitelikleri öğrenmesine olanak tanımaktadır. Küçük boyuta sıkıştırılmış öznitelik vektörleri sayesinde özellikle büyük ve karmaşık veri setleriyle çalışırken veri işleme ve model eğitimi süreçleri önemli ölçüde hızlanmaktadır. Ayrıca daha düşük boyutlu bir temsil kullanımı modelin gürültülere karşı daha dayanıklı olmasını sağlamakta ve aşırı uyum riskini azaltmaktadır. Kodlayıcı mimariler birçok farklı alanda değerli araçlar olarak kendilerini kanıtlamışlardır. Görüntü sıkıştırma, veri görselleştirme ve boyut azaltma, kodlayıcı mimarinin sıklıkla kullanıldığı uygulama alanlarındadır. Örneğin, yüz tanıma sistemlerinde kodlayıcı insan yüzlerini temsil eden yüksek boyutlu görüntüleri, benzersiz ve sıkıştırılmış bir vektör haline getirerek işlemektedir.

- Dar Boğaz (Gizli Vektör) Mimarisi

Dar boğaz (gizli vektör) mimarisi, derin öğrenme modellerinde, özellikle de otomatik kodlayıcılar ve çeşitli sinir ağı yapılarında karşılaşılan bir mimaridir. Bu mimari yüksek boyutlu girdi verisinin, modelin temel özelliklerini taşıyan daha düşük boyutlu bir vektör halinde tutulmasını sağlar. Bu vektörde verinin önemli özellikleri korunurken, gürültü gibi gereksiz bilgilerin büyük bir kısmı atılır. Dar boğaz mimarisi sayesinde modelin daha etkin öğrenmesini sağlanarak, aşırı uyuma (overfitting) karşı dirençli modeller elde edilebilir. Dar boğaz mimarisi birçok farklı alanda uygulama bulmuştur. Örneğin görüntü işleme, ses işleme ve doğal dil işleme gibi alanlarda veri rekonstrüksiyonu, gürültü azaltma ve boyut indirgeme işlemleri için kullanılmaktadır.

- Kod-Çözücü Mimari

Kod çözücü mimari, oto-kodlayıcı modellerde dar boğaz (gizli vektör) tarafından elde edilen düşük boyutlu temsil verisini alarak orijinal girdiyi yeniden oluşturmaya çalışır. Bu süreçte, kod çözücü, kodlayıcının tersine işlev görerek veriyi katmanlar boyunca genişletir ve başlangıçtaki veri boyutuna ulaştırır (Goodfellow, Bengio, & Courville, 2016). Bu sayede model, verinin önemli özelliklerini kullanarak orijinal girdiye mümkün olduğunca yakın bir çıktı üretmeyi hedefler.

Kod çözücü mimarinin etkinliği, modelin genel performansı ve yeniden oluşturma kabiliyeti için kritik öneme sahiptir. Kod çözücü, gizli temsildeki bilgileri kullanarak verinin karmaşık yapısını yeniden inşa eder ve bu süreçte öğrenilen özelliklerin genelleştirilmesine katkı sağlar (Hinton & Salakhutdinov, 2006). Özellikle görüntü işleme, ses işleme ve doğal dil işleme gibi alanlarda, kod çözücü mimariler yüksek boyutlu verilerin etkili bir şekilde yeniden oluşturulmasına olanak tanır.


Kod çözücü mimariler, farklı uygulama alanlarına ve ihtiyaçlara göre çeşitli modifikasyonlara tabi tutulmuştur. Örneğin, Varyasyonel Oto-Kodlayıcılarda (Variational Autoencoders, VAE) kod çözücü, olasılıksal bir yaklaşım benimseyerek gizli uzaydan örneklenen verileri yeniden oluşturur (Kingma, 2013). Bu yaklaşım, yeni veri örneklerinin üretilmesine ve veri dağılımının daha iyi anlaşılmasına imkan tanır.

Ayrıca, kod çözücü mimariler gürültü azaltma, veri tamamlama ve anomali tespiti gibi uygulamalarda da kullanılmaktadır. Örneğin, Gürültü Azaltıcı Oto-Kodlayıcılarda (Denoising Autoencoders) kod çözücü, gürültülü girdilerden temiz veriler üretmek için kullanılır (Vincent, Larochelle, Bengio, & Manzagol, 2008). Anomali tespitinde ise kod

çözücü, normal verileri yüksek doğrulukla yeniden oluştururken anormal verilerde başarısız olarak bu verilerin tespit edilmesine yardımcı olur (Zhou & Paffenroth, 2017).

2.3.5. Evrişimli Uzun Kısa Süreli Bellek Ağları ve Mimarisi

Evrişimli Uzun Kısa Süreli Bellek Ağları (Convolutional Long Short-Term Memory, ConvLSTM), hem zamansal (temporal) hem de konumsal (spatial) özelliklerin aynı anda modellenmesini sağlayan bir derin öğrenme mimarisidir (Şekil 14). Bu yöntem, standart Uzun Kısa Süreli Bellek (LSTM) ağlarının zaman serilerindeki bağımlılıkları öğrenme kapasitesini, Evrişimli Sinir Ağları'nın (CNN) konumsal özellikleri yakalama becerisiyle birleştirerek yüksek boyutlu ve dinamik veri setlerinde önemli avantajlar sunmaktadır (Shi, ve diğerleri, 2015).



Şekil 14. ConvLSTM hücre yapısı

ConvLSTM, LSTM'nin temel işleyiş mantığını benimser ancak LSTM'den farklı olarak, giriş, unutma ve çıktı kapılarında (input, forget, output gates) tam bağlantılı (fully connected) matris çarpımları yerine evrişimsel işlemleri (convolutions) kullanır. Böylece, zaman içinde değişen konumsal paternler öğrenilir. Modelin bir hücresindeki temel işlemler şu şekildedir:

- Girdi (X_t): Modelin aldığı konumsal ve zamansal bilgiyi içerir (örneğin, ardışık zamanlarda alınan görüntüler veya haritalar).
- Gizli Durum (H_t): Modelin bir önceki zaman adımındaki bilgileri taşıdığı durum.
- Hücre Durumu (C_t): Uzun vadeli bağımlılıkları temsil eder ve zaman içindeki bilgiyi aktarır.
- Evrimsel Kapılar (f_t, i_t, o_t): Modelin bilgi akışını düzenlemek için kullanılan mekanizmalar.

ConvLSTM 'in işleyişi, aşağıdaki denklemlerle ifade edilir (Shi, ve diğerleri, 2015):

- Unutma Kapısı: Geçmiş bilgilerin ne kadarının korunacağını belirleyen unutma kapısı,

$$f_t = \sigma(W_f * X_t + U_f * H_{t-1} + b_f) \quad (24)$$

şeklinde ifade edilir.

- Giriş Kapısı ve Aday Hücre Durumu: Yeni hücreye ne kadar bilginin dahil edileceğini ifade eden giriş kapısı (i_t) ve aday hücre durumu ($\tilde{C}_t$),

$$i_t = \sigma(W_i * X_t + U_i * H_{t-1} + b_i) \quad (25)$$

$$\tilde{C}_t = \tanh(W_c * X_t + U_c * H_{t-1} + b_c) \quad (26)$$

şeklinde ifade edilir.

- Hücre Durumu Güncellemesi: Unutma ve giriş kapılarının etkisiyle hücre durumu

$$C_t = f_t \odot C_{t-1} + i_t \odot \tilde{C}_t \quad (27)$$

şeklinde güncellenir.

- Çıkış Kapısı ve Gizli Durum: Modelin çıktı bilgilerini kontrol eden Çıkış Kapısı (o_t)

$$o_t = \sigma(W_o * X_t + U_o * H_{t-1} + b_o) \quad (28)$$

şeklinde hesaplanır. Bu eşitlikte H_t ise gizli durumu temsil eder. Burada *, evrimsel işlemi; $\odot$, eleman bazlı çarpımı ifade eder. Parametreler (W, U, b), öğrenme sırasında optimize edilen ağırlık ve sapmaları ifade eder.

2.4. Derin Öğrenme Uygulamalarında Hiperparametre Optimizasyonu

Hiperparametreler, bir makine öğrenimi veya derin öğrenme modelinin performansını doğrudan etkileyen; ancak modelin eğitimi sırasında veri üzerinden otomatik olarak öğrenilmeyen, eğitim öncesinde belirlenmesi gereken dışsal parametrelerdir (Goodfellow, Bengio, & Courville, 2016). Başka bir deyişle, hiperparametreler modelin ön tanımlı mimari ve optimizasyon özelliklerini şekillendiren başlangıç noktalarını ve çerçevelerini oluştururlar. Bu parametrelerin seçimi, modelin kapasitesini, yakınsama hızını ve genelleme yeteneklerini derinlemesine etkiler. Örneğin, öğrenme oranı (learning rate), gizli katman (hidden layer) sayısı, aktivasyon fonksiyonlarının türü ve optimizasyon algoritması gibi faktörler, hiperparametre setinin önemli bileşenleridir. Aynı zamanda, düzenleme (regularization) parametreleri, mini-yığın (batch) boyutu ve veri artırma (data augmentation) stratejilerinin seçimi de sıklıkla hiperparametre optimizasyonlarını gerektiren konular arasında yer alır (Hastie, Tibshirani, & Friedman, 2009; Géron, 2019).

Hiperparametrelerin doğru bir şekilde belirlenmesi, modelin performansını anlamlı ölçüde iyileştirebilmekte, eğitim sürecini hızlandırabilmekte ve test verisi üzerindeki genelleme başarısını artırabilmektedir. Yanlış seçilen hiperparametreler ise modelin aşırı uyum (overfitting) veya yetersiz öğrenme (underfitting) problemleri ile karşı karşıya kalmasına neden olabilir. Örneğin, aşırı büyük bir öğrenme oranı modelin optimizasyon sürecinde yerel minimumlara yaklaşmasını engellerken, çok küçük bir öğrenme oranı eğitimin çok yavaş ilerlemesine veya modele zamanla yanlış yönelmelere yol açabilir. Benzer biçimde, gereğinden fazla katmana veya nörona sahip bir model, karmaşıklığı nedeniyle aşırı uyuma meyilli olabilirken, çok küçük bir ağ boyutu karmaşık örüntüleri yakalamakta yetersiz kalabilir (Hastie, Tibshirani, & Friedman, 2009; Goodfellow, Bengio, & Courville, 2016).

2.4.1. Hiperparametre Optimizasyon Teknikleri

Hiperparametre optimizasyonu, modelin performansını maksimuma çıkarmak amacıyla farklı hiperparametre kombinasyonlarının sistematik, yarı-otomatik veya tamamen otomatik bir şekilde araştırılması işlemidir.

Yarı otomatik yöntemler, araştırmacının belirli hiperparametre aralıklarını veya kombinasyonlarını manuel olarak seçtiği, ardından sınırlı bir arama sürecinin

gerçekleştirildiği yaklaşımlardır. Örneğin, kullanıcı önce öğrenme oranı için dar bir aralık belirler ve bu aralıkta farklı değerler denenir. Benzer şekilde, gizli katman sayısı veya nöron sayısı gibi parametreler araştırmacının ön bilgisine dayanarak kademeli olarak değiştirilir. Bu yöntemler, araştırmacının sezgilerini ve deneyimini sürece dahil etmesi açısından avantajlı olabilir. Ancak, dezavantajları arasında sürecin oldukça zaman alıcı olması, parametreler arasındaki etkileşimleri gözden kaçırma ihtimali ve insan hatasına açık olması sayılabilir. Ayrıca yarı otomatik yöntemlerde global optimum yerine yalnızca lokal çözümlere ulaşılması sık karşılaşılan bir durumdur.

Buna karşılık tam otomatik yöntemler, araştırmacının minimum müdahalesiyle hiperparametre arama sürecini sistematik veya akıllı algoritmalar aracılığıyla yürütür. Bu yöntemler arasında Izgara Arama, Rastgele Arama ve Bayes Optimizasyonu gibi yöntemler öne çıkmaktadır.

- **Izgara Arama (Grid Search):** Bu yaklaşımda, her bir hiperparametre için belirlenmiş değer aralıklarının tüm olası kombinasyonları değerlendirilir. Bu yöntem basit, sistematik ve anlaşılır olsa da yüksek boyutlu ve geniş aralıklı hiperparametre uzaylarında hesaplama maliyeti (zaman ve işlemci gücü) hızla artar (Bergstra & Bengio, 2012). Özellikle derin öğrenme modellerinde çok sayıda hiperparametre ve geniş aralıklar söz konusu olduğunda, ızgara araması pratik olmaktan çıkar.
- **Rastgele Arama (Random Search):** Hiperparametre uzayında rastgele örnekleme yaparak belirli sayıda kombinasyon test edilir. Rastgele arama, ızgara aramasına kıyasla yüksek boyutlu problemler için daha verimli ve esnek bir yöntem sunar. Bu yöntemle, hiperparametre uzayının daha geniş bir bölgesi daha az maliyetle keşfedilebilir (Bergstra & Bengio, 2012). Ancak rastgele örnekleme sonucunda optimal hiperparametre setine ulaşamayabilir. Bu durum da bu yöntemin en büyük dezavantajlarından biridir.
- **Bayesyen Optimizasyon (Bayesian Optimization):** Bu yöntem, hiperparametre uzayında gözlemlenmiş performans ölçütlerini kullanarak bir olasılık modeli (örn. Gaussian process) oluşturur ve sonraki denemelerin nerede yapılacağına dair akıllı tahminler üretir. Böylece az sayıda deneme ile yüksek performanslı kombinasyonlara ulaşılabilir. Özellikle derin öğrenme modellerinde, Bayesyen optimizasyonun sağladığı verimlilik öne çıkmaktadır (Snoek, Larochelle, & Adams, Practical bayesian optimization of machine learning algorithms, 2012).

Bayes optimizasyonu, Bayes teoremine dayanan bir optimizasyon yöntemidir (Wu, ve diğerleri, 2019). Bayes teoremi,

$$P(A | B) = \frac{P(B|A)P(A)}{P(B)} \quad (29)$$

şeklinde tanımlanabilir. Bu denklemde A ve B sırasıyla model ve gözlemi temsil etmektedir. $P(A | B)$, modelin posterior olasılığı, $P(B | A)$, A verilmişken B'nin olasılığı ve $P(A)$, A'nın prior olasılığıdır.

Derin sinir ağları (DNN) için Bayesyen optimizasyon algoritması da şu şekilde açıklanabilir (Cho, ve diğerleri, 2020):

- Başlangıç: Optimizasyon sürecinde değerlendirilecek hiperparametre uzayı belirlenir ve başlangıçta bilgi kümesi ($\mathcal{H}$) boş olarak başlatılır.
- Hiperparametre Seçimi: Mevcut bilgiye dayanarak, değerlendirilmesi gereken yeni bir hiperparametre kombinasyonu x_n belirlenir (ilk hiperparametre seçimi rastgele olarak belirlenir). Seçim, belirlenen amaç fonksiyonu aracılığıyla;

$$x^* = \operatorname{argmax}_{x \in \mathcal{H}} f(x) \quad (30)$$

şeklinde gerçekleştirilir (Cho, ve diğerleri, 2020; Wu, ve diğerleri, 2019).

- Model Değerlendirmesi: Eğitilen modeller, belirlenen performans metriği (örneğin KOH gibi) üzerinden değerlendirilir:

$$y_n \leftarrow f(x_n) \quad (31)$$

- Bilgi Kümesinin Güncellenmesi: Önceki adımlarda elde edilen bilgiler doğrultusunda, olasılıksal bir model oluşturulur. Bu model, hiperparametre uzayının henüz keşfedilmemiş bölgelerindeki en yüksek başarı potansiyeline sahip noktaları belirleyerek, yeni örnekleme noktalarını önerir.

$$\mathcal{H} \leftarrow \mathcal{H} \cup (x_n, y_n) \quad (32)$$

- Çıkış Kriterlerinin Kontrolü: Belirlenen iterasyon sayısına ulaşıldığında veya model performansı belirlenen eşik değeri aşmadığında optimizasyon süreci sonlandırılır.

Bayes hiperparametre optimizasyon algoritması için tüm bu süreci gösteren sözde kod (Pseudo code) aşağıda sunulmuştur:

1. $\mathcal{H} \leftarrow \emptyset$
2. for $n = 1, 2, \dots$ yap
3. Seç:

$$x_n \in \operatorname{argmax}_{x \in \mathcal{X}} \hat{f}(x; \mathcal{H})$$
4. Değerlendir:

$$y_n \leftarrow f(x_n)$$
5. Güncelle:


$$\mathcal{H} \leftarrow \mathcal{H} \cup (x_n, y_n)$$
6. Çıkış Kriterlerini Kontrol Et
7. end for

Bu üç yöntem, otomatik hiperparametre optimizasyonunun en yaygın örneklerini temsil ederken, literatürde daha farklı stratejiler de bulunmaktadır. Örneğin, Genetik Algoritmalar (Genetic Algorithms) veya Evrimsel Stratejiler (Evolutionary Strategies), popülasyon tabanlı yaklaşımlar ile hiperparametre arama sürecini evrimsel mekanizmalar aracılığıyla yönlendirir. Reinforcement Learning (Pekiştirmeli Öğrenme) temelli hiperparametre optimizasyonu, modelin performans geri bildirimi üzerinden hiperparametre seçimini bir eylem-politika problemine dönüştürür (Li, Jamieson, DeSalvo, Rostamizadeh, & Talwalkar, 2018). Ayrıca, Popülasyon Tabanlı Eğitim (Population Based Training), model eğitimini ve hiperparametre seçimlerini eş zamanlı olarak güncelleyerek dinamik bir arama stratejisi sunar (Jaderberg, ve diğerleri, 2017). Son dönemde popülerleşen çok-tekdüzenli optimizasyon (multi-fidelity optimization) ve Hypergradient yöntemleri ise eğitim maliyetlerini düşürerek, daha verimli ve hızlı çözümler sağlamayı hedeflemektedir (Franceschi, Frascioni, Salzo, Grazi, & Pontil, 2018)

Hiperparametre optimizasyon süreci, iteratif bir döngü içinde gerçekleşir ve genellikle şu aşamalardan oluşur: (1) hiperparametrelerin başlangıç değerlerinin belirlenmesi, (2) modelin eğitilmesi ve doğrulama performansının ölçülmesi, (3) hiperparametre değerlerinin güncellenmesi ve (4) performans hedeflerine ulaşılan kadar bu döngünün tekrarlanması (Şekil 15).

Bu süreçte, doğrulama seti performansı bir rehber olarak kullanılır ve modelin genelleştirme kapasitesini artırmak için en uygun hiperparametre kombinasyonları bulunmaya çalışılır. Örneğin, bir öğrenme oranı (η) hiperparametre optimizasyon sürecinde,

küçük adımlarla azaltılıp artırılarak modelin öğrenme hızı optimize edilebilir. Hiperparametre arama döngüsü, özellikle Bayesyen optimizasyon veya rastgele arama gibi algoritmalarla otomatikleştirildiğinde karmaşık derin öğrenme modellerinde zamandan ve kaynaklardan tasarruf sağlar (Bergstra & Bengio, 2012; Snoek, Larochelle, & Adams, 2012).



Şekil 15. Hiperparametre optimizasyon döngüsü

Hiperparametre optimizasyon sürecinin hangi yöntem veya yöntemler kombinasyonu ile yürütüleceği; veri setinin boyutu, modelin karmaşıklığı, hesaplama altyapısının kapasitesi ve projenin zaman kısıtlamaları gibi çok sayıda faktöre bağlıdır. Kimi durumlarda basit bir ızgara araması yeterli olurken, bazı senaryolarda Bayesyen optimizasyon veya evrimsel algoritmalar gibi daha gelişkin yöntemler daha verimli sonuçlar sağlayabilir. Sonuç olarak, hiperparametre optimizasyon süreci, modern makine öğrenimi ve derin öğrenme projelerinde başarıya giden kritik bir adımdır (Hastie, Tibshirani, & Friedman, 2009; Goodfellow, Bengio, & Courville, 2016).

2.4.2. Derin Öğrenme Modellerinde Temel Hiperparametreler

Derin öğrenme modelleri, çok katmanlı yapıları sayesinde karmaşık veri kümelerinde derin örüntüleri tespit edebilme becerisine sahiptir. Ancak, bu başarının arkasında, ağ yapısından eğitim stratejilerine kadar birçok hiperparametrenin doğru seçimi yer alır. Hiperparametreler, modelin eğitimi ve genelleme performansı üzerinde doğrudan etkili olduğu için, neyi ne kadar “ayarladığımız (tuning)”, eğitimin süresi ve elde edilen sonuçlar açısından kritik önemdedir (Goodfellow, Bengio, & Courville, 2016). Bu bölümde, derin öğrenme uygulamalarında en yaygın biçimde ele alınan hiperparametreler ayrıntılı bir şekilde incelenmektedir.

- Öğrenme Oranı (Learning Rate, η)

Öğrenme oranı (learning rate), derin öğrenme modellerinin eğitiminde kullanılan gradyan tabanlı optimizasyon algoritmalarının (ör. Stokastik Gradyan İnişi – SGD, Adam, RMSProp vb.) merkezinde yer alan, sabit ya da adaptif bir katsayıdır. Bir başka deyişle, her geri yayılım (backpropagation) adımında model parametrelerinin (ağırlıklar ve sapmalar) ne kadar güncelleneceğini belirleyen anahtar hiperparametredir (Goodfellow, Bengio, & Courville, 2016; Hastie, Tibshirani, & Friedman, 2009). Bir öğrenme oranı η kullanılarak, ağırlık güncellemeleri

$$w_{\text{yeni}} = w_{\text{eski}} - \eta \cdot \nabla_w L(w) \quad (33)$$

şeklinde uygulanır. Burada w , modelin ağırlıklarını (veya sapmalarını), $\nabla_w L(w)$ hata fonksiyonunun (L) ağırlıklar (w) üzerindeki gradyanını (türevini) ifade eder. η ise güncellemenin adım büyüklüğünü kontrol eden sabit sayı olan öğrenme oranıdır.

Doğru öğrenme oranı seçimi, modelin en kısa sürede ve en istikrarlı biçimde optimuma yakın noktalar etrafında konumlanmasını kolaylaştırırken; yanlış bir öğrenme oranı, modelin ya çok yavaş ya da hiç yakınsamamasına ya da kararsız dalgalanmalara sürüklenmesine neden olabilir.

- Yığın Boyutu (Batch Size)

Makine öğrenimi ve özellikle derin öğrenme modellerinin eğitiminde, veri seti genellikle art arda küçük alt kümeler hâlinde modele tanıtılır. Yığın Boyutu, bu alt kümelerin (mini-batch’lerin) kaç örnek içereceğini belirleyen kritik bir hiperparametredir (Goodfellow, Bengio, & Courville, 2016). Eğitim aşamasında, her bir geri yayılım adımında, model

parametreleri bu yığında yer alan örneklerin ortalama hata (loss) fonksiyonu türevlerine göre güncellenir. Dolayısıyla yığın boyutu hem eğitim sürecinin karakterini hem de modelin yakınsama (convergence) ve genelleme (generalization) davranışını doğrudan etkiler.

Derin ağlar, çok boyutlu ve karmaşık bir parametre uzayında hata fonksiyonunu minimize etmek amacıyla gradyan tabanlı optimizasyon teknikleri kullanır. Eğitim sırasında her iterasyonda yapılan ağırlık güncellemesi

$$\mathbf{w}_{t+1} = \mathbf{w}_t - \eta \frac{1}{B} \sum_{i \in I} \nabla_{\mathbf{w}} \mathcal{L}(\mathbf{w}_t, \mathbf{x}_i, y_i) \quad (34)$$

şeklinde tanımlanabilir (Goodfellow, Bengio, & Courville, 2016; LeCun, Bengio, & Hinton, 2015). Burada $\mathbf{w}_t$, t -inci iterasyondaki parametre vektörünü, η öğrenme oranını (learning rate), B yığın boyutunu ve I ise $|I|=B$ olacak biçimde seçilen mini-yığın indeks kümesini ifade eder. Temel olarak yığın boyutu büyüdükçe, gradyanların veri setini temsil etme gücü artar ve güncellemeler daha “pürüzsüz” hal alır. Küçük yığın boyutu ise her iterasyonda daha gürültülü (varyansı yüksek) gradyan güncellemeleriyle eğitim sürecini ilerletir; bu durum çoğu zaman modelin aşırı uyum (overfitting) yapma riskini azaltıcı bir etki yaratır.

Bununla birlikte eğitim süresi ve bellek kullanımı da yığın boyutu ile doğrudan ilişkilidir. Büyük yığın boyutu, her iterasyonda daha fazla verinin işlenmesi anlamına geldiğinden hesaplama kaynaklarını yoğun biçimde kullanır. Küçük yığın boyutu ise daha sık güncelleme ve nispeten az bellek tüketimi sağlar; ancak eğitim süresi her epok için uzayabilir veya eğitim sürecinde dalgalı bir hata grafiği ile karşılaşılabilir.

Çok büyük yığın boyutu tercih edildiğinde, model eğitimi her iterasyonda daha kararlı bir gradyan yönüyle güncellense bile, bazı çalışmalarda test seti üzerindeki başarının (genelleme yeteneğinin) görece düşük olabileceği rapor edilmiştir (Keskar, Mudigere, Nocedal, Smelyanskiy, & Tang, 2016). Bu durum, modelin keskin minimum noktalara yakınsama riskinden kaynaklanabilir. Ayrıca yüksek yığın boyutu kullanabilmek için büyük bir GPU/TPU bellek kapasitesi gerekir. Bellek kısıtlıysa, çok büyük yığın boyutu seçimi pratikte mümkün olmayabilir.

Çok küçük yığın boyutu durumunda ise eğitimin yakınsaması dalgalı hâle gelebilir; model parametreleri gradyan yönünde “zigzag” hareketlerle ilerlediğinden eğitim süresi artabilir. Bununla birlikte, bu gürültülü güncellemeler bir çeşit düzenleme (regularization) etkisi yaratarak aşırı uyumun önüne geçebilir. Yine de yığın boyutunun aşırı küçük olması

(ör. 1 veya 2), hesaplama verimliliğini düşürebilir ve modele yeterli istatistiksel bilgi kazandırmayabilir.

Örneğin, toplam 100 örnek veri olsun. Öğrenme oranı $\eta=0.01$ ve yığın boyutu $B=10$ seçildiğinde, her epok süresince 10'arlı gruplara ayrılmış toplam 10 mini-batch üzerinde güncelleme yapılır. Yani, bir epok = 10 iterasyondan oluşur. Ağırlıklar w , her iterasyonda

$$w_{yeni} = w_{eski} - 0.01 \frac{1}{10} \sum_{i=1}^{10} \nabla_w \mathcal{L}(w, x_i, y_i) \quad (35)$$

şeklinde güncellenir. Eğer yığın boyutu $B=50$ seçilseydi, her epok için toplam 2 mini-batch oluşacak ve her epok 2 iterasyonla tamamlanacaktı.

- Epok Sayısı (Epoch Number)

Derin öğrenme modellerinin eğitiminde, bir epok, tüm eğitim veri setinin model tarafından tam olarak bir kez işlenmesini ifade eder (Goodfellow, Bengio, & Courville, 2016). Örneğin, elimizde 20.000 örneklik bir veri seti varsa ve yığın boyutu 100 seçilmişse, 1 epok sırasında ardışık 100'erlik mini-batch'ler üzerinden toplam 200 güncelleme adımı (iterasyon) gerçekleştirilir. Eğitimin sonraki adımında, model aynı veri setini yeniden dolaşmaya başlar ki bu da "ikinci epok" olarak adlandırılır.

Epok sayısı, modelin veri setine ne kadar süreyle "maruz kaldığını" belirleyen kritik bir hiperparametredir. Model, düşük sayıda epok ile yetersiz öğrenme (underfitting) yaşayabilir; veri setindeki karmaşık örüntüleri tam olarak kavrayamaz. Benzer şekilde epok sayısının aşırı yüksek seçilmesi durumunda, modelin eğitim verisine aşırı uyum (overfitting) yapması ve doğrulama/test seti üzerindeki başarısının düşmesi gözlemlenebilir. Bu nedenle, epok sayısının belirlenmesi erken durdurma (early stopping) ve doğrulama seti performansının izlenmesi gibi stratejilerle yakından ilişkilidir.

Epok sayısını artırmak, modelin aynı veri setini tekrar tekrar görerek parametre güncellemelerine devam etmesi anlamına gelir. Modellerin genelde 10 ila 200 arasında epok sayısı ile eğitildiği sıklıkla gözlense de bu sayı veri kümesinin büyüklüğüne, karmaşıklığına, problem türüne (ör. görüntü sınıflandırma, dil modelleme) ve hedeflenen doğruluk seviyesine göre değişiklik gösterebilir.

Epok sayısı gereğinden fazla artırıldığında, model eğitim verisine aşırı derecede uyum sağlayabilir. Bu durum, doğrulama seti performansındaki istikrarlı yükselişin bir noktadan sonra durağanlaşıp nihayetinde kötüleşmeye başlamasıyla anlaşılır. Erken durdurma mekanizmaları, doğrulama seti hatası en iyi değerine ulaştığında eğitim sürecini kesintiye

uğratarak modelin aşırı uyuma girmesini engeller. Bu yöntem, epok sayısını doğrudan “elle” seçmek yerine otomatize bir strateji sunar.

- Dropout Oranı

Dropout, derin öğrenme modellerinde aşırı uyumu azaltmayı hedefleyen popüler bir düzenleme (regularization) yöntemidir. Özünde, eğitim aşamasında belirli bir olasılıkla nöronların (veya bağlantıların) rastgele “devre dışı bırakılması” prensibine dayanır (Srivastava, Hinton, Krizhevsky, Sutskever, & Salakhutdinov, 2014). Böylece modelin belli katmanlarında, her ileri besleme ve geri yayılım (backpropagation) adımında bazı nöronlar eğitimde etkili olmaz; bu durum, ağı tek bir detaya aşırı bağımlı kalmamasını ve daha yüksek genelleme özellikleri geliştirmesini sağlar.

Dropout hiperparametresi genellikle p harfi ile ifade edilir ve $[0, 1]$ aralığında bir değer olarak seçilir. Bir katmana $p = 0.5$ dropout uygulamak, eğitim sırasında her iterasyonda o katmandaki nöronların yarısını (rastgele seçilen) devre dışı bırakmak anlamına gelir. Daha düşük bir dropout oranı (ör. 0.2), devre dışı bırakılan nöron sayısını azaltırken, çok yüksek oranlar (> 0.7) aşırı bilgi kaybına neden olarak modelin öğrenmesini engelleyebilir.

Eğitim esnasında bazı nöronların rastgele kapatılması, ağı veriyi “öğrenirken” çok spesifik ve lokal bağımlılıklar oluşturma riskini düşürür. Böylece eğitim verisinden ziyade veri kümesindeki genel örüntülere odaklanmak zorunda kalan ağ, test verisinde daha yüksek doğruluğa ulaşma potansiyeli taşır.

- Katman Sayısı

Derin öğrenme ağlarının karakteristik özelliği, birden fazla katman içermesidir. Modelin derinliği, yani katman sayısı, öğrenebileceği fonksiyonel temsillerin karmaşıklığını ve soyutlama gücünü belirleyen en temel hiperparametrelerden biridir (Goodfellow, Bengio, & Courville, 2016). Bir derin sinir ağı, giriş katmanıya başlayıp çıkış katmanıya sonlanır ve bu iki katman arasında bulunan her katman “gizli katman” (hidden layer) olarak adlandırılır. Katman sayısı arttıkça, modeller daha karmaşık özellikler yakalayabilir.

Derin bir ağda, alt katmanlar genellikle ham veri üzerindeki basit örüntüleri (kenar, renk, frekans bileşenleri vb.) öğrenirken, üst katmanlar kademeli olarak daha yüksek seviyeli (nesne bileşenleri, semantik anlamlar vb.) temsillere ulaşır. Bu çok katmanlı mekanizma, modellenmek istenen karmaşık fonksiyonun parçalara ayrılmış biçimde öğrenilmesini olanaklı kılar. Örneğin bir görüntü sınıflandırma görevinde, ağı ilk katmanları kenar veya doku benzeri alt özellikleri öğrenirken, derinlerdeki katmanlar daha bütüncül obje temsillerine odaklanabilir (LeCun, Bengio, & Hinton, 2015).

Bu hiperparametre model mimarisini belirleyen en önemli hiperparametrelerden biridir. Katman sayısı, derin öğrenme modellerinin derinlik düzeyini belirleyerek ağıın ifade gücünü doğrudan etkiler. Fazla katman, modelin güçlü temsil kabiliyetine sahip olmasını sağlarken, aynı zamanda eğitim zorluğu, hesaplama maliyeti ve overfitting riskini de artırır. Yüksek katman sayısına sahip derin ağlarda güncellenmesi gereken ağırlık ve sapma sayıları milyonları bulabildiğinden bu parametrenin optimum bir düzeyde belirlenmesi oldukça önemlidir.

- Nöron (Birim) Sayısı

Derin öğrenme modellerinde bir katmandaki nöron (veya birim) sayısı, ağıın genişliğini belirleyen temel bir hiperparametredir. Bir gizli katmanda kaç nöron bulunduğu, o katmanın veri temsili kapasitesini ve özellik işleme gücünü doğrudan etkiler (Goodfellow, Bengio, & Courville, 2016). Bu sayı sabit veya katmandan katmana farklı nöron sayıları olarak belirlenebilir. Katmandaki nöron sayısı arttıkça, katman ile bir sonraki katman arasındaki bağlantıların (parametrelerin) sayısı da artar. Bu durum ağıın temsil gücünü büyütürken daha karmaşık fonksiyonları öğrenebilmesini sağlar. Ancak, gereğinden fazla nöron kullanan bir model, veri setine aşırı uyum (overfitting) eğiliminde olabilir ve eğitim sürecini uzatarak yüksek hesaplama maliyeti gerektirebilir. Dolayısıyla, nöron sayısı hiperparametresi, fazla seçildiğinde aşırı uyum riski ve kaynak kullanımı artarken, yetersiz seçildiğinde model karmaşık örüntüleri yakalayamayabilir.

2.5. Derin Öğrenme Uygulamalarında Verilerin Ön İşleme Süreçleri

Verilerin ön işleme (preprocessing) aşaması, ham verilerin modellenmeye hazır, temiz ve anlamlı bir yapıya dönüştürülmesi sürecini ifade eder. Bu aşama, derin öğrenme modellerinin yüksek performans elde etmesinde kritik bir rol oynamaktadır. Ham veri çoğu zaman gürültülü, eksik veya dengesiz olduğundan, uygun ön işleme adımları uygulanmadığında modelin performansı ciddi ölçüde düşebilir. Özellikle büyük veri setlerinin kullanıldığı derin öğrenme uygulamalarında, veri kalitesinin sağlanması modelin genelleştirme kapasitesi ve eğitimin kararlılığı açısından büyük önem taşır (Goodfellow, Bengio, & Courville, 2016; Géron, 2019).

Genellikle veri ön işleme sürecinde aşağıdaki adımlar izlenmektedir:

- Verilerin Normalizasyonu ve Standartlaştırılması:

Veriler farklı ölçeklere ve dağılımlara sahip olabilir. Bu durum, gradyan tabanlı optimizasyon algoritmalarının yavaşlamasına veya kararsız davranmasına yol açabilir. Verilerin belirli bir aralığa (örneğin $[0,1]$ veya $[-1,1]$) normalizasyonu veri dağılımlarını daha tutarlı hale getirir. Bu sayede eğitim süreci hızlanır ve model parametrelerinin daha kararlı şekilde güncellenmesi sağlanır (Goodfellow, Bengio, & Courville, 2016; Hastie, Tibshirani, & Friedman, 2009).

X_i bağımsız değişkenleri ve Y_i bağımlı değişkenleri için ötelenmiş değerler X'_i ve Y'_i

$$X_{i_{ort}} = \frac{[X_i]}{n} \quad Y_{i_{ort}} = \frac{[Y_i]}{n} \quad (36)$$

$$X'_i = X_i - X_{i_{ort}} \quad Y'_i = Y_i - Y_{i_{ort}} \quad (37)$$

şeklinde elde edilir. Burada n veri sayısını ifade etmektedir. X'' ve Y'' normlandırılmış değerler;

$$c_x = \sqrt{[X_i'^2]} \quad c_y = \sqrt{[Y_i'^2]} \quad (38)$$

$$X_i'' = \frac{X'_i}{c_x} \quad Y_i'' = \frac{Y'_i}{c_y} \quad (39)$$

formülleri ile hesaplanır. Böylece X_i bağımsız değişkenleri ve Y_i bağımlı değişkenleri için X_i'' ve Y_i'' ötelenmiş ve normlandırılmış değerler elde edilmiş olur. Bu yöntem literatürde L2 normalizasyon veya birim vektör dönüşümü (unit-norm transformation) olarak adlandırılmaktadır (Bishop, 2016).

Alternatif olarak sık kullanılan bir diğer normalizasyon türü ise minimum-maksimum normalizasyondur. Minimum-maksimum normalizasyonu,

$$x_{norm} = \frac{x_i - x_{min}}{x_{max} - x_{min}} \quad (40)$$

şeklinde tanımlanır (Bishop, 2016). Burada x_{norm} normalize edilmiş zaman serisinin i . Elemanını, x_i zaman serisinin i . Elemanını, x_{min} zaman serisindeki minimum değere sahip elemanı, x_{max} zaman serisindeki maksimum değere sahip elemanı göstermektedir.

- Uyuşumsuz Verilerin Ayıklanması

Veri setinde bulunan ve veri setinin dağılımından oldukça farklı olan ölçüler uyuşumsuz ölçü olarak adlandırılır. Bu ölçüler derin öğrenme modellerinin hatalı genellemeler yapmasına ve performansının düşmesine neden olabilir.

Uyuşumsuz ölçüler En Küçük Kareler Yöntemi 'ne dayalı klasik uyuşumsuz ölçü belirleme testleri (örneğin, Data-Snooping, Tau-testi(pope testi), t-testi (student testi)) kullanılarak tespit edilir. Bu değerler ya ölçü kümesinden tamamen çıkarılır ya da robust kestirim gibi yöntemler kullanılarak bilinmeyenlere olan etkisini azaltmak amacıyla ağırlıklandırılır. Sonuç olarak, uyuşumsuz veriler teker teker ya veri setinden elimine edilir ya da uygun yöntemlerle ağırlıkları düzenlenerek modelin daha kararlı bir şekilde eğitilmesi sağlanır.

Zaman serisinde T-Testi kullanılarak bir uyuşumsuz ölçü testi için her bir j ölçüsüne karşılık fonksiyonel model,

$$l + v = [A \ e_j] \begin{bmatrix} X \\ \Delta_j \end{bmatrix} \quad (41)$$

şeklinde ifade edilir (Öztürk & Şerbetçi, 1992). Bu fonksiyonel modelde Δ_j , j numaralı ölçüdeki kaba hatayı ifade ederken, l ölçüler, v düzeltmeler, A katsayılar matrisi, x bilinmeyenler ve e_j ise j . birim vektörü ifade etmektedir. Δ_j 'nin ters ağırlığı

$$q_{\Delta\Delta} = \frac{1}{e_j^T P Q_{vv} P e_j} \quad (42)$$

şeklinde hesaplanır. Δ_j ise,

$$\Delta_j = -\frac{e_j^T P v}{e_j^T P Q_{vv} P e_j} \quad (43)$$

şeklinde hesaplanır (Öztürk & Şerbetçi, 1992). Bu eşitliklerde P ağırlık matrisi, Q_{vv} ise ölçülerin ters ağırlık matrisini ifade eder. Uyuşumsuz ölçü için H_0 ve H_s hipotezleri,

$$\begin{aligned} H_0: E(\Delta_j) &= 0 \\ H_s: E(\Delta_j) &\neq 0 \end{aligned} \quad (44)$$

şeklinde kurulur. Burada H_0 hipotezi, j 'inci ölçüde anlamlı bir kaba hata bulunmadığını varsaymaktadır. Buna karşılık seçenek hipotez (H_s), j 'inci ölçüde sıfırdan farklı, anlamlı bir

kaba hata bulunduğunu ve bu nedenle ölçünün diğer ölçülerle uyumsuz olduğunu ifade etmektedir. Hipotezleri test etmek için test büyüklüğü,

$$T = \frac{|e_j^T P v|}{s_0 \sqrt{e_j^T P Q_{VV} P e_j}} \quad (45)$$

şeklinde hesaplanır. m_0 , birim ölçünün ortalama hatasının sonuç (a posteriori) değeridir. f serbestlik derecesini göstermek üzere,

$$s_0 = \pm \sqrt{\frac{1}{f-1} \left([P v v] - \frac{(e_j^T P v)^2}{e_j^T P Q_{VV} P e_j} \right)} \quad (46)$$

şeklindedir. Burada (44)'deki hesaplanan test büyüklükleri arasında en büyüğü $T_{\max}$ seçilerek iki yönlü α anlamlılık düzeyi için t tablosundan alınan $t_{f-1, 1-\frac{\alpha}{2}}$ ile karşılaştırılır. $T_{\max} \geq t_{f-1, 1-\frac{\alpha}{2}}$ koşulu sağlandığında, ilgili j . ölçü uyumsuz sayılarak ölçü kümesinden çıkarılır (Öztürk & Şerbetçi, 1992).

Zaman serisi formundaki verilerde uyumsuz ölçü tespiti ve ayıklanması için literatürde yayın kullanılan diğer bir yöntem ise k-sigma yöntemidir. Bu yöntemle göre bir gözlemin beklenen ortalamadan sapması,

$$|x_i - \mu| > k \cdot \sigma \quad (47)$$

koşulunu sağlıyorsa, bu değer uyumsuz kabul edilir (Papoulis & Unnikrishna Pillai, 2002). Aritmetik ortalama μ ve karesel ortalama hata σ ,

$$\mu = \frac{1}{n} \sum_{i=1}^n x_i \quad (48)$$

$$\sigma = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \mu)^2} \quad (49)$$

şeklinde hesaplanır. Burada x_i bir gözlem değeri, μ veri setinin ortalaması, σ ise standart sapmasıdır. Bu yöntemde, rastgele bileşene ait bir ölçünün düzeltilmiş değeri, birim ağırlıklı ölçünün ortalama hatasının k katını aşıyorsa, o ölçü uyumsuz olarak değerlendirilir. Uygulamada genellikle k sınır değeri olarak, normal dağılım tablosundan alınan ve α

yanılma olasılıklarına karşılık gelen 1.645, 2.58 veya 3.29 değerleri kullanılır. Çoğunlukla k değeri 3 olarak seçildiğinden, yöntem 3-sigma yöntemi olarak da adlandırılmaktadır. Bu işlem, modelin eğitim sürecinde daha doğru bir optimizasyon sürecinin izlenmesine ve genelleştirme kapasitesinin artırılmasına yardımcı olur (Zhang, Li, & Wang, 2019).

- Eksik Verilerin Doldurulması

Birçok gerçek veri seti eksik değerler ve boşluklar içerir. Bu eksiklikler, modelin eğitimi esnasında kullanılabilir bilginin azalmasına ve hatalı çıkarımlara neden olabilir. Eksik değerler, basit istatistiksel yöntemler (hareketli ortalama, medyan veya mod kullanımı), daha gelişmiş interpolasyon yöntemleri (k -en yakın komşu tabanlı interpolasyon, regresyon tabanlı yöntemler) veya özel eksik veri tamamlama algoritmaları ile doldurulabilir. Derin öğrenme bağlamında bazen otomatik kodlayıcı (autoencoder) tabanlı eksik veri tamamlama stratejileri de uygulanmaktadır (Van Buuren & Groothuis-Oudshoorn, 2011; Géron, 2019).

Eksik verilerin doldurulmasında en temel yaklaşımlardan biri lineer interpolasyondur. Bu yöntemde eksik değer, kendisinden önceki (x_{t-1}, y_{t-1}) ve sonraki (x_{t+1}, y_{t+1}) değerleri kullanılarak doğrusal ilişki ile tahmin edilir. Lineer interpolasyon formülü,

$$\hat{y}_t = y_{t-1} + \frac{(y_{t+1} - y_{t-1})}{(x_{t+1} - x_{t-1})} (x_t - x_{t-1}) \quad (50)$$

şeklinde ifade edilir (Junninen, Niska, Tuppurainen, Ruuskanen, & Kolehmainen, 2004). Burada y_{t-1} ve y_{t+1} , eksik değerle sırasıyla önceki ve sonraki bilinen gözlem değerlerini; x_{t-1} , x_t ve x_{t+1} ise bu gözlemlere karşılık gelen bağımsız değişken (örneğin zaman veya konum) değerlerini ifade etmektedir. Kesirli ifade $\frac{(y_{t+1} - y_{t-1})}{(x_{t+1} - x_{t-1})}$ iki bilinen nokta arasındaki doğrusal eğimi, $(x_t - x_{t-1})$ terimi ise eksik noktanın önceki bilinen noktaya olan yatay uzaklığını göstermektedir. Böylece $\hat{y}_t$ bu iki nokta arasındaki doğru üzerinde konumuna karşılık gelen tahmini değer olarak elde edilir.

Polinomal interpolasyonda ise eksik değer, komşu veri noktalarına uyan bir polinom yardımıyla tahmin edilir. Lagrange formu kullanılarak n veri noktası üzerinden inşa edilen polinom,

$$\hat{y}_t = \sum_{i=1}^n y_i \prod_{\substack{j=1 \\ j \neq i}}^n \frac{x_t - x_j}{x_i - x_j} \quad (51)$$

şeklinde yazılır ve eksik değer $\hat{y}_t = P(x_t)$ olarak hesaplanır. Burada y_i , i . bilinen gözlem değerini; x_i ise bu değere karşılık gelen bağımsız değişkeni ifade etmektedir. Çarpım sembolü içindeki $\frac{x_t - x_j}{x_t - x_j}$ terimi, Lagrange temel polinomunun i . bileşenini göstermekte olup $j \neq i$ olacak şekilde tanımlanır. Polinomal interpolasyonun özel bir durumu olan üçüncü dereceden bir kübik interpolasyon,

$$\hat{y}_t = a + b(x_t - x_i) + c(x_t - x_i)^2 + d(x_t - x_i)^3 \quad (52)$$

şeklinde tanımlanır (Junninen, Niska, Tuppurainen, Ruuskanen, & Kolehmainen, 2004). Burada a , b , c ve d katsayıları, eksik değer bulunduğ x_t konumunu çevreleyen veri noktaları kullanılarak belirlenir ve hem fonksiyon değerinin hem de türevlerinin sürekliliğini sağlayacak şekilde hesaplanır.

Zaman serilerinde sık kullanılan bir başka yöntem hareketli ortalamadır. Bu yöntemde eksik değer, belirli bir pencere genişliği w içindeki değerlerin ortalaması ile tahmin edilir. Basit hareketli ortalama için formül,

$$\hat{y}_t = \frac{1}{w} \sum_{i=1}^w y_{t-i} \quad (53)$$

şeklinde dir. Burada w , hareketli ortalamanın pencere boyutunu; y_{t-i} ise eksik değerin i adım öncesindeki gözlem değerini ifade etmektedir. Simetrik hareketli ortalama yaklaşımında ise eksik değer, kendisinden hem önce hem de sonra gelen gözlemler dikkate alınarak,

$$\hat{y}_t = \frac{1}{2w+1} \sum_{i=-w}^w y_{t+i} \quad (54)$$

şeklinde hesaplanır (Saeipourdizaj, Sarbakhsh, & Gholampour, 2021).

Daha gelişmiş yöntemlerden biri de k-en yakın komşuluk (k-Nearest Neighbors, k-NN) tabanlı interpolasyondur. Bu yaklaşımda eksik değeri doldurulacak gözlemin diğer gözlemlerle olan mesafesi (örneğin Öklid mesafesi),

$$d(x_t, x_m) = \sqrt{\sum_{l \neq t} (y_l - y'_l)^2} \quad (55)$$

formülü ile belirlenir, en küçük mesafeye sahip k komşu seçilir ve eksik değer bu komşuların ağırlıklı ortalaması ile

$$\hat{y}_t = \frac{\sum_{m \in N_k(x_t)} \frac{1}{d(x_t, x_m) + \epsilon} y_m}{\sum_{m \in N_k(x_t)} \frac{1}{d(x_t, x_m) + \epsilon}} \quad (56)$$

şeklinde hesaplanır (Junninen, Niska, Tuppurainen, Ruuskanen, & Kolehmainen, 2004). Burada y_m bilinmeyen t anındaki $\hat{y}_t$ değerinin m . Komşusunun gözlem değerini ifade ederken, $N_k(x_t)$ ise x_t konumuna en yakın k komşusundan oluşan kümedir. ϵ ise sıfıra bölme hatasını önlemek amacıyla kullanılan çok küçük pozitif bir sabittir. Böylece, tahmin edilen değer $\hat{y}_t$, komşuların değerlerinin mesafenin tersi ile ağırlıklandırılmış normalize edilmiş ortalaması olarak elde edilir.

- Kategorik Verilerin Kodlanması

Kategorik nitelikler (örneğin renk, şehir adı veya ürün kategorisi) sayısal formatlara dönüştürülmeden derin öğrenme modellerinde kullanılamaz. Bu amaçla genellikle one-hot encoding veya etiket kodlama (label encoding) tercih edilir. Ancak daha yüksek düzeyli ilişkileri yakalayabilmek için gömülü kodlamalar (embeddings) da kullanılabilir. Özellikle doğal dil işleme gibi alanlarda, embedding katmanları kategorik özellikleri düşük boyutlu, anlamlı temsillere çevirerek modelin daha zengin bir bilgi uzayında çalışmasını sağlar (Bengio, Courville, & Vincent, 2013).

- Veri Ayrımı (Eğitim, Doğrulama ve Test Setleri)

Modelin genelleme yeteneğini doğru bir şekilde ölçebilmek için veri setinin farklı alt kümelerine ayrılması gerekir. Genellikle verilerin %70-80'i eğitim, %10-15'i doğrulama (validasyon) ve %10-15'i test için ayrılır. Bu sayede modelin aşırı uyum yapması engellenir ve hiperparametrelerin seçiminde tarafsız bir geri bildirim sağlanır. Bazı durumlarda, veri miktarı kısıtlıysa k -katlı çapraz doğrulama (k -fold cross-validation) gibi yöntemler de kullanılabilir (Hastie, Tibshirani, & Friedman, 2009; Goodfellow, Bengio, & Courville, 2016).

Ek olarak, özellikle görüntü, metin veya ses verileri için veri arttırma (data augmentation) teknikleri, modelin farklı örnekleri tanıma yeteneğini zenginleştirerek overfitting riskini azaltabilir. Örneğin, görüntülerde rastgele kırpma, döndürme veya parlaklık ayarlamaları yapılırken; metinsel verilerde ise sözcük değiştirme, cümle yeniden düzenleme gibi stratejiler uygulanabilir (Shorten & Khoshgoftaar, 2019).

2.6. Derin Öğrenme Uygulamalarında Model Performans Analizi ve Metrikler

Derin öğrenme modellerinin başarısını değerlendirmek ve iyileştirmek için kullanılan performans analizleri ve metrikler, modellerin doğruluğunu, genelleştirme kapasitesini ve tahmin yeteneklerini ölçmek açısından kritik bir öneme sahiptir. Bu metrikler, modelin çıktılarının gerçek değerlerle ne kadar uyduğunu belirleyerek, modelin gücünü ve eksikliklerini objektif bir şekilde ortaya koyar (Goodfellow, Bengio, & Courville, 2016).

Performans değerlendirme süreci genel olarak test veri seti kullanılarak gerçekleştirilir. Eğitim aşamasında, model parametreleri sürekli olarak güncellenerek hata fonksiyonu (Bölüm 2.2.4'te verilen metrikler) en aza indirilmeye çalışılır. Doğrulama (validasyon) aşamasında, seçilen metrikler aracılığıyla modelin genelleştirme başarısı ve hiperparametrelerin uygunluğu değerlendirilir. Son olarak test aşaması, modelin gerçek performansını objektif bir şekilde ölçmeye imkân tanır (Hastie, Tibshirani, & Friedman, 2009). Derin öğrenme modellerinde hangi performans metriklerinin kullanılacağı; uygulama alanı, problem türü (sınıflandırma veya regresyon) ve veri seti özellikleri gibi çeşitli faktörlere bağlıdır. Yanlış veya yetersiz bir metrik seçimi, modelin hatalarını gözden kaçırmaya ya da başarısını abartmaya neden olabilir. Örneğin, sınıflandırma senaryolarında farklı boyutları öne çıkaran doğruluk (accuracy), kesinlik (precision), geri çağırma (recall) ve F1 skoru gibi metrikler sıkça kullanılırken; regresyon problemlerinde tahmin hatalarının ortalamasını veya varyansını değerlendiren mutlak hatalar ortalaması (MHO), Karese Ortalama Hata (KOH), belirleyicilik katsayısı (R^2) ve Pearson Doğrusal Korelasyon Katsayısı (r) gibi metrikler tercih edilir (Hastie, Tibshirani, & Friedman, 2009).

Performans analizinin, yalnızca bir metrik üzerinden yürütülmemesi gerektiği unutulmamalıdır. İhtiyaçlara göre birden fazla metriğin birlikte ele alınması, modelin performansını farklı açılardan değerlendirerek daha kapsamlı bir analiz yapmaya olanak tanır.

Bu bölümde, derin öğrenme modellerinde yaygın olarak kullanılan performans metrikleri ele alınacaktır. Bu metrikler Bölüm 2.2.4'te verilen metrikler ile karıştırılmamalıdır. Model performanslarını ölçmek için eğitilmiş modellerin test veri seti üzerinde yaptığı tahminler ve test veri setine ait gerçek gözlem değerleri kullanılarak bu bölümde anlatılan analizler yapılmaktadır. Buna karşın Bölüm 2.2.4'te ifade edilen hata fonksiyonları ise eğitim süresince her bir adımda (ağırlık güncellemesinde) ileri yayılım aşamasının ardından gerçek gözlem değeri ile model tahmini arasındaki farkı kullanılan metriğe göre ölçer ve ağırlıklar bu hata oranına göre geri yayılım ile güncellenir. Genel

olarak performans metrikleri kullanıldığı problemin türüne göre (sınıflandırma ve regresyon) 2 farklı sınıfta incelenebilir. Sınıflandırma problemleri için performans ölçütleri, doğruluk, duyarlık, geri çağırma ve F1 skorudur. Regresyon modellerinde kullanılan ölçütler ise mutlak hatalar ortalaması, karesel ortalama hata ve belirleyicilik katsayısı ve Pearson korelasyon katsayısıdır.

Sınıflandırma problemleri için bir duyarlılık ölçütü olan Doğruluk, modelin doğru sınıflandırdığı örneklerin toplam örnek sayısına oranıdır. Ancak, doğruluk tek başına dengesiz veri setlerinde yanıltıcı olabilir (Provost, Fawcett, & Kohavi, 1998).

$$\text{Doğruluk (Accuracy)} = \frac{\text{Doğru Pozitifler (TP)} + \text{Doğru Negatifler (TN)}}{\text{Toplam Örnek Sayısı (TP+TN+ FP + FN)}} \quad (57)$$

Burada:

TP: Doğru pozitif tahminler

TN: Doğru negatif tahminler

FP: Yanlış pozitif tahminler

FN: Yanlış negatif tahminler

Kesinlik ölçütü ise pozitif tahminlerin ne kadarının doğru olduğunu ölçer:

$$\text{Kesinlik (Precision)} = \frac{\text{Doğru Pozitifler (TP)}}{\text{Doğru Pozitifler (TP) + Yanlış Pozitifler (FP)}} \quad (58)$$

Geri Çağırma (Recall), nicel bir ölçüttür ve gerçek pozitif örneklerin ne kadarının doğru tahmin edildiğini ölçer:

$$\text{Geri Çağırma (Recall)} = \frac{\text{Doğru Pozitifler (TP)}}{\text{Doğru Pozitifler (TP) + Yanlış Negatif (FN)}} \quad (59)$$

F1 Skoru, duyarlık (precision) ve geri çağırma (recall) arasında bir denge sağlayan metriktir:

$$F1 = 2 \cdot \frac{\text{duyarlık} \cdot \text{geri çağırma}}{\text{duyarlık} + \text{geri çağırma}} \quad (60)$$

Mutlak Hatalar Ortalaması-MHO (Mean Absolute Error), modelin tahminlerinin gerçek değerlerden olan ortalama mutlak sapmasını ölçer ve eşitlik (13)'e göre hesaplanır.

R^2 (belirleyicilik katsayısı), tahmin modellerinde özellikle regresyon problemlerinde hedef (bağımlı) değişkenin toplam varyansının ne kadarının model tarafından açıklandığını nicelleştiren ve 1'e yaklaştıkça modelin veriyi daha iyi açıkladığını gösteren temel bir performans ölçütüdür. Matematiksel olarak R^2 ,

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (61)$$

şeklinde ifade edilir.

Burada:

- y_i , gerçek hedef değerini,
- $\hat{y}_i$, modelin tahmin ettiği değeri,
- $\bar{y}$, tüm gerçek değerlerin ortalamasını,
- n ise veri noktalarının sayısını ifade eder.

2.6.1. Karesel Ortalama Hata-KOH (Root Mean Squared Error- RMSE)

Karesel ortalama hata, modelin tahmin hatalarını orijinal hedef değişkenin birimi üzerinden ölçmeyi sağlar. Burada verilen karesel ortalama hata eşitlik (12)'de verilen Ortalama Kare Hata'nın kareköküdür. KOH değeri,

$$KOH = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (62)$$

şeklinde yazılır.

Burada:

- y_i : Gerçek değer
- $\hat{y}_i$: Modelin tahmin ettiği değer
- n : Veri noktalarının sayısını ifade eder.

2.6.2. Pearson Doğrusal Korelasyon Katsayısı (R)

Pearson Korelasyon Katsayısı, tahmin edilen değerlerle ($\hat{y}_i$) gerçek değerler (y_i) arasındaki lineer ilişkinin derecesini ölçmek için kullanılır. Değer aralığı -1 ile +1 arasında

değişir; +1 mükemmel pozitif lineer korelasyonu, -1 ise mükemmel negatif lineer korelasyonu ifade ederken 0, lineer bir ilişkinin olmadığını gösterir. Pearson Korelasyon Katsayısı,

$$R = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^n ((X_i - \bar{X})^2 (Y_i - \bar{Y})^2)}} \quad (63)$$

şeklinde ifade edilir.

Burada:

- X_i ve Y_i : Veri noktaları
- $\bar{X}$ ve $\bar{Y}$: Değişkenlerin ortalamaları
- n : Veri noktalarının toplam sayısını ifade etmektedir.

2.7. Derin Öğrenme Uygulamalarında Genelleştirme Analizi

Derin öğrenme modelleri, karmaşık veri kümelerinden anlamlı örüntüler çıkartma kapasitesine sahip çok katmanlı yapılar olarak tanımlanabilir. Ancak derin ağların sahip olduğu yüksek parametre uzayı ve esnek mimariler, bir modelin yalnızca eğitim verisine uyum sağlaması, bir başka deyişle aşırı uyum (overfitting) sergilemesi riskini de beraberinde getirir. Bu noktada, genelleştirme kavramı devreye girer. Genelleştirme, bir modelin yalnızca eğitim setinde değil, daha önce hiç görmediği test seti veya gerçek dünya verisinde de yüksek performans gösterme yeteneğini ifade eder (Goodfellow, Bengio, & Courville, 2016). Bu yetenek, modelin yalnızca belirli örnekleri ezberlemesi yerine, veri dağılımındaki temel yapısal ve istatistiksel örüntüleri öğrenmesi anlamına gelir.

Söz konusu genelleştirme yeteneğini ortaya koymak, ölçmek ve anlamak için yürütülen sistematik süreçler ise genelleştirme analizi başlığı altında incelenir. Genelleştirme analizi, bir derin öğrenme modelinin farklı koşullarda, farklı veri setlerinde ve dağılımlarda nasıl performans gösterdiğini değerlendirerek modelin gerçek dünya problemlerine ne derece uyum sağlayabileceğini araştırır (Hastie, Tibshirani, & Friedman, 2009). Böylece genelleştirme analizi, modelin gerçek kapasitesini, potansiyelini ve sınırlarını nesnel bir çerçevede ortaya koyar.

Bu noktada, genelleştirme olgusunun neden önemli olduğu sorusu akla gelir. Derin öğrenme modellerinin yalnızca eğitim setindeki performansına dayanarak karar vermek,

uygulanabilirlik açısından ciddi riskler barındırır. Gerçek dünyada veri daima değişkenlik gösterir; anlık veri gürültüsü, değişen koşullar veya beklenmeyen örnek tipleri karşısında modelin başarısı sorgulanabilir. Genelleştirme becerisi yüksek olan modeller, değişen veri koşulları, farklı dağılımlar ve hatta az bilinen test örnekleri karşısında istikrarlı sonuçlar vererek güvenilirliği artırır.

Genelleştirilebilir ağların avantajlı yönleri arasında, modelin eğitim verisine körü körüne uyum yapmaması, veri değişikliklerine dayanıklı olması ve böylece kullanım alanlarının genişlemesi sayılabilir. Örneğin, genelleştirilebilir bir ağ, yalnızca belirli bir kamerayla çekilmiş görüntülerde değil, farklı kamera markaları, çözünürlükler ve ışık koşulları altında elde edilen görüntüler üzerinde de başarılı olabilir. Bununla birlikte, genelleştirilebilirliği yüksek bir model elde etmek için çoğu zaman güçlü düzenleme (regularization) stratejileri, geniş veri setleri veya karmaşık mimariler kullanmak gerekebilir. Bu da hesaplama maliyetlerini yükseltebilir ve bazen eğitim sürecini zorlaştırabilir. Ayrıca, genelleştirme yeteneği yüksek modeller bazen çok genel yapılar öğrenerek belirli spesifik problemlerde optimum performansa ulaşamayabilir, çünkü spesifik bir çözüm uzayı yerine daha geniş bir çözüm uzayında hareket etme eğilimindedir.

Farklı veri kaynaklarından elde edilen veri setlerine ve farklı veri tiplerine uyum sağlayabilen bir derin öğrenme modelinin sunduğu avantajlar da bu çerçevede ele alınmalıdır. Eğer bir ağ, farklı veri kaynaklarından elde edilen çeşitli veriler üzerinde tutarlı bir performans gösterebiliyorsa, uygulama alanları genişler. Bu esneklik, araştırmacılara ve uygulayıcılara modelin yeniden tasarım ihtiyacını azaltarak proje sürecini hızlandırma, çok modelli (multimodal) entegre çözümler geliştirme ve yeni veri kaynaklarıyla beslenen dinamik sistemler kurma imkânı verir. Ayrıca, farklı veri kaynaklarını bir araya getirebilen ağlar, zayıf yönlerini diğer veri tiplerinden sağlanan tamamlayıcı bilgilerle giderebilir. Örneğin, görüntü ve metin verisini birleştiren bir model, yalnızca görsel ipuçlarına bakmaktansa metinsel açıklamalarla da desteklendiğinden daha sağlam genelleme becerisi geliştirebilir.

3. VERİ SETLERİ VE YAPILAN ÇALIŞMALAR

Bu bölümde, tez kapsamında gerçekleştirilen uygulamalar, kullanılan veri setleri ve elde edilen bulgular ayrıntılı olarak sunulmaktadır. Öncelikle, derin öğrenme yöntemlerine temel oluşturmak ve çevresel veri modelleme süreçlerinde yöntemsel deneyim kazanmak amacıyla Ege Denizi'nde iki mareograf istasyonu ve meteorolojik gözlem verileri (3.1.4. Ege Denizi Pilot Çalışma Veri Seti) kullanılarak bir pilot çalışma yürütülmüştür (Bölüm 3.2). Bu pilot çalışmada klasik makine öğrenimi algoritmalarından Çoklu Doğrusal Regresyon, Destek Vektör Regresyonu ve Rastgele Orman Regresyonu uygulanmış ve elde edilen sonuçlar karşılaştırmalı olarak değerlendirilmiştir. Pilot çalışmanın ardından tez çalışmasının ana konusunu oluşturan Karadeniz için modelleme çalışmaları yapılmıştır (Bölüm 3.3). Karadeniz'de deniz seviyesi değişimlerinin modellenmesi amacıyla DUACS veri seti kullanılarak (Bölüm 3.1.1'de verilen veri seti) yığılmış LSTM, oto-kodlayıcı LSTM ve ConvLSTM derin öğrenme mimarileri geliştirilmiş (sırasıyla Bölüm 3.3.2, Bölüm 3.3.3, Bölüm 3.3.4); ayrıca istatistiksel bir karşılaştırma yöntemi olarak sönümlü kalıcılık modeli kullanılmıştır (Bölüm 3.3.5). Ardından geliştirilen derin öğrenme modellerinin genelleştirme kabiliyetleri CMEMS radar altimetre veri seti (Bölüm 3.1.2'de verilen veri seti) ve TRAB mareograf veri seti (Bölüm 3.1.3'te verilen veri seti) üzerinde test edilmiştir (Bölüm 3.3.7). Bunun yanı sıra, Karadeniz için bir Deniz Seviyesi Erken Uyarı Sistemi geliştirilmiş ve bu kapsamda TideGuard yazılımı tasarlanarak sistemin mimarisi, arayüz özellikleri ve sistem performansını ortaya koyan simülasyon sonuçları sunulmuştur (Bölüm 3.4). Ayrıca, çevresel modelleme çalışmalarında araştırmacıların kullanımına yönelik Envilearn adlı açık kaynak kodlu derin öğrenme yazılımı geliştirilmiş, bu yazılımın arayüz tasarımı, kullanıcı deneyimi ve erişilebilirlik özellikleri ele alınmıştır (Bölüm 3.5).


Bu bölümün alt başlıklarında sırasıyla Bölüm 3.1'de kullanılan veri setleri tanıtılacak, Bölüm 3.2'de Ege Denizi üzerinde gerçekleştirilen pilot modelleme çalışması sunulacak, Bölüm 3.3'te Karadeniz'de derin öğrenme yöntemleriyle yürütülen modelleme çalışmaları ve genelleştirilebilirlik analizi aktarılacak, Bölüm 3.4'te TideGuard yazılımının tasarımı ve performans analizi verilecek ve Bölüm 3.5'te Envilearn yazılımının geliştirme süreci ve özellikleri açıklanacaktır.

3.1. Tez Çalışmasında Kullanılan Veri Setlerinin Tanıtımı ve Özellikleri

Tez çalışmasında yapılan deniz seviyesi modelleme çalışmaları için 4 farklı veri seti kullanılmıştır.

3.1.1. Veri Seti 1: Karadeniz DUACS Radar Altimetre Veri Seti

DUACS veri seti, ERS1, Topex/Poseidon, ERS2, Jason-1, Envisat, Jason-2, Cryosat, Altika, Sentinel-3A ve Jason-3 gibi uydulardan alınan ölçümleri birleştiren çok amaçlı uydu altimetre verilerini içermektedir. Özellikle Deniz Seviyesi Anomalisi (SLA) analizleri için tasarlanmış olan bu veri seti, Copernicus Dünya Gözlem Programı (CMEMS) tarafından dağıtılmakta ve güvenilirliği ile doğruluğunu sağlamak için detaylı jeofiziksel ve atmosferik düzeltmelere tabi tutulmaktadır. DUACS deniz seviyesi anomali veri seti, $1/8 \times 1/8$ derece bir konumsal çözünürlük sunmakta ve deniz seviyesi değişimlerinin detaylı mekânsal analizine olanak tanımaktadır (Şekil 16). 1993 ile 2020 yıllarını kapsayan bir zaman aralığını içeren bu veri seti, günlük ortalama anomali değerleri sağlamaktadır.




Şekil 16. Karadeniz DUACS deniz seviyesi anomali veri seti (CMEMS, 2022)

Bu veri setinde SLA değerleri -41.5 cm ile $+46.6$ cm aralığında değişmektedir. Ortalama SLA değeri $+10$ cm mertebesindedir. Bu değerler, derin öğrenme modellerinin tahmin performansının KOH metriği açısından değerlendirilmesi aşaması için önemli bilgi sağlamaktadır.

DUACS veri seti derin öğrenme modellerinde kullanılmak amacıyla eğitim, doğrulama ve test veri setlerine ayrılmıştır. Eğitim veri seti derin öğrenme modellerinin eğitiminde, doğrulama veri seti hiperparametre optimizasyonunda model performansının izlenmesinde, test veri seti ise derin öğrenme modellerinin tahmin performanslarının belirlenmesinde kullanılmıştır.

Modelin eğitimi ve test aşamalarında, veri setinin konumsal olarak eğitim, doğrulama ve test alt kümelerine ayrılması tercih edilmiştir. Bu yaklaşımın benimsenmesinin temel nedeni, LSTM modellerinin zaman serisi verileri ile çalışıyor olması ve dolayısıyla zamansal ayrımın modelin deniz seviyesi anomalileri ile ilişkili zamansal bağımlılıkları ve dinamikleri öğrenmesini sınırlayabilecek olmasıdır. Zamansal ayrım, veri dağılımında değişikliklere neden olabileceği gibi, eğitim ve test dönemleri arasında tutarsızlıklara yol açabilir. Buna karşın, konumsal ayrım, daha geniş bir zaman dilimini kapsamakta ve veri çeşitliliğini artırarak modelin farklı dönemler boyunca daha iyi genelleştirilmesini sağlamaktadır.

Bu veri seti 1 Ocak 1993 - 3 Haziran 2020 tarihleri arasındaki 10.016 günlük deniz seviyesi anomali verisi içermektedir. Her günlük kayıt 56×120 piksel konumsal çözünürlüğe sahip olup, toplamda 6720 piksel içermektedir. Bu 6720 pikselin sadece 2616 adedi deniz seviyesi anomali verisi içermektedir. Dolayısıyla her gün için 2616 farklı konuma ait (tüm Karadeniz'i kapsayan) deniz seviyesi anomali verisi bulunmaktadır. 1 Ocak 1993 - 3 Haziran 2020 tarihleri arasında 2616 pikselin her biri 10.016 veri noktasından oluşan bir zaman serisini temsil etmektedir. Dolayısıyla veri seti boyutu oldukça büyük olup, tüm veri setinin kullanımı hem zaman hem de hesaplama maliyetleri açısından oldukça zorlayıcıdır. Hiperparametre optimizasyonu için gerekli hesaplama maliyetleri ve zaman kısıtlamaları nedeniyle, veri setinin tamamının kullanılması mümkün olmamış, bu sebeple yalnızca verinin yaklaşık %30'u eğitim, doğrulama ve test aşamalarında değerlendirilmiştir. 2616 pikselin 524'ü eğitim, 131'i test ve 131'i doğrulama amaçlı kullanılmıştır. Eğitim noktaları düzenli bir ızgara üzerinde seçilirken, doğrulama ve test noktaları rastgele belirlenmiştir (Şekil 17). Veri seti, toplamda 2616 su kütlesi noktası içermekte olup, eğitim, doğrulama ve test aşamalarında bu noktaların yaklaşık %30'u (786 nokta) kullanılmıştır. Eğitim aşamasında 10.016×524 veri noktası, doğrulama ve test aşamalarında ise her biri 131×10.016 veri noktası işleme alınmıştır.




Şekil 17. Eğitim, doğrulama ve test veri setleri

3.1.2. Veri Seti 2: Karadeniz CMEMS Radar Altimetre Veri Seti

CMEMS veri seti, Avrupa Okyanus Modellemesi Çekirdeği (Nucleus for European Modelling of the Ocean - NEMO) sayısal okyanus numerik modeli temel alınarak oluşturulmuş olup, $1/40 \times 1/40$ derece gibi oldukça ayrıntılı bir konumsal çözünürlük sağlamaktadır (Jansen, ve diğerleri, 2025).

CMEMS veri seti, birden fazla uydu görevinden elde edilen uydu altimetre verilerinin yeniden analiz (reanalysis) yöntemiyle birleştirilmesiyle oluşturulmuştur. Veri seti, 23 Nisan 2021 ile 3 Mayıs 2023 tarihleri arasındaki dönemi kapsamakta olup, toplamda 741 günlük bir veri aralığı sunmaktadır (Şekil 18).

CMEMS veri setinin yüksek konumsal çözünürlüğü, Karadeniz bölgesindeki okyanus dinamikleri ve fiziksel süreçlerin daha ayrıntılı bir şekilde temsil edilmesini sağlamaktadır. Bu yüksek çözünürlük, özellikle modellerin farklı konumsal ve zamansal ölçeklerdeki genelleme yeteneklerini değerlendirmek için avantaj sunmakta, daha düşük çözünürlüklü veri setlerinde gözlenemeyen yerel özelliklerin tespit edilmesine olanak tanımaktadır.



Şekil 18. Karadeniz CMEMS deniz seviyesi anomali veri seti (Jansen, ve diğerleri, 2025).

3.1.3. Veri Seti 3: Karadeniz Mareograf Veri Seti

Karadeniz için deniz seviyesi gözlemleri yapan Trabzon ilinde konumlandırılmış, Harita Genel Müdürlüğü'ne (HGM) ait TRAB mareograf istasyonu 15 dakikalık bağıl (rölatif) deniz seviyesi gözlem verileri kaydetmektedir (Şekil 19). Burada bağıl deniz seviyesi gözlemi, deniz yüzeyinin yüksekliğinin, bulunduğu istasyona göre belirlenmiş bir referans noktasına (genellikle istasyonun bulunduğu kara parçasına sabitlenmiş bir noktaya) göre ölçülmesiyle elde edilen veriyi ifade eder. Bu tür ölçümler hem deniz seviyesindeki değişiklikleri hem de kara parçasındaki olası dikey kara hareketlerini içerebilir. TRAB istasyonunda kaydedilen deniz seviyesi verileri Türkiye Ulusal Deniz Seviyesi İzleme Sistemi (TUDES) kapsamında HGM tarafından internet sitesi aracılığıyla kullanıcılara sunulmaktadır. Tez çalışması kapsamında kullanılan veriler Trabzon (TRAB) mareograf istasyonundan alınan 1 Ocak 2023 - 31 Aralık 2023 tarihleri arasındaki 15 dakikalık deniz seviyesi ölçümleridir.



Şekil 19. TRAB Mareograf istasyonu konumu


3.1.4. Ege Denizi Pilot Çalışma Veri Seti: Ege Denizi Mareograf ve Meteorolojik Gözlem Verileri

Karadeniz'deki deniz seviyesi modellenmesine yönelik derin öğrenme temelli asıl tez çalışmasına başlamadan önce, yöntemsel bir hazırlık süreci gerçekleştirilmiştir. Bu hazırlık kapsamında, klasik makine öğrenmesi algoritmalarının deniz seviyesi modelleme performansını görmek ve modelleme sürecine hâkim olmak amacıyla, Türkiye Ulusal Deniz Seviyesi İzleme Sistemi (TUDES) kapsamında Harita Genel Müdürlüğü tarafından sağlanan Ege Denizi'ndeki Menteş ve Bodrum mareograf istasyonlarına ait bağıl deniz seviyesi verileri ve ilgili meteorolojik parametreler ile bir pilot çalışma yapılmıştır.

Bu pilot uygulama, veri ön işleme, öncül bilgi (öznitelik) çıkarımı, model eğitimi ve performans değerlendirme süreçlerinde önemli bir tecrübe kazanılmasını sağlamış; Karadeniz'e yönelik derin öğrenme modelleri geliştirilmeye başlamadan önce güçlü bir metodolojik temel oluşturmuştur. Ayrıca bu çalışma, literatüre ulusal hakemli bir makale olarak kazandırılmıştır (Yavuzdoğan & Kayıkçı, 2021). Bu bağlamda, Ege Denizi'nde yer alan Menteş ve Bodrum mareograf istasyonlarına ait verilerden yararlanılmıştır. Bu veri setinde, Türkiye Ulusal Deniz Seviyesi İzleme Sistemi (TUDES) kapsamında Harita Genel Müdürlüğü tarafından sağlanan Menteş ve Bodrum mareograf istasyonlarına ait deniz seviyesi ve meteorolojik parametrelerin verileri mevcuttur (HGM, 2019) (Şekil 20). Kullanılan veriler; deniz seviyesi, hava sıcaklığı, hava nemi, hava basıncı, rüzgâr hızı ve rüzgâr yönü gibi bileşenleri kapsamaktadır.

Elde edilen ham veriler, Ege Denizi'nde konumlanmış olan Menteş ve Bodrum istasyonlarından saatlik ölçümler şeklinde temin edilmiştir. Menteş istasyonuna ait ölçüm verileri 1999 ile 2014 yılları arasındaki dönemi kapsarken, Bodrum istasyonu için bu zaman aralığı 1999 ile 2010 yılları arasındadır. Mareograf istasyonlarının veri toplama sürelerinin farklılıkları, bölgesel ve operasyonel faktörlerden kaynaklanmaktadır.

Ayrıca, ilerideki bölümlerde bahsedileceği üzere bu verilerin doğruluğunu ve bütünlüğünü sağlamak adına istasyonların veri kalitesi kontrol süreçleri ayrıntılı olarak ele alınmış ve zaman serileri üzerinde istatistiksel değerlendirmeler yapılmıştır.



Şekil 20. Ege Denizi'nde Menteş ve Bodrum istasyonlarının konumları (Yavuzdoğan & Kayıkçı, 2021)

3.2. Derin Öğrenme Sürecine Hazırlık Ön Çalışma: Ege Denizi Pilot Modelleme Çalışması

Tez çalışmasına geçilmeden önce, makine öğrenmesi algoritmalarının deniz seviyesi değişimlerini modelleme konusundaki performanslarını değerlendirmek amacıyla, Türkiye'nin Ege Denizi kıyılarında konumlanmış iki mareograf istasyonuna ait gözlem verileri ile bir pilot uygulama gerçekleştirilmiştir. Bu çalışmanın temel amacı, deniz seviyesi verileri üzerinde klasik makine öğrenmesi yöntemlerinin uygulanabilirliğini test etmek, veri ön işleme ve modelleme süreçlerine hâkimiyet sağlamak ve sonraki aşamalarda kullanılacak derin öğrenme yaklaşımlarına yönetsel bir zemin oluşturmaktır.

Ege Denizi'nin tercih edilmesinde, bu bölgedeki meteorolojik ve oşinografik değişkenlerin çeşitliliği, saatlik çözünürlükte uzun dönemli deniz seviyesi ve meteorolojik

veri erişimi olmuştur. Pilot çalışmada, bağıl deniz seviyesi verilerine ek olarak hava sıcaklığı, nem, basınç, rüzgâr hızı ve yönü gibi parametreler de dikkate alınmıştır.

Bu kapsamda, Çoklu Doğrusal Regresyon (Bölüm 2.1.1), Destek Vektör Regresyonu (Bölüm 2.1.2) ve Rastgele Orman Regresyonu (Bölüm 2.1.3) makine öğrenme algoritmaları kullanılmış; modellerin doğrulukları çeşitli performans metrikleri ile karşılaştırmalı olarak değerlendirilmiştir. Elde edilen sonuçlar, kısa vadeli deniz seviyesi değişimlerinin kestiriminde bu yöntemlerin etkili olabileceğini göstermiştir.

Pilot çalışma sonucunda kazanılan deneyimler, bu tez kapsamında Karadeniz’e yönelik olarak geliştirilen derin öğrenme temelli modellerin veri ön işleme, model eğitimi, hiperparametre ayarı ve değerlendirme stratejileri açısından önemli bir altyapı sunmuştur.

3.2.1. Ege Denizi Pilot Uygulamada Kullanılan Makine Öğrenimi Yaklaşımları ve Uygulama Amacı

Pilot çalışmanın temel hedefi, deniz seviyesi değişimlerinin tahmininde sıklıkla kullanılan doğrusal modellerin sınırlılıklarını ortaya koymak ve daha karmaşık bağımlılık yapılarını temsil edebilen doğrusal olmayan algoritmaların bu tür çevresel verilerdeki performansını değerlendirmektir. Bilindiği üzere deniz seviyesi, yalnızca tek bir etkene değil; hava sıcaklığı, atmosfer basıncı, nem, rüzgâr hızı ve yönü gibi birçok meteorolojik faktörün bileşkesiyle şekillenen çok değişkenli ve karmaşık bir süreçtir. Bu nedenle, doğrusal modelleme varsayımlarının ötesine geçebilen, ilişkilerdeki doğrusal olmayan örüntüleri de yakalayabilen algoritmalara ihtiyaç duyulmaktadır.

Bu bağlamda çalışmada üç farklı regresyon temelli makine öğrenimi algoritması tercih edilmiştir:

- Çoklu Doğrusal Regresyon (ÇDR): Klasik bir modelleme yöntemi olan ÇDR, bağımlı değişken ile birden fazla bağımsız değişken arasındaki doğrusal ilişkiyi temsil etmeye çalışır. Bu algoritma çalışmada referans model olarak kullanılmış; doğrusal modelleme kapasitesinin sınırları gözlemlenmiş ve daha gelişmiş yöntemlerle karşılaştırma yapılabilmesi amacıyla temel oluşturmuştur.
- Destek Vektör Regresyonu (DVR): Çekirdek (kernel) fonksiyonları sayesinde doğrusal olmayan ilişkileri yüksek doğrulukla modelleyebilen DVR, özellikle karmaşık yapılar içeren çevresel verilerde sıkça tercih edilmektedir. Bu çalışmada

DVR, klasik doğrusal modellerin temsil edemediği ilişkileri öğrenme potansiyeli nedeniyle önemli bir alternatif olarak değerlendirilmiştir.

- Rastgele Orman Regresyonu (ROR): Bir topluluk öğrenme (ensemble learning) yöntemi olan ROR, çok sayıda karar ağacını birleştirerek modelleme yapar ve özellikle değişkenler arası etkileşimlerin yüksek olduğu veri kümelerinde başarılı sonuçlar verir.

Bu pilot uygulama sonucunda elde edilen bulgular, makine öğrenimi yöntemlerinin kısa vadeli deniz seviyesi tahmininde önemli bir araç olduğunu göstermekle birlikte, tez çalışması kapsamında da derin öğrenme modellerine geçişte önemli bir hazırlık süreci sunmaktadır. Ayrıca bu pilot çalışma, tez yazarları tarafından hakemli bir ulusal dergide yayımlanmıştır (Yavuzdoğan & Kayıkçı, 2021).

3.2.2. Ege Denizi Pilot Uygulamada Kullanılan Veri Setleri ve Çalışma Alanı

Bu çalışmada, Menteş ve Bodrum mareograf istasyonlarından elde edilen deniz seviyesi, hava sıcaklığı, nem, basınç, rüzgâr hızı ve rüzgâr yönü verileri, 3.1.4. bölümünde tanıtılan “Ege Denizi Pilot Çalışma Veri Seti: Ege Denizi Mareograf ve Meteorolojik Gözlem Verileri” veri setinden elde edilmiştir. Bu veri seti Türkiye Ulusal Deniz Seviyesi İzleme Sistemi (TUDES) kapsamında Harita Genel Müdürlüğü'nün resmi internet sitesi üzerinden temin edilmiştir (<https://tudes.harita.gov.tr/>, Erişim Tarihi : 06 Haziran 2019).

3.2.3. Ege Denizi Pilot Çalışma Veri Ön İşleme Süreçleri

Mareograf istasyonlarında kaydedilen saatlik deniz seviyesi verileri makine öğrenimi algoritmalarında kullanılmadan önce, çeşitli veri ön işleme süreçlerinden geçirilmelidir. Bu amaçla ilk olarak deniz seviyesi verilerdeki uyuşumsuz ölçüler araştırılmıştır. Trend, mevsimsel ve dönemsel bileşenlerden arındırılmış rastgele bileşene uygulanacak olan uyuşumsuz ölçü testi için ilk olarak doğrusal trend belirlenmelidir. Bu çalışmada doğrusal trend, *En Küçük Kareler Regresyonu (EKKR)* yöntemiyle

$$Y_i + v_i = a_0 + a_1 X_i \quad (64)$$

şeklinde hesaplanmıştır. Bu bağlamda, a_0 katsayısı, doğrusal modelin y-eksenini kestiği noktayı ifade ederken, a_1 katsayısı doğrunun eğimini temsil etmektedir. Ayrıca, v_i regresyon modeline ait düzeltme değerini, X_i bağımsız değişkeni, Y_i ise bağımlı değişkeni ifade etmektedir. EKKR'ye göre regresyon modeli için düzeltme denklemleri,

$$y + v = Ax \quad (65)$$

gibi kurulur. Burada $\mathbf{A}$ katsayılar matrisi, $\mathbf{x}$ bilinmeyenler vektörü ve $\mathbf{v}$ düzeltme vektörü

$$\mathbf{A} = \begin{bmatrix} 1 & X_1 \\ 1 & X_2 \\ \vdots & \vdots \\ 1 & X_n \end{bmatrix} \mathbf{x} = \begin{bmatrix} a_0 \\ a_1 \end{bmatrix} \mathbf{v} = \begin{bmatrix} v_1 \\ v_2 \\ \vdots \\ v_n \end{bmatrix} \quad (66)$$

şeklinde dir. Burada n , veri setinin toplam boyutunu ifade etmektedir. 65 numaralı denkleme dayanan düzeltme sistemi, En Küçük Kareler (EKK) yöntemi uygulanarak çözüldüğünde, bilinmeyen değerler

$$\mathbf{x} = (\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T \mathbf{Y} \quad (67)$$

formülü ile elde edilir. Bu eğim katsayısının istatistiksel anlamlılığını değerlendirmek amacıyla uygulanan parametre anlamlılık test istatistiği,

$$t_{a_1} = \frac{|a_1|}{m_{a_1}} \quad (68)$$

şeklinde tanımlanır. Bu test istatistiği, $\alpha = 0.05$ yanılma olasılığı ve $f = n - 2$ serbestlik derecesine sahip t dağılımından alınan tablo değeri 1.96 ile karşılaştırılmıştır. Test sonuçları, parametrenin anlamlı olup olmadığını belirlemek amacıyla kullanılmıştır. Bodrum ve Menteş mareograf istasyonlarından elde edilen a_1 eğim katsayısı ve parametre anlamlılık testi sonuçları Tablo 3 ve 4'teki gibidir.

Tablo 3. Bodrum istasyonu doğrusal trend bileşeni katsayı anlamlılık testi

a_1 Katsayısı	Test Değeri	T-Tablo Değeri	Sonuç
0.1234	38.3583	1.96	a_1 Anlamlı

Tablo 4. Menteş istasyonu doğrusal trend bileşeni katsayı anlamlılık testi

a_1 Katsayısı	Test Değeri	T-Tablo Değeri	Sonuç
0.1461	54.1474	1.96	a_1 Anlamlı

Trend bileşeninin tahmini, basit doğrusal regresyon modeli kullanılarak gerçekleştirilmiş ve bu sayede trend etkisinden temizlenmiş deniz seviyesi zaman serileri oluşturulmuştur. Ardından, harmonik bileşenlerin (Mevsimsel bileşen ve Gelgit bileşenleri) tahmini için, trend etkisinden arındırılmış bu deniz seviyesi zaman serileri üzerinde harmonik analiz uygulanmıştır.

Bağlı deniz seviyesi zaman serilerinde en önemli düzenli bileşenler astronomik gelgit bileşenleri ve mevsimsel bileşenlerdir. Bu bileşenler Harmonik Analiz gibi yöntemlerle tespit edilebilir. Astronomik gelgit bileşenleri, Tablo 5'te belirtilen bileşenler üzerinden tanımlanmaktadır (Yüksel & Esin, 2016; Yüksel, ve diğerleri, 2018; Yavuzdoğan & Kayıkçı, 2021).

Tablo 5. Astronomik gelgit bileşenleri (Yavuzdoğan & Kayıkçı, 2021)

Kaynak	Sembol	Periyot (saat)
Main lunar, yarı-günlük	M ₂	12.42
Main solar, yarı-günlük	S ₂	12.00
Lunar elliptic, yarı-günlük	N ₂	12.66
Lunar-solar, yarı-günlük	K ₂	11.97
Lunar solar, günlük	K ₁	23.93
Main lunar, günlük	O ₁	25.82
Main solar, günlük	P ₁	24.07
Lunar fortnightly (15 günlük), uzun periyotlu	Mf	327.86
Lunar monthly (aylık), uzun periyotlu	Mm	661.30

Gelgit hareketleri, meteorolojik koşullar, sığ sularda oluşan taban sürtünmesi gibi birçok farklı faktörden de etkilenmektedir. Zaman serilerindeki gelgit sinyalleri, farklı genlik ve frekanslara sahip harmonik bileşenlerin toplamı olarak ifade edilir. Bu sinyaller, yarı-günlük, günlük veya daha uzun süreli periyotlarla ortaya çıkabilir. Bir harmonik model ise

$$h_i = Z_o + at_i + \sum_{j=1}^M A_j \cos(\omega_j t_i - \theta_j) \quad (69)$$

şeklinde tanımlanabilir (Teferle, 2003; Yavuzdoğan & Kayıkçı, 2021). Gelgiti oluşturan her bir bileşenin genlik ve faz değerleri, klasik harmonik analiz yöntemleri kullanılarak hesaplanır. Bir sinyalin genlik ve faz açıları, (69) numaralı eşitlikte verilen formülün genişletilmesiyle elde edilmektedir (Sezen, 2006; Teferle, 2003; Yavuzdoğan & Kayıkçı, 2021).

$$A_j \cos(\omega_j t_i - \theta_j) = A_j [\cos(\omega_j t_i) \cos(\theta_j) + \sin(\omega_j t_i) \sin(\theta_j)] \quad (70a)$$

$$A_j \cos(\theta_j) = B_j \quad (70b)$$

$$A_j \sin(\theta_j) = C_j \quad (70c)$$

$$\omega_j = 2\pi f_j \quad (70d)$$

Kabulleri yapılarak harmonik analiz denkleminde yerine konulursa;

$$h_i = Z_0 + a(t_i - t_0) + \sum_{j=1}^M B_j \cos(2\pi f_j(t_i - t_0)) + C_j \sin(2\pi f_j(t_i - t_0)) \quad (71)$$

denklemini elde edilir. Bu denkleme göre t_0 başlangıç epogu için A katsayılar matrisi ve x bilinmeyenler vektörü Denklem 72'deki gibi yazılır. Her bir periyodik etkinin modeli, A matrisine iki sütunun eklenmesiyle temsil edilir (Sezen, 2006; Teferle, 2003; Yavuzdoğan & Kayıkçı, 2021).

$$\mathbf{A} = \begin{bmatrix} 1 & t_1 - t_0 & \sin(2\pi f_1(t_1 - t_0)) & \cos(2\pi f_1(t_1 - t_0)) \\ 1 & t_2 - t_0 & \sin(2\pi f_1(t_2 - t_0)) & \cos(2\pi f_1(t_2 - t_0)) \\ \vdots & \vdots & \vdots & \vdots \\ 1 & t_{N-1} - t_0 & \sin(2\pi f_1(t_{N-1} - t_0)) & \cos(2\pi f_1(t_{N-1} - t_0)) \\ 1 & t_N - t_0 & \sin(2\pi f_1(t_N - t_0)) & \cos(2\pi f_1(t_N - t_0)) \end{bmatrix}, \mathbf{x} = \begin{bmatrix} Z_0 \\ a \\ B_1 \\ C_1 \end{bmatrix} \quad (72)$$

En Küçük Kareler (EKK) yöntemine dayalı dengeleme işleminin sonucunda, her bir periyodik bileşen için B ve C katsayıları kullanılarak genlik ve faz açısı

$$A_j = \sqrt{B_j^2 + C_j^2} \text{ ve } \theta_j = \arctan \frac{C_j}{B_j} \quad (73)$$

şeklinde hesaplanır. Bu bağlamda, yukarıda kullanılan eşitliklerdeki terimler aşağıdaki şekilde tanımlanmıştır:

- h_i : t_i zamanında elde edilen ortalama deniz seviyesi değeri
 t_i : Başlangıç epoğundan itibaren geçen gün sayısı
 a : Doğrusal trend katsayısı
 Z_0 : Başlangıç epoğundaki ortalama deniz seviyesi değeri
 M : Modelde yer alan anlamlı gelgit bileşenlerinin toplam sayısı,
 N : Aylık toplam ortalama değerlerin sayısı,
 A_j, ω_j, θ_j : j bileşene ait sırasıyla genlik, frekans ve faz açısıdır.

Klasik harmonik analizle ilgili detaylı bilgiye Pugh (1996) çalışmasından ulaşılabilir (Pugh, 1996). Bu çalışmada, klasik harmonik analiz yöntemi kullanılarak mareograf istasyonlarında kaydedilen deniz seviyesi zaman serilerindeki mevsimsel bileşen ve gelgit bileşenleri, Pawlowicz vd. (2002) tarafından geliştirilen MATLAB tabanlı T_TIDE yazılımı ile hesaplanmıştır (Pawlowicz, Beardsley, & Lentz, 2002). T_TIDE, gelgitlere neden olan 64 temel bileşene ait sinyallerin faz, genlik ve frekans değerlerini hesaplama yeteneğine sahiptir. Bu özelliklerinden dolayı, oşinografi alanındaki çalışmalar için, özellikle genlik bileşenlerinin modellenmesinde yaygın olarak kullanılmaktadır (Arns, ve diğerleri, 2020; Costa, ve diğerleri, 2020; Juva, Flögel, Karstensen, Linke, & Dullo, 2020).

Bağlı deniz seviyesi zaman serilerindeki mevsimsel ve gelgit bileşenlerin etkisinin giderilebilmesi için zaman serilerinde bulunabilecek uzun vadeli, yıllık, yarı yıllık, aylık, iki haftalık, günlük, yarım günlük ve daha kısa süreli periyodik sinyaller incelenmiştir. Harmonik analiz sonucunda, istasyonlara ait saatlik deniz seviyesi zaman serilerinden elde edilen genlik, faz ve frekans değerleri Tablo 6 ve Tablo 7’de özetlenmiştir.

Tablo 6. Menteş istasyonunda anlamlı sinyallerin frekans, genlik ve faz değerleri


Sinyal Adı	Frekans	Genlik	Genlik Duyarlılığı	Faz	Faz Duyarlılığı
SA	0.000114	0.2238	0.09	147.03	25.37
P1	0.041553	0.0227	0.011	347.13	29.63
PSI1	0.041895	0.0213	0.013	105.85	30.58
M2	0.080511	0.0336	0.021	105.96	37.65
H2	0.080626	0.1434	0.022	96.71	8.82
T2	0.083219	0.0348	0.02	286.82	36.62
S2	0.083333	0.0336	0.023	300.17	36.4
R2	0.083447	0.0391	0.023	337.69	29.18
2MN6	0.240022	0.0051	0.003	60.33	37.08

Tablo 7. Bodrum istasyonunda anlamlı sinyallerin frekans, genlik ve faz değerleri

Sinyal Adı	Frekans	Genlik	Genlik Duyarlılığı	Faz	Faz Duyarlılığı
SA	0.000114	0.0524	0.009	109.53	9.72
O1	0.038731	0.0027	0.001	162.68	32.98
PSI1	0.041895	0.0034	0.001	230.73	22.32
H2	0.080626	0.006	0.002	352.52	19.84
R2	0.083447	0.0061	0.002	179.95	22.85
M4	0.161023	0.0001	0	203.53	44.66


Bu bağlamda, SA bir yıllık periyoda sahip mevsimsel bileşeni temsil ederken, P1, PSI1 ve O1 sinyalleri günlük periyotta gözlenen gelgit bileşenlerini ifade etmektedir. M2, H2, T2, S2 ve R2 sinyalleri yarım günlük gelgit bileşenlerini; M4 sinyali 6 saatlik gelgit bileşenini; 2MN6 sinyali ise 4 saatlik gelgit bileşenini temsil etmektedir.

Bodrum istasyonuna ait mevsimsel bileşen ve anlamlı gelgit sinyallerinin toplamından oluşan gelgit bileşeni, Şekil 21’de örnek olarak sunulmuştur.




Şekil 21. Bodrum istasyonu için mevsimsel bileşen ve gelgit bileşeni

Trend, Mevsimsel ve Gelgit bileşenlerinin zaman serisinden çıkarılmasının ardından kalan rastgele bileşene uygulanan uyumsuz ölçü testi (Denklem 47) sonucunda ölçü kümesinden çıkarılan uyumsuz ölçüler Şekil 22 ve 23’te verilmiştir.




Şekil 22. Bodrum istasyonunda elde edilen uyumsuz ölçüler




Şekil 23. Menteş istasyonunda elde edilen uyumsuz ölçüleri

Uyuşumsuz ölçülerin ölçü kümesinden çıkarılmasının ardından boş veri noktaları hareketli ortalama yöntemiyle Denklem 53'teki gibi 24 saatlik pencere boyutu kullanılarak doldurulmuştur (Şekil 24 ve 25).



Şekil 24. Bodrum istasyonu hareketli ortalama doldurulan veri noktaları (Kırmızı x işareti doldurulan veri noktalarını göstermektedir.)



Şekil 25. Menteş istasyonu hareketli ortalama doldurulan veri noktaları (Kırmızı x işareti doldurulan veri noktalarını göstermektedir.)

Çıkarılan uyuşumsuz ölçülerin hareketli ortalama yöntemi ile doldurulmasının ardından veriler makine öğrenmesi modellerine girdi olarak kullanılmadan önce, Denklem 36–39’de gösterildiği şekilde ağırlık merkezine ötelenmiş ve normalize edilmiştir. Bu işlem, veri matrislerinde ortaya çıkabilecek kondisyon bozukluklarını önlemek amacıyla uygulanmıştır.

3.2.4. Makine Öğrenimi Modellerinde Kullanılacak Öncül Bilgilerin (Öznitelik) Çıkarımı

Makine öğrenimi algoritmalarının başarısı büyük ölçüde kullanılan öncül bilgilere (öznitelik - feature), yani modele sunulan girdi değişkenlerine (bağımsız değişken) bağlıdır. Bu öncül bilgiler, modelin öğrenmesi gereken örüntüleri temsil eden ve girdi verisinden anlamlı bilgileri taşıyan bileşenlerdir. Modelin, hedef değişkenle (örneğin deniz seviyesi) olan ilişkisini doğru biçimde kurabilmesi için, bu ilişkide etkili olan faktörlerin uygun biçimde öncül bilgi olarak belirlenmesi gereklidir.

Öncül bilgi seçimi ve çıkarımı süreci, ham verilerin doğrudan modele verilmesinden çok daha etkili bir yaklaşım sunar. Çünkü bazı girdiler, yalnızca ölçülmüş değerler değil; bu değerlerden türetilmiş, daha anlamlı ve genelleştirilebilir temsillerdir. Bu işlem, veri setindeki bilginin daha iyi temsil edilmesini sağlar ve modelin hem doğruluğunu hem de genellenebilirliğini artırır. Ayrıca, verideki gereksiz veya düşük etkili bilgilerin ayıklanarak modelin karmaşıklığının azaltılması da diğer bir avantajdır.

Bu çalışmada da benzer şekilde, bağıl deniz seviyesi verilerinden ve meteorolojik gözlem parametrelerinden elde edilen çeşitli öncül bilgiler model girdisi olarak dahil edilmiştir. Bu girdi verileri, hem deniz seviyesi temel bileşenlerini (trend, mevsimsellik, gelgit) hem de bu yapıları etkileyen dışsal çevresel faktörleri (meteorolojik parametreler) temsil etmektedir.

Pilot çalışmada makine öğrenmesi modellerine girdi olarak dahil edilen öncül bilgiler, temelde iki ana grupta toplanabilir:

1. Zaman Serisinin Bileşenlerinden Türetilen Düzenli Etkiler (Deniz Seviyesi Temel Bileşenleri):

- Doğrusal trend
- Mevsimsel bileşen (Tablo 6 ve Tablo 7’de bulunan SA sinyal bileşeni)
- Gelgit bileşenleri (Tablo 6 ve Tablo 7)


Burada deniz seviyesi zaman serilerindeki doğrusal trend bileşeni, basit doğrusal regresyon modeli ile ön işleme aşamasında (Bölüm 3.2.3.) gösterildiği gibi zaten hesaplanmıştır. Benzer şekilde mareograf istasyonlarından elde edilen gelgit bileşenleri ve mevsimsel bileşen harmonik analiz yöntemi kullanılarak ön işleme aşamasında (Bölüm 3.2.3.) elde edilmiştir. Bu değişkenler, deniz seviyesindeki düzenli ve tahmin edilebilir örüntüleri temsil eder. Doğrudan modele verilerek, algoritmanın bu düzenli yapıları ayrıca öğrenmeye çalışmasına gerek bırakılmaz. Böylece model, asıl tahmini zor olan kısa vadeli ve düzensiz değişimlere odaklanabilir.

2. Dışsal Çevresel Faktörler (Meteorolojik Parametreler)

- Hava Sıcaklığı
- Hava Basıncı
- Hava Nemi
- X yönünde Rüzgar Bileşeni
- Y Yönünde Rüzgar Bileşeni


Bu değişkenler, özellikle kısa vadeli deniz seviyesi değişimlerinde etkili olabileceği değerlendirilen dışsal faktörlerdir.

Deniz seviyesini etkileyen başlıca faktörlerden biri olan rüzgâr, vektörel bir büyüklük olduğundan, ham veri setinde yer alan rüzgâr hızı ve yönü verileri kullanılarak, mareograf istasyonlarındaki düşey ve yatay rüzgâr bileşenleri aşağıdaki şekilde hesaplanmıştır (Şekil 26).



Şekil 26. Yatay ve düşey rüzgar bileşenlerinin hesaplanması (Yavuzdoğan & Kayıkçı, 2021).

Pilot çalışmada kısa süreli deniz seviyesi tahmininde kullanılan öncül bilgiler ve akış şeması Şekil 27’de verilmiştir.



Şekil 27. Makine öğrenimi algoritmalarının eğitiminde kullanılan öncül bilgiler

3.2.5. Makine Öğrenimi Modellerinin Performanslarının Karşılaştırılması

Pilot çalışmada, algoritmaların eğitim ve test veri setlerindeki performanslarını karşılaştırmak amacıyla zaman serisi tahminlerinde yaygın olarak kullanılan Pearson korelasyon katsayısı (r) ve Karesel Ortalama Hata (KOH) metrikleri (Denklem 62 ve Denklem 63) kullanılmıştır.

3.2.6. Ege Denizi Pilot Çalışma Bulguları


Pilot çalışmada, Ege Denizi'nde yer alan iki mareograf istasyonundaki anlık deniz seviyesi değişimlerini tahmin etmek için meteorolojik değişkenler (hava sıcaklığı, hava basıncı, nem, düşey ve yatay rüzgâr bileşenleri) ve deniz seviyesinin temel bileşenleri (doğrusal trend mevsimsel bileşen ve gelgit bileşenleri) kullanılmıştır. Bu amaçla, üç farklı makine öğrenimi algoritmasıyla (ÇDR, DVR ve ROR) tahmin modelleri geliştirilmiş ve bu modellerin performansları karşılaştırmalı olarak değerlendirilmiştir.

ÇDR, DVR ve ROR makine öğrenimi algoritmalarının eğitimi Şekil 27'de görülen öncül veri setinin %70'i, algoritmaların öğrenim sürecinde eğitim verisi olarak ayrılmış, geri kalan %30'u ise tahmin performanslarını sınamak amacıyla test verisi şeklinde rastgele seçilmiştir.

Söz konusu makine öğrenimi algoritmalarının tüm eğitim ve test aşamaları, Python tabanlı SciKit-Learn kütüphanesi kullanılarak uygulanmıştır.


- Çoklu Doğrusal Regresyon Algoritması Eğitim ve Test Performansı

Pilot çalışma kapsamında kısa-sürelî deniz seviyesi değişimlerini modellemek için kullanılan ilk makine öğrenimi algoritması olan Çoklu Doğrusal Regresyon (ÇDR) algoritması, eğitim verileriyle eğitilerek deniz seviyesi tahminleri gerçekleştirilmiştir. Bu tahminler, test dönemi verilerini kapsayacak şekilde yapılmıştır. Elde edilen tahmin sonuçları, gerçekte gözlemlenen değerlerle karşılaştırılarak, test veri seti üzerindeki doğruluk performansları değerlendirilmektedir (Şekil 28).



Şekil 28. ÇDR algoritması model tahminleri ve gözlemlenen deniz seviyesi değerleri

ÇDR algoritmasının deniz seviyesi tahmin performansı, eğitim ve test veri kümelerinde r (Pearson korelasyon katsayısı) ve KOH (Ortalama Kare Hatası) metrikleri üzerinden değerlendirilmiştir. Bu değerlendirmelere ilişkin sonuçlar Şekil 29'da gösterilmektedir.




Şekil 29. ÇDR algoritması deniz seviyesi tahmin performansı


Şekil 29 incelendiğinde, ÇDR algoritmasının hem eğitim hem de test dönemlerinde her iki istasyonda benzer deniz seviyesi tahmin sonuçları verdiği gözlenmektedir. Bununla birlikte, Bodrum İstasyonu için son dönemde gerçekleştirilen tahminler, gerçeğe kıyasla oldukça farklıdır. Bu durum, karmaşık bağımlılık ilişkilerinin söz konusu olduğu veri setlerinde, doğrusal temelli fonksiyonlarla yapılan tahminlerin sınırlı kalabileceğini göstermesi bakımından önemlidir.

- Destek Vektör Regresyonu Algoritması Eğitim ve Test Performansı

RTF (Radyal Tabanlı Fonksiyon) çekirdek kullanan DVR algoritması ile gerçekleştirilen deniz seviyesi tahminleri, Şekil 30'da gösterilmektedir. Ayrıca, eğitim ve test veri setlerinden elde edilen tahmin performansı (r ve KOH metrikleri) Şekil 31'de sunulmuştur.



Şekil 30. DVR algoritması model tahminleri ve gözlemlenen deniz seviyesi değerleri




Şekil 31. DVR algoritması deniz seviyesi tahmin performansı

Şekil 31'deki sonuçlara bakıldığında, DVR algoritmasının hem daha yüksek korelasyon hem de daha düşük KOH değerleriyle ÇDR algoritmasına göre daha başarılı bir deniz seviyesi tahmin performansı sergilediği görülmektedir.


- Rastgele Orman Regresyonu Algoritması Eğitim ve Test Performansı

ROR algoritmasıyla yüksek doğrulukta deniz seviyesi tahmini yapabilmek için, karar ağacı ormanında kaç ağaç kullanılacağına doğru belirlenmesi büyük önem taşımaktadır. Pilot uygulamada, ROR algoritmasında kullanılacak ağaç sayısını tespit edebilmek üzere KOH ve r doğruluk analizlerine dayanan bir yöntem benimsenmiştir. Ağaç sayısının model başarısına etkisi incelenerek uygun sayı seçilmiştir; 10 ağaçtan başlayarak 200 ağaca kadar ROR algoritması ile deniz seviyesi tahmini yapılmıştır. Bodrum istasyonuna ilişkin tahmin sonuçlarının test veri setindeki doğruluk performansı ise Şekil 32'de gösterilmektedir.




Şekil 32. ROR algoritmasında ağaç sayısının tahmin performansına etkisi

Şekil 32'deki analizler, ağaç sayısı arttıkça ROR modelinin tahmin performansının yükseldiğini göstermektedir. Ancak yaklaşık 100 ağaçtan sonra korelasyon ve KOH metriklerinde dikkate değer bir değişiklik olmadığı saptanarak, ROR algoritmasında 100 ağaç kullanılması tercih edilmiştir. ROR algoritmasının deniz seviyesi tahminleri ve performansına ilişkin sonuçlar sırasıyla Şekil 33 ve Şekil 34'te sunulmaktadır.



Şekil 33. ROR algoritması model tahminleri ve gözlemlenen deniz seviyesi değerleri




Şekil 34. ROR algoritması deniz seviyesi tahmin performansı

Şekil 34 incelendiğinde, ROR algoritmasının deniz seviyesi tahmin performansının eğitim ve test veri setinde, ÇDR ve DVR algoritmalarına kıyasla belirgin ölçüde daha yüksek olduğu görülmektedir. Bu yüksek doğruluk düzeyinin, ROR algoritmasının karmaşık bağımlılık ilişkilerini kendi ağaç tabanlı yapısı sayesinde daha etkili biçimde modelleyebilmesinden kaynaklandığı düşünülmektedir.

- Makine Öğrenimi Algoritmalarının Karşılaştırılması

Makine öğrenimi algoritmalarının eğitimin ardından test veri setindeki model tahminlerinin performans analizine ilişkin sonuçlar Şekil 35’te gösterilmektedir.



Şekil 35. ÇDR, DVR ve ROR algoritmalarının karşılaştırılması

Her iki istasyondaki test performansları incelendiğinde, ÇDR ve DVR algoritmalarının ROR algoritmasına göre daha düşük sonuçlar ürettiği görülmektedir.

3.2.7. Ege Denizi Pilot Çalışma Sonuçları

Bu çalışmada, Ege denizindeki iki mareograf istasyonundan elde edilen kısa-süreli deniz seviyelerini tahmin etmek amacıyla makine öğrenimi yöntemleri kullanılmış ve böylece tahmin modelleri oluşturularak modellerin performansları karşılaştırılmıştır. Kısa-süreli deniz seviyesini tahmin edebilmek için makine öğrenimi algoritmalarına sağlanan öncül bilgiler, istasyonlarda ölçülen meteorolojik verilerin yanı sıra anlık deniz seviyesi zaman serilerinin doğrusal trend ve harmonik bileşenlerini (mevsimsel ve gelgit bileşenleri) içermektedir. Bu doğrultuda, ÇDR, DVR ve ROR olmak üzere üç farklı makine öğrenimi

algoritmasından yararlanılmış; eğitim verileriyle eğitilen modeller, test verilerindeki deniz seviyesi tahmin performansı bakımından korelasyon katsayısı ve KOH metrikleriyle değerlendirilmiştir.

Analizler sonucunda, mareograf istasyonlarındaki deniz seviyesi, ROR algoritmasıyla %96 ila %84 arasında korelasyon ve 29 ila 64 mm arasında değişen KOH değerleriyle oldukça yüksek doğrulukta tahmin edilebilmiştir. En başarılı tahmin performansı ROR algoritmasında elde edilirken, en düşük performans ÇDR algoritmasında gözlenmiştir. Pilot çalışmadan elde edilen sonuçların, önceki çalışmalarla aynı veri setleri ve öncül bilgiler kullanılsa da ROR algoritmasının ve kullanılan öncül bilgilerin anlık deniz seviyesi tahminindeki başarısı konusunda fikir vereceği düşünülmektedir. Nitekim literatürde, kısa-sürelili deniz seviyelerinin makine öğrenimi yöntemleriyle belirlenmesine ilişkin çalışmalarda, Imani ve arkadaşları (2018) ± 34 mm, Imani ve arkadaşları (2014b) ± 35 mm, Roshni ve arkadaşları (2019) ise ± 75 mm KOH değeri raporlamıştır; bu çalışmada ise Bodrum istasyonunda ± 29 mm, Menteş istasyonunda ise ± 64 mm KOH elde edilmiştir (Imani, Kao, Lan, & Kuo, 2018; Imani, You, & Kuo, 2014; Roshni, Samui, & Drisya, 2019).

Ayrıca elde edilen bulgular, doğrusal tahmin modellerinin deniz seviyesini kestirmede ne kadar yetersiz kalabileceğini de ortaya koymaktadır. Zira ÇDR algoritması (bir doğrusal tahmin modeli), hem korelasyon hem de KOH metriklerinde doğrusal olmayan DVR ve ROR algoritmalarından daha düşük bir performans sergilemiştir. ROR algoritmasının ağaç yapısına dayanan modeli, meteorolojik veriler, doğrusal trend ve harmonik bileşenler gibi bağımsız değişkenleri kullanarak deniz seviyesini yüksek doğrulukla öngörebilmiştir. Bu durum, ROR algoritmasının anlık deniz seviyelerinin karmaşık bağımlılık yapılarını modellemede diğer algoritmalarla kıyasla daha başarılı olduğunu göstermektedir.

3.3. Karadeniz’de Derin Öğrenme Yöntemleri ile Deniz Seviyesi Değişimlerinin Modellenmesi

Pilot uygulama kapsamında yürütülen Ege Denizi’ndeki modelleme çalışması, klasik makine öğrenimi algoritmalarının kısa vadeli deniz seviyesi tahminindeki performansını değerlendirmek açısından önemli bir zemin oluşturmuştur. Elde edilen yöntemsel kazanımlar, bu tez kapsamında Karadeniz için geliştirilecek daha ileri düzeydeki derin öğrenme modellerinin veri işleme, modelleme ve değerlendirme süreçlerine ışık tutmuştur. Bu bölümde, Karadeniz bölgesine odaklanılarak deniz seviyesi değişimlerinin tahmini

amaçlanmaktadır. Bu kapsamda, bir istatistiksel referans model olan sönümlü-kalıcılık yöntemi ile birlikte üç farklı derin öğrenme mimarisi (Yığılmış LSTM, Oto-Kodlayıcı LSTM ve ConvLSTM) kullanılarak modelleme ve genelleştirilebilirlik analizleri gerçekleştirilmiştir. Bu bölümde, söz konusu modellerin tasarımı, eğitim süreçleri ve tahmin performanslarına ilişkin ayrıntılı analizler sunularak Karadeniz’de kısa vadeli deniz seviyesi tahmininde derin öğrenme yöntemlerinin etkinliği kapsamlı bir biçimde değerlendirilecektir.

3.3.1. Derin Öğrenme Ağlarında Kullanılmak Üzere DUACS Veri Setinin Hazırlanması

Derin öğrenme ağlarının eğitimi ve tahmininde kullanılacak DUACS veri setinin kalite kontrolünün yapılması ve derin öğrenme ağlarında kullanılabilmesi için veri seti aşağıda belirtilen ön işleme aşamalarından geçirilmiştir.

- Verilerin Normalizasyonu

Kullanılan DUACS veri seti zaman serisi analizleri için kalite kontrolü yapılmış verilerdir. İlk olarak derin öğrenme yönteminde kullanılmadan önce eğitim, doğrulama ve test verileri $[0,1]$ aralığında normalize edilmiştir. Normalizasyon işleminde Denklem 40’da verilen standart Minimum-Maksimum normalizasyon yöntemi kullanılmıştır.

- Uyuşumsuz Verilerin Eliminasyonu

Bu tez çalışmasında kullanılan DUACS deniz seviyesi anomalisi verileri, Copernicus Marine Environment Monitoring Service (CMEMS) tarafından temin edilmiş ve dağıtım öncesinde çok aşamalı kalite kontrol süreçlerinden geçirilerek zaman serisi analizlerinde doğrudan kullanılacak formatta sunulmuştur. Bu doğrultuda, veri setine k-sigma kontrolü ($k=3$) uygulanmış; yani her bir zaman serisinin ortalaması ve standart sapması temel alınarak $\mu \pm 3\sigma$ aralığının dışına çıkan değerler analiz edilmiştir.

Ancak yapılan bu istatistiksel kontrol sonucunda, kullanılan veri setinde uyumsuz veri gözlemi tespit edilmemiştir. Dolayısıyla, bu çalışmada herhangi bir veri eliminasyonu veya düzeltme işlemi uygulanmasına gerek kalmamıştır. Bu durum, Copernicus tarafından sağlanan verilerin yüksek kalite düzeyinde olduğunu göstermektedir.

- Eksik Verilerin Doldurulması

Zaman serisi analizlerinde ve özellikle derin öğrenme temelli modellerde, eksik veriler modelin öğrenme kapasitesini olumsuz etkileyebilmekte ve tahmin performansında ciddi

sapmalara neden olabilmektedir. Bu nedenle, model eğitimi öncesinde eksik veri kontrolü kritik bir adımdır.

Bu çalışmada kullanılan DUACS deniz seviyesi anomalisi veri seti, Copernicus tarafından önceden kalite kontrolü yapılmış ve eksik veri içermeyecek şekilde hazırlanmıştır. Ek olarak, istatistiksel kontroller sonucunda herhangi bir eksik veya uyuşumsuz veri tespit edilmemiştir. Bu nedenle, eksik veri doldurma (gap-filling) yöntemlerine ihtiyaç duyulmamıştır.

Veri setinin bütünlüğü sayesinde model eğitimi doğrudan, veri üzerinde herhangi bir onarım veya müdahale gerektirmeksizin gerçekleştirilmiştir.

- Eğitim-Doğrulama-Test Veri Seti Ayrımı: Konumsal Ayrıştırma Yaklaşımı

Makine öğrenimi ve özellikle derin öğrenme modellerinde, modelin öğrenme başarısını ve genelleme kapasitesini değerlendirebilmek için veri setinin eğitim, doğrulama ve test kümelerine ayrılması zorunlu bir adımdır. Bu ayrım, modelin yalnızca eğitim verisiyle değil, daha önce görmediği yeni verilerle de ne ölçüde başarılı tahminler yapabildiğini göstermeyi amaçlar. Zaman serisi tabanlı çalışmalarda genellikle verilerin zamansal olarak bölünmesi yaygın bir yaklaşım olmakla birlikte, bu tez kapsamında konumsal ayrım yöntemi tercih edilmiştir.

Zamansal ayrım, verinin zaman eksenini boyunca bölünmesini ifade eder. Örneğin, geçmişteki belirli bir tarih aralığı eğitim verisi olarak seçilirken, daha sonraki tarih aralığı doğrulama veya test verisi olarak kullanılır. Bu yöntem, özellikle zaman serisi analizlerinde yaygındır. Ancak bu yaklaşımda modelin test verisinde karşılaştığı örüntüler, eğitim verisinden farklı bir iklimsel veya mevsimsel döneme ait olabilir. Bu da modelin tahmin performansını düşürebilir ve sonuçların genellenebilirliğini azaltabilir.

Konumsal ayrım ise verinin mekânsal (yani coğrafi konuma göre) olarak bölünmesidir. Bu yöntemde model, belirli bölgelerdeki veri üzerinden eğitilir ve başka bölgelerdeki verilerle test edilir. Tüm konumsal örnekler aynı zaman aralığını kapsar. Bu durum, modelin zamansal örüntüleri eksiksiz öğrenmesini sağlarken, farklı mekânlarda da bu örüntüleri ne kadar doğru tahmin edebildiğini ölçme imkânı verir. Özellikle LSTM tabanlı zamansal bağımlılıkları öğrenmeye dayalı modellerde, konumsal ayrım daha tutarlı ve metodolojik açıdan daha isabetli bir yaklaşım olabilir.

DUACS deniz seviyesi anomalisi veri seti, Karadeniz genelinde 2616 deniz seviyesi verisi içeren pikselden oluşmaktadır. Bu piksellerin her biri, 10.016 günlük zaman serisini

temsil etmektedir (Şekil 17). Bu çalışmada, modelin eğitilmesi, doğrulanması ve test edilmesi amacıyla toplam 786 piksel seçilmiştir:

- 524 piksel eğitim,
- 131 piksel doğrulama,
- 131 piksel test amacıyla kullanılmıştır.

Eğitim noktaları düzenli bir ızgara yapısı ile seçilirken, doğrulama ve test noktaları rastgele dağılım ile belirlenmiştir (Bkz. Şekil 17). Böylece farklı konumsal bölgelerde model performansının ölçülmesi mümkün kılınmıştır.

Eğitim, doğrulama ve test veri setlerinin ayrımında konumsal yaklaşımın benimsenmesinin çeşitli metodolojik ve uygulamaya yönelik gerekçeleri bulunmaktadır. Aşağıda bu yaklaşımın tercih edilme nedenleri açıklanmıştır:

- Zamansal Bağımlılıkların Korunması: LSTM tabanlı modeller, zaman içerisindeki örüntüleri öğrenmeye odaklıdır. Eğer veriler zaman eksenine göre ayrılırsa, modelin eğitildiği dönem ile test edildiği dönem farklı dağılımlara sahip olabilir. Bu durum, modelin öğrendiği zamansal ilişkileri test aşamasında yeniden oluşturamamasına neden olabilir. Konumsal ayırım, tüm veri noktalarının aynı zaman aralığını kapsamamasına olanak tanıyarak bu sorunu önleyebilir.
- Tüm Zaman Aralığının Kullanımı: Konumsal ayırım, modelin eğitimi için tüm zaman serisi sürecinin (örneğin 1993–2020 arası 10.016 gün) kullanılmasını sağlamaktadır. Bu durum, modelin iklimsel dalgalanmalara, mevsimsel değişimlere ve yıllık örüntülere hâkim olmasını sağlayabilir. Eğer zamansal ayırım yapılmış olsaydı, eğitim ve test setlerinde yıl içi değişkenlik dengesinin bozulabileceği değerlendirilmiştir.


- Kayan Pencere (Sliding Window) Mekanizması

Model eğitimi ve test edilmesi sürecinde yalnızca veri setinin kalitesi ve uygun şekilde ayrılması değil, aynı zamanda tahmin probleminin nasıl kurgulandığı da son derece belirleyicidir. Bu tez kapsamında geliştirilen LSTM temelli derin öğrenme modelleri, geçmiş gözlemlerden gelecekteki değerlerin tahminine dayanan dizisel (sequential) öğrenme yaklaşımlarını temel almaktadır. Bu doğrultuda, modelin girdi (input) ve çıktı (output) dizilerini oluşturmak üzere kayan pencere (sliding window) mekanizması uygulanmıştır. Her bir model eğitimi için kullanılacak veri çiftlerinin sistematik biçimde oluşturulmasını sağlayan bu yaklaşım, veri hazırlama sürecinin bir parçası olarak bu bölümde detaylandırılmaktadır.

Kayan pencere mekanizması, zaman serisi tahminlerinde yaygın olarak kullanılan bir yaklaşımdır ve modellerin zamansal bağımlılıkları ve verideki örüntüleri etkili bir şekilde yakalamasına olanak tanır (Vafaeipour, Rahbari, Rosen, Fazelpour, & Ansarirad, 2014; Azlan, Yusof, & Mohsin, 2019; Chou & Nguyen, 2018). Bu yöntem, özellikle deniz seviyesi anomalileri gibi ardışık veri kümeleriyle çalışırken son derece kullanışlıdır; çünkü doğru tahminler yapabilmek için zamansal bağlamın derin öğrenme modeli tarafından iyi anlaşılması gerekmektedir.

Bu tez çalışmasında, 1, 2 ve 3 adımlık tahmin süreleri (lead time) ile 30 günlük bir pencere boyutuna sahip kayan pencere mekanizması kullanılmıştır. Tahmin süresi (lead time), modelin kaç adım ileriye yönelik tahmin yaptığına karşılık gelir. Kayan pencere mekanizmasının işleyişi şu şekilde özetlenebilir (Şekil 36):

1. Başlangıç Penceresi: İlk zaman adımında pencere, zaman serisinin ilk 30 gününü kapsar. Model, belirlenen tahmin süresi için bu 30 gözlemi kullanarak bir tahmin yapar. Örneğin, tahmin süresi 1 gün ise, model 31. günün değerini tahmin eder; tahmin süresi 2 gün ise, model 32. günün değerini tahmin eder ve bu süreç bu şekilde devam eder.
2. İleri Kaydırma: Model bir tahmin yaptıktan sonra pencere bir adım ileri kaydırılır. Her yeni zaman adımında pencere bir gün ileri taşınarak yine 30 günlük veri aralığını korur. Örneğin, ikinci zaman adımında pencere 2. gün ile 31. gün arasını kapsayacak şekilde kaydırılır ve model belirlenen tahmin süresi için yeni tahmini yapar.
3. Tahmin Sürecinin Devamı: Bu süreç, pencerenin her adımda bir gün ileri kaydırılmasıyla devam eder. Model, her seferinde en güncel 30 günlük gözlem setini kullanarak belirlenen tahmin süresi için yeni tahminler yapar.



Şekil 36. Kayan pencere mekanizması

- Hiperparametre Optimizasyon Algoritmasının Seçimi

Tez çalışması kapsamında, otomatik hiperparametre optimizasyon yöntemlerinden Rastgele Arama (Random Search), Izgara Arama (Grid Search) ve Bayesyen Optimizasyon yöntemlerinin etkinliğini değerlendirmek amacıyla ek bir araştırma gerçekleştirilmiştir.

Bu amaçla, DUACS veri setinin bir bölümü kullanılarak yığılmış LSTM modeli için en uygun hiperparametre kombinasyonu 500 iterasyon boyunca aranmıştır. Optimizasyon sürecinde kullanılan hiperparametre türleri ve bunlara ait hiperparametre uzayı boyutları Tablo 8’de verilmiştir.

Tablo 8. Hiperparametre uzayı boyutları

Hiperparametre Adı	Hiperparametre Uzayı Boyutları
Yığılmış Katman Sayısı	Minimum = 1, Maksimum = 20
Hafıza Hücresi Sayısı	Minimum = 16, Maksimum = 512
Dropout Oranı	Minimum = 0.1, Maksimum = 0.99
Öğrenme Oranı	Minimum = 0.0001, Maksimum = 0.01
Yığın Boyutu	Minimum = 8, Maksimum = 512

Tablo 8’de belirtilen hiperparametre uzayı kullanılarak, farklı optimizasyon algoritmaları aracılığıyla 500 iterasyon boyunca hiperparametre aramaları gerçekleştirilmiştir.

Her yöntemde doğrulama veri seti üzerindeki KOH değeri esas alınarak en başarılı hiperparametre kombinasyonu seçilmiştir. Her bir HPO algoritması ile elde edilen optimum hiperparametre setleri, Tablo 9’da verilmiştir.

Tablo 9. Farklı optimizasyon yöntemleriyle elde edilen en uygun hiperparametre setleri

Optimizasyon Yöntemi	Yığılmış Katman Sayısı	Hafıza Hücresi Sayısı	Dropout Oranı	Öğrenme Oranı	Yığın Boyutu
Rastgele Arama	1	(16)	0.1	0.01	32
Bayesyen Optimizasyon	2	(32,16)	0.1	0.001	128
Izgara Arama	2	(16,16)	0.2	0.005	64

Elde edilen hiperparametre setleri kullanılarak DUACS eğitim veri setinin %50’si kullanılarak 3 farklı model eğitilmiş ve tahmin performansları test veri seti kullanılarak belirlenmiştir. 3 farklı optimizasyon algoritmasından elde edilen Yığılmış LSTM modellerinin test veri seti üzerindeki tahmin performansları Tablo 10’da verilmiştir.

Tablo 10. Optimizasyon yöntemlerine göre model performansları

Optimizasyon Yöntemi	KOH (mm)
Rastgele Arama	42.1
Bayesyen Optimizasyon	25.8
Izgara Arama	31.9

Tablo 10 incelendiğinde, Bayesyen Optimizasyon yöntemi 25.8 mm KOH değeriyle en düşük hata oranını elde ederek en başarılı performansı göstermiştir. Izgara Arama yöntemi 31.9 mm, Rastgele Arama ise 42.1 mm hata değeriyle daha yüksek hata oranlarına sahip olmuştur.

Bu sonuçlar, Bayesyen Optimizasyonun model doğruluğu açısından diğer yöntemlere göre daha verimli bir hiperparametre arama stratejisi sunduğunu göstermektedir. Bununla birlikte, bu yöntemlerin işlem süreleri de değerlendirilmiş ve sonuçlar Tablo 11’de verilmiştir.

Tablo 11. Optimizasyon yöntemlerine göre işlem süreleri

Optimizasyon Yöntemi	İşlem Süresi
Rastgele Arama	2 Saat 28 Dakika
Bayesyen Optimizasyon	2 Saat 10 Dakika
Izgara Arama	2 Saat 55 Dakika

Tablo 11 incelendiğinde, üç optimizasyon yönteminin işlem sürelerinin birbirine yakın olduğu görülmektedir. En kısa işlem süresi Bayesyen optimizasyona ait olup, 2 saat 10 dakikalık sürede optimizasyon sürecini tamamlamıştır. Buna karşılık, Izgara Arama yöntemi 2 saat 55 dakika ile en uzun işlem süresine sahiptir. Sonuçlar göstermektedir ki Bayesyen Optimizasyon hem doğruluk hem de işlem süresi açısından yüksek bir performans sunmaktadır. Bu nedenle, tez kapsamında yürütülen derin öğrenme tabanlı modelleme çalışmalarında nihai hiperparametre optimizasyon yöntemi olarak Bayesyen Optimizasyon tercih edilmiştir.

3.3.2. Uygulama 1: Yığılmış Uzun Kısa Süreli Bellek Modeli ile Karadeniz’de Deniz Seviyesi Anomalilerinin Tahmini


- Yığılmış Uzun-Kısa Süreli Bellek (LSTM) Ağının Tasarımı

Deniz seviyesi modellemede, Uzun-Kısa Süreli Bellek (LSTM) ağları, özellikle zaman serisi tahminindeki optimum performansları nedeniyle makine öğrenimi teknikleri arasında daha yaygın hale gelmektedir (Adebisi & Balogun, 2021). LSTM birimlerinin zaman serisi tahminlerindeki avantajı, karmaşık yapıları sayesinde geçmiş bilgileri daha uzun süre hafızalarında tutabilmeleridir (Makridakis, Spiliotis, & Assimakopoulos, 2018). Ancak LSTM modelinin doğruluğu, uygun öznitelikler ve hiperparametre optimizasyonu ile doğrudan ilişkilidir (Yin, Zhang, Wang, & Xiong, 2020). Yüksek model doğruluğu için ağ için en uygun olan optimal hiperparametrelerin belirlenmesi gerekmektedir. Bir LSTM'nin hiperparametreleri, gizli katman sayısı, öğrenme hızı, aktivasyon fonksiyonu, nöron sayısı, epok sayısı, hata fonksiyonu ve yığın boyutu (batch size) olarak sayılabilir.

Hiperparametre optimizasyonunun (HPO) temel sorunu, sinir ağı modelinde amaç fonksiyonunun değerlendirilmesinin son derece zaman alıcı olmasıdır. Her HPO denemesi için, eğitim verileri üzerinde bir model eğitilmeli, doğrulama verileri üzerinde tahminler yapılmalı ve ardından model performans metriği (KOH, R^2 gibi) hesaplanmalıdır (Şekil 37). Bu süreç, doğrulama veri setinde en düşük tahmin hatası ile en uygun hiperparametre setini bulmak için bir manuel optimizasyon döngüsüdür. Ancak, çok fazla hesaplama kaynağı ve zamanı tüketir. Ayrıca hiperparametre uzayının boyutu, özellikle çok katmanlı sinir ağlarında oldukça büyük olabilir. Bu durum, optimal hiperparametre setini manuel olarak bulmayı zorlaştırır. Izgara Arama, Rastgele Arama, Bayesyen Optimizasyon ve Hiperbant

Optimizasyonu gibi çoklu otomatik hiperparametre optimizasyon yöntemleri, geniş hiperparametre uzayında en uygun hiperparametre setini bulmak için sıklıkla kullanılır.

Bununla birlikte, rastgele arama (random search) ve ızgara arama (grid search) gibi bazı çoklu otomatik hiperparametre optimizasyon yöntemleri bile, bir değerlendirme belleğine sahip olmadıkları için bazen verimsiz olabilir. Bir sonraki hiperparametre setini seçerken, geçmişte kötü sonuçları olan kötü hiperparametreleri hatırlayamazlar. Bu nedenle genellikle kötü hiperparametreleri değerlendirmek için önemli miktarda zaman harcarlar. Bayesyen optimizasyon, rastgele veya ızgara aramanın aksine, optimizasyon süreci boyunca geçmiş değerlendirmeleri de hesaba katar. Bu nedenle, daha az zaman ve hesaplama kaynağı tüketir. Rastgele arama ile Bayesyen optimizasyonu karşılaştıran çalışmalar incelendiğinde Bayesyen optimizasyonun birçok farklı problemde daha iyi sonuçlar verdiği görülmektedir (Eggensperger, ve diğerleri, 2013; Thornton, Hutter, Hoos, & Leyton-Brown, 2013; Li, Jamieson, DeSalvo, Rostamizadeh, & Talwalkar, 2017).



Şekil 37. Hiperparametre optimizasyonu döngüsü

Tez çalışması için yapılan literatür taramaları ışığında, LSTM ağları ile deniz seviyesi değişimlerini tahmin etmek için çoklu otomatik hiperparametre optimizasyon yöntemlerini

kullanan herhangi bir çalışmaya rastlanmamıştır. Bu nedenle bu tez çalışması kapsamında otomatik hiperparametre optimizasyon yöntemlerinden Bayesyen optimizasyon yöntemi ilk defa deniz seviyesi tahmin eden ağların hiperparametre optimizasyonu için kullanılmıştır. Böylece otomatik hiperparametre optimizasyon tekniklerinin deniz seviyesi çalışmalarında kolaylıkla kullanılabileceği de gösterilmiştir.

Bu amaçla, yığılmış uzun-kısa süreli bellek ağının model mimarisi ve hiperparametrelerini belirlemek için Bayesyen otomatik hiperparametre optimizasyon tekniği ve DUACS veri setinden elde edilen eğitim ve doğrulama veri setleri kullanılmıştır. Deniz seviyesi tahmini için kullanılacak Yığılmış LSTM ve LSTM Oto-Kodlayıcı ağları, deniz seviyesi anomalilerini tahmin etmek için 1 adım ileri, 2 adım ileri ve 3 adım ileri tahminler yapacak şekilde yapılandırılmıştır. Bu modellerin amacı, geçmiş 30 günlük deniz seviyesi anomalisi gözlemlerini kullanarak, sonraki 1, 2 ve 3 günün anomalilerini doğru bir şekilde tahmin etmektir. Zaman serisi tahminlerini gerçekleştirmek için kayan pencere mekanizması kullanılmıştır.

- Yığılmış LSTM Ağının Hiperparametre Optimizasyonu

Yığılmış LSTM ağının hiperparametre optimizasyonu için ilk olarak yığılmış LSTM modelinin hiperparametre uzayı belirlenmiştir. Hiperparametre uzayı, derin öğrenme modellerinde hiperparametrelerin alabileceği tüm olası değerlerin oluşturduğu çok boyutlu arama alanıdır. Yığılmış LSTM ağı için belirlenen hiperparametre uzayı Tablo 12’de verilmiştir.

Tablo 12. Yığılmış LSTM ağının hiperparametre optimizasyonu için parametre uzayı


Hiperparametre Adı	Parametre Uzayı Boyutu
Yığılmış Katman Sayısı	Min = 1, Maks = 20
Hafıza Hücresi Sayısı	Min = 16, Maks = 512
Dropout Oranı	Min = 0.2, Maks = 0.99
Yığın (Batch) Boyutu	Min = 16, Maks = 512

Hiperparametre uzayının belirlenmesinin ardından ilk hiperparametre seti rastgele olarak seçilmiştir. Bu hiperparametre seti ile yığılmış LSTM ağı deniz seviyesi zaman serilerini tahmin etmiş ve modelin tahmin performansı KOH metriği kullanılarak belirlenmiştir. Ardından hiperparametre optimizasyon döngüsü 500 iterasyon boyunca çalıştırılmış olup, bu hiperparametre optimizasyon süreci sonunda elde edilen optimal hiperparametre seti Tablo 13’te verilmiştir.

Tablo 13. Yığılmış LSTM ağı için HPO sonucunda elde edilen optimal hiperparametre seti

Hiperparametre Adı	Optimal Değer
Yığılmış Katman Sayısı	2
Hafıza Hücresi Sayısı	(64,32)
Dropout Oranı	0.3
Yığın (Batch) Boyutu	16

Elde edilen optimal hiperparametre setine göre kurulan yığılmış LSTM modeline ilişkin model mimarisi ve hiperparametreleri Şekil 38’de sunulmuştur. Böylece Yığılmış LSTM ağıının tasarımı tamamlanmıştır.



Optimizasyon Algoritması: Adam (Öğrenme Oranı: 0.0001)

Kayıp (Loss) Fonksiyonu: Ortalama Kare Hata

Şekil 38. Yığılmış LSTM ağı model mimarisi

- Yığılmış LSTM Ağının Eğitimi

Bu tez bölümünde, yığılmış Uzun-Kısa Süreli Bellek (LSTM) ağının eğitimi, test edilmesi ve tahmin performansı detaylı bir şekilde ele alınmakta ve modelin eğitim sürecinde kullanılan veri setleri, öğrenme sürecine yönelik değerlendirmeler ve model performansına ilişkin analizler sunulmaktadır.

Yığılmış LSTM ağının eğitimi için “Veri Seti 2: Karadeniz DUACS Radar Altimetre Veri Seti” bölümünde bahsedildiği üzere her biri 10.016 günlük ölçümler içeren toplam 524 adet ortalama deniz seviyesi anomali zaman serisi kullanılmıştır. Bu 524 zaman serisi, Karadeniz üzerindeki düzenli bir konumsal ızgaralama (gridleme) kullanılarak farklı koordinatlardan elde edilmiştir (Şekil 17).

Model eğitimi ve test aşamasında zaman serisi modellerinde genellikle kullanılan kayan pencere (sliding window) mekanizması uygulanmıştır. Model, geçmiş 30 günlük deniz seviyesi anomalisi değerlerini girdi olarak alarak, sırasıyla 1 adım, 2 adım ve 3 adım (1 gün, 2 gün, 3 gün) ileri tahminler üretmiştir.

Bu tez çalışmasında geliştirilen yığılmış LSTM modelinin eğitim süreci, hiperparametre optimizasyonu ile belirlenen mimari yapı ve parametreler doğrultusunda yürütülmüş, eğitim performansını artırmak ve aşırı öğrenmeyi önlemek amacıyla çeşitli düzenleme ve izleme mekanizmaları entegre edilmiştir.

Yığılmış LSTM Modeli, zaman serisi tabanlı tahmin problemi olarak yapılandırılmıştır. Her bir eğitim örneği, 30 günlük geçmiş deniz seviyesi anomalisi verisinden oluşan bir pencere (input sequence) kullanılarak oluşturulmuştur. Bu pencerenin çıktısı, sırasıyla 1 gün, 2 gün ve 3 gün ileriye yönelik tahmin değerleridir. Bu yaklaşım sayesinde model hem kısa vadeli dinamikleri hem de ardışık örüntüleri öğrenmeye uygun hale getirilmiştir.

Kullanılan DUACS veri setinde her biri 10.016 günlük gözlem içeren toplam 524 konumdan gelen zaman serileri modelin eğitimine dahil edilmiştir. Bu verilerden oluşturulan girdi-çıkı örnekleri, kayan pencere (sliding window) yöntemiyle türetilmiştir. Böylece her bir zaman serisi, farklı başlangıç noktalarından alınan çok sayıda ardışık pencere ile modelin öğrenme sürecine katkı sağlamıştır. Eğitim boyunca kullanılan parametreleri şu şekildedir:

- Optimizasyon algoritması: Adam
- Öğrenme oranı: 0.0001
- Hata fonksiyonu: KOH
- Aktivasyon fonksiyonları: tanh ve sigmoid (LSTM hücrelerinde)


- Batch boyutu: 16
- Epoch sayısı: 100

Eğitim süreci boyunca model, eğitim setinden türetilen örnekler ile optimize edilmiştir. Her epok sonunda modelin doğrulama veri seti üzerindeki performansı değerlendirilmiş ve hata değeri (validation loss) izlenmiştir. Bu izleme sayesinde, modelin eğitim sırasında doğrulama performansının bozulduğu durumlar belirlenmiş; gerekirse eğitim süreci erken durdurularak (early stopping) aşırı öğrenme engellenmiştir.

Modelin eğitim süreci sırasında elde edilen eğitim ve doğrulama hatalarının değişimi Şekil 39’da gösterilmiştir.

Her bir ileri tahmin adımı (1, 2 ve 3 gün) için modelin eğitimi ayrı ayrı gerçekleştirilmiştir. Böylece her bir tahmin hedefi için özel optimize edilmiş modeller elde edilmiştir.

Sonuç olarak, yığılmış LSTM ağı, seçilen mimari yapı, doğru veri ayrımı stratejisi ve düzenli eğitim izleme süreci sayesinde öğrenme görevini başarıyla gerçekleştirmiştir. Modelin test setindeki tahmin performansı sonraki bölümlerde detaylı şekilde değerlendirilmiştir.



Şekil 39. Yığılmış LSTM ağı hata grafiği

Şekil 39’da yığılmış LSTM modelinin eğitim sürecindeki hata (loss) eğrileri gösterilmektedir. KOH cinsinden ifade edilen bu hata değerleri, modelin hem eğitim hem de

doğrulama (validasyon) veri kümeleri üzerindeki öğrenme performansını yansıtmaktadır. Grafik incelendiğinde, her iki hata eğrisinin de eğitim boyunca istikrarlı biçimde azaldığı, modelin doğrulama verisi üzerindeki performansının ise oldukça kararlı olduğu görülmektedir.

Grafikte dikkat çeken önemli bir durum, validasyon kaybının eğitim kaybından düşük seyretmesidir. Bu durum, derin öğrenme modellerinde nadir görülen bir durum olup, bu çalışmada kullanılan dropout katmanları ile doğrudan ilişkilidir. Eğitim sürecinde uygulanan %30 oranındaki dropout, sadece eğitim verisi üzerinde aktiftir. Bu katman, eğitim sırasında rastgele hafıza hücrelerini devre dışı bırakarak modelin aşırı öğrenmesini (overfitting) önlemeye çalışmakta; ancak aynı zamanda eğitim kaybını yapay olarak bir miktar artırmaktadır. Buna karşılık, validasyon aşamasında dropout uygulanmadığından, model tüm hafıza hücrelerini kullanarak daha kararlı ve daha düşük hata değerleri üretmektedir.

Dolayısıyla, validasyon kaybının eğitim kaybının altında kalması, eğitim sırasında uygulanan düzenleme stratejisinin bir sonucu olarak değerlendirilmelidir. Benzer durum (Goodfellow, Bengio, & Courville, 2016) çalışmasında ayrıntılı olarak anlatılmıştır.

- Yığılmış LSTM Modeli ile Tahminler ve Performans Değerlendirmesi

Eğitim süreci başarıyla tamamlanan yığılmış LSTM modeli, Karadeniz genelindeki deniz seviyesi anomalilerinin kısa vadeli öngörülerini gerçekleştirmek amacıyla test veri seti üzerinde değerlendirilmiştir. Bu değerlendirme, modelin daha önce görmediği konumsal noktalarda ne düzeyde tahmin yapabildiğini anlamak açısından büyük önem taşımaktadır. Bu doğrultuda, modelin 1 gün, 2 gün ve 3 gün ileriye dönük tahmin doğruluğu analiz edilmiş; tahmin performansı hem zaman içindeki hem de konumsal dağılım açısından değerlendirilmiştir.

Yığılmış LSTM modeli, test veri setinde yer alan 131 konumsal noktada, 10.016 günlük zaman serisi boyunca test edilmiştir. Modelin performansı, her bir ileri tahmin süresi için ayrı ayrı değerlendirilmiştir. Modelin her bir noktadaki tahmin çıktıları, gerçek deniz seviyesi anomalisi değerleri ile karşılaştırılarak hata değerleri hesaplanmış ve ortalamaları alınarak genel performans ölçütleri elde edilmiştir. Yapılan testler sonucunda elde edilen model tahminleri ile gerçek deniz seviyesi anomali gözlemleri arasındaki karesel ortalama hata ve Pearson korelasyonu metriklerine ilişkin ortalama değerler Tablo 14'te verilmiştir.

Tablo 14. Yığılmış LSTM ağı test veri seti tahmin performansları


Performans Metriği	1 Gün İleri Tahmin	2 Gün İleri Tahmin	3 Gün İleri Tahmin
Karesel Ortalama Hata	5.291	8.37	11.49
Pearson Korelasyonu	0.9980	0.9957	0.9909

Modelin 1 günlük tahminlerinde elde edilen ± 5.29 mm KOH ve 0.9980 korelasyon katsayısı, yığılmış LSTM mimarisinin Karadeniz bölgesindeki kısa vadeli deniz seviyesi değişimlerini oldukça hassas bir şekilde öngörebildiğini göstermektedir. 2 günlük ve 3 günlük tahminlerde performansın kademeli olarak azaldığı görülmekle birlikte, bu düşüş, zaman serisi modellemenin doğası gereği beklenen bir durumdur. Öngörü süresi arttıkça modelin belirsizlikle baş etme yeteneği azalmakta, ancak elde edilen değerler hâlâ oldukça yüksek güvenilirlik sunmaktadır.

Özellikle 3 günlük tahminde bile ± 11.49 mm KOH ve 0.9909 korelasyon değerine ulaşılması, modelin hem kısa hem de orta vadeli örüntüleri öğrenme ve genelleme kabiliyetinin güçlü olduğunu ortaya koymaktadır.

Buna ek olarak, modelin mekânsal doğruluğu da haritalar üzerinden incelenerek yorumlanmıştır ve kıyısal alanlarda genellikle daha düşük hata oranları ile yüksek korelasyon elde edildiği görülmüştür. Bu durum, kıyı bölgelerinde deniz seviyesi değişimlerinin daha belirgin ve düzenli örüntüler taşımasından kaynaklanıyor olabilir.

Şekil 40, yığılmış LSTM modeli ile gerçekleştirilen 1, 2 ve 3 günlük deniz seviyesi anomalisi tahminlerine ait KOH değerlerinin Karadeniz üzerindeki konumsal dağılımını göstermektedir. Bu görselde yer alan haritalar, modelin tahmin performansının hem tahmin ufkuna hem de coğrafi konuma göre nasıl değiştiğini görsel olarak ortaya koymaktadır.



Şekil 40. Yığılmış LSTM ağı için karşılaştırmalı KOH haritaları

1 günlük tahminler için KOH dağılımı incelendiğinde (Şekil 40a), Karadeniz'in açık deniz bölgelerinde KOH değerlerinin çoğunlukla ± 3 – 5 mm arasında kaldığı, dolayısıyla modelin bu bölgelerde oldukça yüksek doğrulukta tahminler üretebildiği gözlemlenmektedir. Buna karşılık, batı Karadeniz kıyıları ve özellikle doğu kıyı şeridi boyunca bazı alanlarda KOH değerlerinin ± 6 – 8 mm aralığına yükseldiği dikkat çekmektedir.

2 günlük tahminlerde (Şekil 40b), benzer bir dağılım eğilimi devam etmektedir. Açık deniz bölgeleri, özellikle Karadeniz'in merkez kesimleri, modelin göreceli olarak daha düşük hata ile çalıştığı alanlar olmaya devam etmektedir. Buna karşın, kıyısız bölgelerde, özellikle Türkiye kıyılarına yakın kesimlerde KOH değerlerinin belirgin biçimde arttığı ve ± 8 – 10 mm seviyelerine ulaştığı görülmektedir.

3 günlük tahmin haritası (Şekil 40c) ise, tahmin süresinin uzamasıyla birlikte genel hata seviyesindeki artışı açıkça ortaya koymaktadır. Bu aşamada, Karadeniz'in büyük bölümünde KOH değerleri ± 10 mm'nin üzerine çıkmakta, bazı kıyı bölgelerinde ± 13 – 14

mm'ye kadar ulaşmaktadır. Açık deniz bölgeleri tahmin süresi uzasa dahi görece daha dengeli KOH değerleri sunmaya devam etmektedir.

Bu bulgular, modelin açık deniz bölgelerinde daha iyi performans sergilemesinin olası nedenlerine işaret etmektedir. Açık denizlerdeki deniz seviyesi dinamiklerinin daha homojen, dalga etkilerinin ise daha genellenebilir olması, modelin bu bölgelerdeki örüntüleri daha sağlıklı öğrenmesine imkân tanımış olabilir. Buna karşılık, kıyı bölgelerinde; batimetrik karmaşıklık, karasal etkiler, kıyıya özgü rüzgar ve akıntı sistemleri gibi değişkenler, modelin tahmin doğruluğunu sınırlayan faktörler haline gelmiş olabilir. Ayrıca modelin özellikle kıyı bölgelerinde diğer alanlara göre daha yüksek KOH değerleri üretmiş olması, yalnızca model performansı ile değil, aynı zamanda girdi verilerinin doğasına özgü sistematik sınırlamalarla da ilişkilendirilebilir. Bu çalışmada kullanılan deniz seviyesi anomali verileri, uydu radar altimetresi yoluyla elde edilen DUACS ürünlerine dayanmaktadır. Ancak uydu altimetre sistemleri, sığ kıyı bölgelerinde güvenilir ölçümler yapma konusunda çeşitli zorluklarla karşılaşmaktadır. Sığ sularda, altimetre sinyalinin yeryüzüne gönderildikten sonra tekrar toplanması sırasında, sinyalin bir kısmı kara parçaları, kıyı çizgisi veya adacıklar gibi yansıtıcı engellere çarparak yansır. Bu durum, sinyalin uyduya dönüş yolculuğunda bozulmalara (signal contamination) yol açmakta, parazitli geri dönüş sinyalleri (fingerprint distortions) oluşmasına neden olmaktadır. Sonuç olarak, altimetre verisi kıyıya yakın bölgelerde daha düşük hassasiyet veya belirsizlikler içerebilir. Bu fiziksel ve ölçümsel kısıt, kıyı bölgelerinde gözlenen yüksek KOH değerlerinin yalnızca modelin tahmin kapasitesiyle değil, aynı zamanda girdi verisinin kalitesindeki azalmayla da açıklanabileceğini göstermektedir. Dolayısıyla, bu bölgelerdeki hata seviyeleri yorumlanırken hem model başarıımı hem de ölçüm sistemlerinin sınırlamaları dikkate alınmalıdır.

3.3.3. Uygulama 2: Oto-Kodlayıcı Temelli Uzun Kısa Süreli Bellek Modeli ile Karadeniz’de Deniz Seviyesi Anomalilerinin Tahmini

Bu uygulamada, Karadeniz’deki deniz seviyesi anomalilerinin kısa vadeli tahmini amacıyla geliştirilen Oto-Kodlayıcı LSTM (Auto-Encoder LSTM) mimarisi sunulmaktadır. Bu mimari, zaman serilerini sıkıştırılmış bir gizli (latent) temsil uzayına kodlayarak örüntüleri daha etkili öğrenmeyi ve bu temsili kullanarak ileriye dönük tahmin gerçekleştirmeyi hedeflemektedir. Bu bölümde, geliştirilen oto-kodlayıcı modelin tasarımı,

hiperparametre optimizasyonu, eğitim süreci ve elde edilen tahmin sonuçları detaylı bir biçimde açıklanmıştır.

- Oto-Kodlayıcı Uzun-Kısa Süreli Bellek (LSTM) Ağının Tasarımı

Bu çalışmada kullanılan oto-kodlayıcı LSTM modeli, klasik LSTM mimarisinden farklı olarak iki ana bileşene sahiptir: Kodlayıcı ve Kod Çözücü. Kodlayıcı kısmı, giriş zaman serisini daha düşük boyutlu bir gizli vektöre dönüştürürken; Kod Çözücü kısmı bu temsil üzerinden gelecekteki deniz seviyesi anomalisini tahmin eder. Modelin genel yapısı aşağıdaki gibidir:

- Kodlayıcı Mimari: Girdi olarak, geçmiş 30 günlük deniz seviyesi anomali zaman serisi verileri kullanılır. Kodlayıcı kısmında yer alan LSTM katmanları, girdi zaman serisini giderek daha soyut ve düşük boyutlu bir temsile (gizli vektör) dönüştürür. Bu katmanlar, modelin uzun vadeli bağımlılıkları ve karmaşık örüntüleri öğrenmesine olanak sağlar.
- Gizli Vektör (Bottleneck): Kodlayıcı'dan elde edilen son çıktı, verinin en kritik özelliklerini barındıran sıkıştırılmış temsil olarak kullanılır. Bu temsilin boyutu, modelin kapasitesini ve genelleme performansını doğrudan etkilediğinden, uygun boyutun seçilmesi önem arz etmektedir.
- Kod Çözücü Mimari: Gizli Vektör'den faydalanılarak, Kod Çözücü Mimari veriyi yeniden genişleterek orijinal zaman serisi boyutuna çıkarır. Bu aşamada LSTM katmanları, geleceğe yönelik deniz seviyesi anomalilerini tahmin etmek amacıyla yapılandırılmıştır.

Oto-kodlayıcı LSTM ağının hiperparametreleri, modelin performansını doğrudan etkileyen en kritik faktörlerden biridir. Bu nedenle, bu uygulamada hiperparametrelerin belirlenmesi için çoklu hiperparametre optimizasyon yöntemlerinden Bayesyen optimizasyon yöntemi tercih edilmiştir. Oto-Kodlayıcı LSTM modelinin hiperparametre optimizasyon sürecinde HPO döngüsünün yoğun hesap yükü gerektirmesi ve oldukça zaman alıcı olması nedeniyle bazı hiperparametreler (Katman Sayısı, Hafıza Hücre Sayısı, Gizli Vektör Boyutu vs.) optimizasyona konu edilmeden deneme-yanılma yöntemiyle seçilmiş, Dropout Oranı ve Yığın Boyutu (Batch Size) hiperparametreleri ise Bayesyen optimizasyon yöntemine göre seçilmiştir. Tablo 15'te Oto-Kodlayıcı LSTM modelinin hiperparametre uzayı verilmiştir.

Tablo 15. Oto-Kodlayıcı LSTM ağı için hiperparametre uzayı boyutları


Hiperparametre Adı	Parametre Uzayı Boyutu
Dropout Oranı	Min = 0.2, Maks = 0.99
Yığın (Batch) Boyutu	Min =16, Maks = 512

Hiperparametre uzayının belirlenmesinin ardından ilk hiperparametre seti rastgele olarak seçilmiştir. Bu hiperparametre seti ile Oto-Kodlayıcı LSTM ağı deniz seviyesi zaman serilerini tahmin etmiş ve modelin tahmin performansı KOH metriği kullanılarak belirlenmiştir. Ardından hiperparametre optimizasyon döngüsü 500 iterasyon boyunca çalıştırılmış olup, bu hiperparametre optimizasyon süreci sonunda elde edilen optimal hiperparametre seti Tablo 16’da verilmiştir.

Tablo 16. Oto-Kodlayıcı LSTM ağı için HPO sonucunda elde edilen optimal hiperparametre seti

Hiperparametre Adı	Optimal Değer
Dropout Oranı	0.2
Yığın (Batch) Boyutu	16

Elde edilen optimal hiperparametre setine göre kurulan Oto-Kodlayıcı LSTM modeline ilişkin model mimarisi ve hiperparametreleri Şekil 41’de sunulmuştur.



Şekil 41. Oto-Kodlayıcı LSTM ağı model mimarisi

- Oto-Kodlayıcı LSTM Ağının Eğitimi

Oto-kodlayıcı LSTM modeli, Karadeniz'deki deniz seviyesi anomalilerinin kısa vadeli tahmini amacıyla yapılandırılmış olup, modelin eğitim süreci, önceki bölümde tanımlanan mimari yapı ve hiperparametre ayarları doğrultusunda gerçekleştirilmiştir. Modelin eğitimi süresince kullanılan parametreler aşağıda sunulmuştur:


- Girdi penceresi: 30 gün
- Epok sayısı: 100
- Yığın Boyutu: 16
- Dropout oranı: 0.2
- Öğrenme oranı: 0.0001
- Optimizasyon algoritması: Adam
- Hata fonksiyonu: KOH

Modelin Kodlayıcı kısmından elde edilen gizli vektör, Kod-Çözücü tarafından tekrar yapılandırılmak üzere Yinelenmiş Vektör Katmanı aracılığıyla 30 zaman adımı boyunca çoğaltılmış ve LSTM katmanlarına aktarılmıştır. Bu işlem, gizli temsilin zaman boyutunda genişletilerek ileriye dönük tahmin için uygun hale gelmesini sağlamıştır.

Her bir tahmin süresi (1, 2 ve 3 gün) için model ayrı ayrı eğitilmiş ve her eğitim süreci sonunda doğrulama veri seti üzerinden modelin hata fonksiyonundaki değişim izlenmiştir. Eğitim sürecinde elde edilen eğitim ve doğrulama hatalarının eğrileri Şekil 42'de sunulmuş olup, modelin öğrenme davranışı değerlendirilmiştir.

Bu eğriler incelendiğinde, eğitim ve doğrulama kaybının benzer eğilimlerde azaldığı; overfitting belirtisi gözlenmediği ve modelin genelleme yeteneğini koruyarak başarıyla optimize edildiği anlaşılmıştır. Eğitim süresince dropout uygulanmasının etkisiyle eğitim kaybı doğrulama kaybından daha yüksek seyretmiş; bu durum da dropout'un düzenleyici (regularizer) rolünü başarıyla yerine getirdiğini göstermiştir.

Sonuç olarak, eğitim süreci sonunda elde edilen eğitilmiş model hem düşük hata (loss) değerleriyle hem de stabil doğrulama (validation) performansı ile ileriye dönük tahmin görevleri için uygun bir yapı sergilemiştir. Eğitilen model, bir sonraki bölümde test verisi üzerinde değerlendirilmiş ve performansı ayrıntılı olarak analiz edilmiştir.



Şekil 42. Oto-Kodlayıcı LSTM ağı hata grafiği

- Oto-Kodlayıcı LSTM Modeli ile Tahminler ve Performans Değerlendirmesi

Eğitim süreci başarıyla tamamlanan Oto-Kodlayıcı LSTM modeli, Karadeniz genelinde deniz seviyesi anomalilerinin kısa vadeli tahminlerini gerçekleştirmek amacıyla test veri seti üzerinde uygulanmıştır. Modelin performansı, 1 gün, 2 gün ve 3 gün ileriye dönük tahminler olmak üzere üç farklı zaman ufkunda değerlendirilmiş; elde edilen tahmin sonuçları, Karesel Ortalama Hata (KOH) ve Pearson Korelasyon Katsayısı (r) metrikleri kullanılarak analiz edilmiştir.

Modelin her bir noktadaki tahmin çıktıları, gerçek deniz seviyesi anomalisi değerleri ile karşılaştırılarak hata değerleri hesaplanmış ve ortalamaları alınarak genel performans ölçütleri elde edilmiştir (Tablo 17).

Tablo 17. Oto-Kodlayıcı LSTM ağı test veri seti tahmin performansları


Performans Metriği	1 Gün İleri Tahmin	2 Gün İleri Tahmin	3 Gün İleri Tahmin
Karesel Ortalama Hata	4.633	8.020	11.38
Pearson Korelasyonu	0.9985	0.9958	0.9916

Sonuçlar incelendiğinde, oto-kodlayıcı LSTM modeli özellikle 1 günlük tahminlerde oldukça düşük hata ve yüksek korelasyon ile başarılı bir tahmin gerçekleştirmiştir. KOH değerlerinin ± 4.63 mm seviyesinde kalması, modelin geçmiş 30 günlük veriden yüksek doğrulukla örüntü çıkarabildiğini göstermektedir. Pearson korelasyon katsayısının 0.9985

gibi yüksek bir değerde olması, modelin tahminlerinin gözlenen değerlerle yüksek düzeyde senkronize olduğunu göstermektedir.

2 günlük tahminlerde hata oranlarında kısmi bir artış gözlenmiş (KOH: ± 8.02 mm), ancak model korelasyon açısından yüksek performansını sürdürmüştür ($r = 0.9958$). 3 günlük tahminlerde ise beklenen şekilde hata değerleri biraz daha yükselmiş olsa da (KOH: ± 11.38 mm), modelin korelasyon katsayısı hala 0.99 seviyesinin üzerinde kalarak istikrarlı bir performans sergilemiştir.

Ancak bu performansın yalnızca ortalama olarak değil, aynı zamanda coğrafi dağılım bağlamında da değerlendirilmesi önem arz etmektedir. Bu doğrultuda, modelin farklı tahmin ufuklarına ait tahmin sonuçları konumsal KOH haritaları aracılığıyla görselleştirilmiş; Karadeniz genelindeki bölgesel hata değişimleri detaylı biçimde analiz edilmiştir. KOH haritaları Şekil 43'te verilmiştir.



Şekil 43. Oto-Kodlayıcı LSTM ağı için karşılaştırmalı KOH haritaları

Şekil 43, Oto-Kodlayıcı LSTM modeli tarafından üretilen 1, 2 ve 3 günlük ileri tahminler için hesaplanan KOH değerlerinin Karadeniz üzerindeki konumsal dağılımını göstermektedir. Haritalar, modelin farklı öngörü sürelerinde hangi bölgelerde daha başarılı ya da daha yüksek hataya sahip olduğunu karşılaştırmalı biçimde ortaya koymaktadır.

1 günlük tahmin haritası incelendiğinde, modelin genel olarak Karadeniz'in tamamında düşük KOH değerleri ile başarılı tahminler gerçekleştirdiği görülmektedir. Özellikle açık deniz bölgelerinde KOH'nın $\pm 3-5$ mm bandında seyrettiği, kıyı bölgelerinde ise bazı sınırlı alanlarda $\pm 6-7$ mm değerlerine ulaştığı gözlemlenmiştir. Bu durum, modelin kısa vadeli örüntüleri etkili biçimde öğrendiğini ve kıyı-açık deniz farkına rağmen genelleme yeteneğini koruduğunu göstermektedir.

2 günlük tahminlerde, hata değerlerinde belirgin bir artış gözlenmektedir. KOH değerleri açık denizlerde genellikle $\pm 6-9$ mm aralığında yoğunlaşmakta; özellikle batı ve doğu Karadeniz'in bazı açık deniz alanlarında ± 10 mm'ye yaklaştığı görülmektedir.

3 günlük tahmin haritası, tahmin süresi uzadıkça belirsizliğin arttığını açıkça ortaya koymaktadır. Özellikle doğu Karadeniz açıklarında ve kuzey kıyılar boyunca KOH değerleri $\pm 12-14$ mm bandına ulaşmakta, Karadeniz'in merkezine doğru ise daha dengeli bir dağılım gözlenmektedir. Kıyı bölgelerinde ise hata değerleri göreceli olarak daha değişken olup bazı alanlarda modelin tahmin performansı zayıflamıştır.

Bu üç harita birlikte değerlendirildiğinde, Oto-Kodlayıcı LSTM modelinin kısa vadeli tahminlerde (özellikle 1 gün) oldukça yüksek doğruluk sunduğu; öngörü süresi arttıkça (2 ve 3 gün) bazı alanlarda hata düzeylerinin belirgin şekilde arttığı gözlemlenmiştir. Açık deniz bölgelerinde genellikle daha düşük KOH değerleri elde edilmesi, bu bölgelerdeki deniz seviyesi örüntülerinin daha homojen ve model tarafından daha kolay öğrenilebilir olmasından kaynaklanıyor olabilir. Kıyısız alanlarda ise hem altimetre verisinin sınırlılıkları hem de bölgesel dinamiklerin karmaşıklığı nedeniyle modelin performansında görece zayıflama görülmektedir.

3.3.4. Uygulama 3: Evrişimli Uzun Kısa Süreli Bellek Modeli ile Karadeniz'de Deniz Seviyesi Anomalilerinin Tahmini

Bu bölümde, Karadeniz'deki deniz seviyesi anomalilerinin kısa vadeli tahmini amacıyla geliştirilen Evrişimli Uzun Kısa Süreli Bellek (ConvLSTM) mimarisi tanıtılmakta ve modelin tasarımı, eğitimi ile tahmin performansı detaylı bir şekilde açıklanmaktadır.

ConvLSTM mimarisi, sıradan LSTM yapılarından farklı olarak, girdi verisindeki konumsal yapıları da dikkate alarak hem zamansal hem de konumsal ilişkileri aynı anda öğrenebilen bir yapay sinir ağı modelidir. Bu özelliği sayesinde özellikle ızgaralanmış çevresel veriler ile yapılan tahmin çalışmalarında daha yüksek doğruluk sunabilmektedir.

- Veri Setinin Ön İşleme Aşamaları

Çalışma kapsamında kullanılacak DUACS veri setine derin öğrenme modelinin konumsal–zamansal yapıdaki verileri aynı anda işleyebilmesi amacıyla geleneksel zaman serisi formatından farklı bir veri ön işleme süreci uygulanmıştır. Bu sürecin temel amacı, verileri görüntü dizileri (image sequences) şeklinde yeniden organize ederek ConvLSTM mimarisine uygun hale getirmektir.


- NetCDF Formatından Görüntü Dizilerine Dönüştürme

DUACS SLA verileri orijinalde NetCDF (Network Common Data Form) formatında sağlanmaktadır. Her NetCDF dosyası, belirli bir tarih için tüm Karadeniz genelini kapsayan 2B konumsal SLA dağılımını içerir. Öncelikle, bu dosyalar zaman boyunca sıralanarak SLA değişimini izleyen bir veri kümesi oluşturulmuştur. Bu aşamada uygulanan adımlar:

- Her bir gün için SLA verisi 56x120 piksel boyutlarında matrislere dönüştürülmüştür.
- Matris değerleri gri tonlamaya (greyscale) uygun hale getirilmiş ve her görüntü tek bantlı TIFF dosyasına çevrilmiştir.
- Tek bantlı TIFF görüntüleri, minimum-maksimum normalizasyon kullanılarak, normalize edilmiş tek bantlı TIFF görüntüsüne dönüştürülmüştür.
- Daha sonra tüm görüntüler sıralı biçimde zaman serisi oluşturan görüntü blokları haline getirilmiştir. Tüm bu işlemler Şekil 44’te gösterilmiştir.

- Zaman Dizilerinin Oluşturulması ve Veri Bloklarının Yapılandırılması

Eğitim için kullanılan model her bir tahmin işlemi için geçmiş 25 günün SLA görüntüsünü girdi olarak alır. Bu amaçla, tüm SLA zaman serileri kayan pencere (sliding window) yöntemi ile 25 günlük görüntü bloklarına ayrılmıştır. Her bloğun karşılığı olarak 26. günün SLA haritası çıktı (label) olarak atanmıştır (Şekil 45).




Şekil 44. DUACS veri setinin ConvLSTM mimarisi için ön işleme aşamaları

Şekil 45'te ConvLSTM modeline veri sağlamak amacıyla zaman boyunca yapılandırılmış görüntü bloklarının nasıl oluşturulduğu şematik olarak gösterilmektedir. Modelin temel çalışma prensibi, geçmişteki belirli bir zaman aralığına ait SLA görüntülerini (girdi dizisi) alarak, bu zaman aralığını takip eden günün SLA görüntüsünü (tahmin görüntüsü) üretmektir.

Bu bağlamda, her bir örnek şu şekilde tanımlanmaktadır:


- **Girdi Dizisi (Input Sequence):** Karadeniz'in SLA dağılımını gösteren üst üste 25 ardışık günün görüntüsünden oluşmaktadır. Her bir görüntü, 56×120 piksel boyutunda olup, SLA değerlerinin Karadeniz üzerindeki konumsal dağılımını temsil eder. Bu 25 günlük dizilim, modelin geçmiş görüntüleri öğrenmesi için kullanılır.
- **Çıktı Görüntüsü (Target/Label):** Modelin girdisi olan 25 günlük SLA görüntü dizisinin bir gün ileriye kaydırılmış yeni 25 günlük görüntü dizisi, çıktı dizisi olarak tanımlanır. Böylece model görüntü dizileri ile sekanstan sekansa (sequence-to-sequence) çalışmış olur.
- **Tahmin (Prediction):** Modelin 26. güne dair ürettiği çıktı, tahmin görüntüsü olarak tanımlanır.



Şekil 45. ConvLSTM mimarisi için görüntü bloklarının oluşturulması

Bu yapının en önemli özelliklerinden biri, veri örnekleme stratejisinin veri seti türüne göre farklılaştırılmış olmasıdır:

- Test verisi üzerinde, zaman dizileri klasik kayan pencere (sliding window) yaklaşımı ile oluşturulmuştur. Her pencere bir gün ileri kaydırılmış ve bu sayede zaman içinde çeşitlendirilmiş örüntülerle ve artırılmış verilerle modelin tahmin performansı oldukça detaylı olarak ölçülmüştür.
- Buna karşın, eğitim ve doğrulama verileri için farklı bir yöntem izlenmiştir. 25 günlük ardışık diziler, veri seti boyunca zaman sıralaması korunacak şekilde rastgele seçilmiştir (shuffle). Bu yöntem, eğitim sürecinde örüntü çeşitliliğini artırmış, overfitting riskini azaltmış ve modelin genelleme yeteneğini güçlendirmiştir. Tüm bu veri örnekleme stratejileri Şekil 46’da görülebilir.




Şekil 46. ConvLSTM modelinde kullanılan SLA veri setinin yeniden yapılandırılması.

Şekil 46’da gösterildiği üzere, eğitim veri setindeki 7000 görüntü, her biri 25 ardışık görüntüden oluşacak şekilde yeniden yapılandırılmış ve toplamda 280 adet mini yığın (mini batch) oluşturulmuştur. Benzer şekilde, 1500 doğrulama görüntüsünden de 60 adet mini yığın elde edilmiştir. Bu işlem sırasında, her bir mini yığın, zaman sıralaması bozulmaksızın ama veri seti boyunca rastgele konumlardan seçilen 25 ardışık günlük sekanslardan oluşturulmuştur. Böylece modelin farklı dönemsel örüntülerle karşılaşması sağlanarak genelleme performansı artırılmış ve aşırı öğrenme riski azaltılmıştır.

Buna karşılık, test veri seti için farklı bir yaklaşım benimsenmiştir. Modelin performansını daha hassas şekilde değerlendirebilmek ve daha fazla test örneği elde edebilmek amacıyla, burada kayan pencere (sliding window) mekanizması kullanılmıştır. Bu yöntemde, pencere her seferinde bir gün kaydırılarak 25 günlük diziler oluşturulmuş ve bu sayede 1500 görüntüden 1475 adet mini yığın türetilmiştir. Bu yapı sayesinde, test aşamasında modelin tahmin doğruluğu daha yüksek örneklem sayısı ile ayrıntılı biçimde analiz edilebilmiştir.

- Evrişimli Uzun Kısa Süreli Bellek Ağının Tasarımı

Bu tez çalışmasında geliştirilen ConvLSTM modeli hem zamansal hem de konumsal bilgiyi aynı anda işleyebilen bir derin öğrenme mimarisidir. Modelin mimarisi, yağış kestirimi (Shi, ve diğerleri, 2015) ve video kare tahmini (Niu, Li, and Mo, Guo, & Wang, 2018) alanlarında kullanılan ConvLSTM tabanlı modellerden esinlenilerek tasarlanmıştır. Modelin mimarisi Şekil 47’de görselleştirilmiştir.



Şekil 47. ConvLSTM model mimarisi

Bu çalışmada kullanılan derin öğrenme mimarisi, girdi verilerini ve ara katman çıktıları matematiksel olarak tensör adı verilen çok boyutlu diziler biçiminde işler. Tensör, genel anlamıyla birden fazla boyutta veri barındıran genişletilmiş matris yapılarıdır. Örneğin klasik bir matris iki boyutlu (satır $\times$ sütun) iken, tensörler üç, dört veya daha fazla boyutta olabilir. Bu bağlamda, (25, 56, 120, 1) şeklindeki bir tensör; sırasıyla 25 zaman adımı, her biri 56 piksel yüksekliğe ve 120 piksel genişliğe sahip tek kanallı (gri tonlamalı) görüntüler dizisini temsil eder.

Girdi Katmanı: Model, zaman serisi biçiminde yapılandırılmış 25 ardışık SLA görüntüsünü (56 $\times$ 120 boyutunda) girdi olarak alır. Modelin beklediği giriş formatı, dört boyutlu bir tensör yapısındadır ve şu şekilde tanımlanır: (Zaman Adımı, Yükseklik, Genişlik, Kanal Sayısı).

Bu nedenle, tek bantlı (gri tonlamalı) SLA görüntüleri uygun formata getirilerek her bir girdi örneği (25, 56, 120, 1) boyutlarında yapılandırılmıştır. Burada 25 ardışık 56 $\times$ 120 piksellik SLA görüntüsü, tek kanallı olarak modele sunulmuştur.

64 Kanallı ConvLSTM2D Katmanı: Modelin ilk katmanı olan ConvLSTM2D, giriş katmanından gelen (25, 56, 120, 1) boyutundaki tek kanallı gri tonlamalı SLA görüntü dizisini hem zamansal hem de konumsal olarak işler. Bu katmanda uygulanan 7 $\times$ 7 piksel boyutunda 64 adet filtre ile, her bir zaman adımıdaki konumsal özellikleri çıkarırken, zaman boyutundaki örüntüleri de LSTM hücreleri aracılığıyla takip eder. Böylece model, zaman boyunca değişen konumsal desenleri anlamlandırabilecek hale gelir. İşlem sonucunda veri boyutu (25, 56, 120, 64) şekline dönüşür; yani her bir zaman adımı için 64 kanallı öznitelik haritası (feature map) elde edilmiş olur. Bu öznitelikler, modelin sonraki katmanlarında daha karmaşık örüntülerin öğrenilmesi için temel oluşturur.

Yığın Normalizasyon Katmanı: ConvLSTM2D katmanının çıktısı olan (25, 56, 120, 64) boyutundaki tensör, bir sonraki aşamada Yığın Normalizasyon (Batch Normalization - BN) katmanına aktarılır. Bu katman, modelin öğrenme sürecini daha kararlı hale getirmek amacıyla her mini yığın (batch) içindeki aktivasyon değerlerini normalize eder. Bu sayede, farklı katmanlardaki veri dağılımlarındaki kaymalar (internal covariate shift) azaltılmış olur. Ayrıca BN, öğrenme hızını artırırken aynı zamanda aşırı öğrenme (overfitting) riskini de düşürerek modelin genelleme yeteneğini destekler. Bu aşamadan geçen veriler, normalize edilmiş öznitelikler olarak bir sonraki ConvLSTM katmanına iletilir.

32 Filtreli ConvLSTM2D Katmanı: Bu katmanda filtre sayısı 32'ye düşürülmüş, ancak önceki katmanla aynı filtre boyutu (7 $\times$ 7) korunmuştur. Bu sayede önceki katmandan

aktarılan 64 kanallı öznitelik haritasının boyutu 32'ye düşürülmüştür. Bu işlem, öznitelik haritasını sıkıştırarak modelin hesaplama karmaşıklığını azaltmakta, aynı zamanda daha yüksek seviyeli örüntülerin daha kompakt bir biçimde temsil edilmesini sağlamaktadır. Bu katmanı, yine modelin öğrenme sürecini daha kararlı hale getirmek amacıyla bir yığın normalizasyon (batch normalization) katmanı ve ardından 2 adet daha 32 filtreli ConvLSTM2D katmanı takip etmektedir.

Bu üçüncü ve dördüncü ConvLSTM2D katmanı, bir öncekiyle aynı mimari özellikleri taşımakla birlikte, ağın derinliğini artırarak daha soyut örüntülerin yakalanmasına katkı sağlamaktadır. Zamansal bilgiyi yeniden gözden geçirerek öğrenmeyi pekiştirir.

Conv3D Katmanı: Modelin çıkış bloğunda yer alan üç boyutlu evrişim katmanı (Conv3D), önceki ConvLSTM katmanları tarafından zaman boyunca işlenen öznitelik haritalarını tahmin edilebilir çıktılara dönüştürmek amacıyla kullanılmıştır. Bu katman, girdi olarak (25, 56, 120, 32) boyutunda dört boyutlu bir tensör alır. Bu tensör, sırasıyla 25 zaman adımı, 56 piksel yükseklik, 120 piksel genişlik ve 32 öznitelik (filtre) kanalı içeren bir veri yapısını temsil etmektedir.

Conv3D katmanı bu girdi üzerine 1 adet $1 \times 1 \times 1$ boyutunda evrişim çekirdeği (filtre) uygular. Bu işlem sonucunda, her bir zaman adımı için 56×120 boyutunda tek kanallı bir çıktı üretilir ve çıktı tensörü (25, 56, 120, 1) boyutuna dönüşür. Bu yapı, modelin her bir zaman adımı için tahmin ettiği SLA haritasını içermektedir. Kanal ekseninde burada yalnızca tek bantlı (grayscale) veriyi ifade ettiği için çoğu uygulamada bu boyut düşürülerek çıktı pratikte (25, 56, 120) şeklinde üç boyutlu bir tensör olarak değerlendirilir.

Modelin bu 25 zaman adımlık tahmin çıktıları arasında, özellikle dizinin sonuncusu (25. zaman adımı) tahmin süreci açısından kritik öneme sahiptir. Bu kare, girdi olarak sunulan 25 ardışık günlük SLA haritasını takip eden 26. güne ait SLA tahmin haritası olarak yorumlanır ve modelin başarı ölçütleri (KOH, MHO vb.) bu çıktıya dayalı olarak hesaplanır.

- ConvLSTM Ağıнын Eğitimi

Modelin eğitimi, Karadeniz'e ait deniz seviyesi anomalisi (SLA) verilerinin son 30 yıla ait konumsal-zamansal dağılımlarını içeren büyük boyutlu bir görüntü veri seti üzerinden gerçekleştirilmiştir. Eğitim sürecinde modelin hem konumsal desenleri hem de zamansal değişimleri aynı anda öğrenebilmesi için özel olarak yapılandırılmış (25, 56, 120, 1) boyutunda tensörlerden oluşan örnekler kullanılmıştır. Her örnek, 25 günlük ardışık SLA görüntüsünü içermekte; model, bu diziyi işleyerek 26. güne ait tahmin görüntüsünü üretmektedir.

Model eğitimi sırasında kullanılan veri seti, toplam 10.000 görüntü içerecek şekilde yapılandırılmıştır. Bu görüntüler; 7.000 adet eğitim verisi, 1.500 adet doğrulama verisi ve 1.500 adet test verisi olmak üzere üç alt kümeye ayrılmıştır. Eğitim ve doğrulama veri setlerinde, 25 görüntüden oluşan ardışık bloklar, veri seti içerisinde zaman sıralaması korunarak rastgele seçilmiş ve bu sayede modelin farklı dönem görüntülerine maruz kalması sağlanmıştır. Bu işlem, aşırı uyum (overfitting) riskini azaltırken modelin genelleme performansını güçlendirmiştir.

Test veri setinde ise farklı bir örnekleme stratejisi izlenmiştir. kayan pencere yaklaşımı uygulanarak her adımda pencere bir gün ileri kaydırılmış, böylece 1500 görüntüden toplam 1.475 adet test örneği oluşturulmuştur. Bu yapı, modelin tahmin doğruluğunu zaman boyunca daha hassas bir şekilde değerlendirme olanağı sunmuştur.

Modelin eğitimi sırasında kullanılan bazı temel ayarlar aşağıda özetlenmiştir:


- Hata fonksiyonu (loss function): Binary cross-entropy
- Optimizasyon algoritması: Adam
- Öğrenme oranı: 0.001
- Mini yığın boyutu (batch size): 8
- Epoch sayısı: 100
- Değerlendirme metrikleri: KOH

Modelin eğitimi sırasında, yalnızca veri ile öğrenme değil; aynı zamanda öğrenme stratejilerinin dinamik kontrolü ve erken durdurma gibi düzenleyici önlemler de uygulanmıştır. Eğitim, 100 epok ile başlatılmış ancak erken durdurma ve öğrenme oranı yönetimi sayesinde süreç adaptif olarak yönetilmiştir. Modelin en iyi ağırlıkları, doğrulama kaybı (val_loss) esas alınarak otomatik olarak kaydedilmiştir. Eğitimde kullanılan stratejiler şu şekildedir:

- Erken durdurma (early stopping): Eğitim sırasında modelin doğrulama veri seti üzerindeki başarımı izlenmiş ve 20 eğitim döngüsü boyunca herhangi bir iyileşme görülmezse eğitim otomatik olarak durdurulmuştur. Bu, modelin gereğinden fazla eğitilerek ezberlemesinin önüne geçmek için kullanılmıştır.
- Modeli en iyi anda kaydetme (model checkpoint): Eğitim sürecinde modelin en başarılı olduğu epok (en düşük hata değeri elde edildiğinde) tespit edilerek bu noktadaki hali kaydedilmiş, böylece eğitim sonunda en iyi performansa sahip modelin elde tutulması sağlanmıştır.

- Öğrenme oranı ayarlama (learning rate scheduling): Modelin eğitim sırasında daha doğru öğrenebilmesi için başlangıçta yüksek öğrenme hızı kullanılmış, ardından belirli aralıklarla bu hız azaltılmıştır. İlk 15 epok boyunca öğrenme oranı 0.001 seviyesinde tutulmuş, ardından her yeni evrede bu oran sırasıyla yarıya, dörtte bire, altıda bire ve sekizde bire düşürülerek modelin daha kararlı öğrenmesi sağlanmıştır. Bu yöntem, modelin önce hızlı bir genel öğrenme yapmasını, ardından daha hassas ve kararlı ayarlamalarla sonuca ulaşmasını sağlamıştır.
- Eğitim günlüğü (loglama): Modelin her eğitim adımında elde ettiği başarı ve hata değerleri, sonradan incelenmek üzere günlük (log) dosyasına kaydedilmiştir. Bu sayede eğitim süreci görsel olarak da takip edilebilir hale getirilmiştir.

Eğitim işlemi sırasında kullanılan mini yığın (batch) boyutu 8 olarak belirlenmiştir. Yani model her seferinde 8 farklı 25 günlük veri örneğini aynı anda işleyerek öğrenmesini gerçekleştirmiştir. Eğitim süresince elde edilen Eğitim ve Doğrulama hatalarını gösteren grafik Şekil 48’de verilmiştir.



Şekil 48. ConvLSTM modelinin eğitim ve doğrulama hata eğrisi

Yukarıda, ConvLSTM modelinin eğitim ve doğrulama hatalarının epok sayısına göre değişimi gösterilmektedir. Grafik, modelin eğitim sürecinde istikrarlı bir şekilde öğrenme gerçekleştirdiğini ve doğrulama verisi üzerindeki başarımının da artarak aşırı öğrenme (overfitting) eğilimi göstermediğini açıkça ortaya koymaktadır. Özellikle 60. epoktan itibaren eğitim ve doğrulama eğrileri birbirine yaklaşıp kararlı bir seyir izlemektedir.

- ConvLSTM ile Deniz Seviyesi Anomali Tahminleri ve Performans Değerlendirmesi


ConvLSTM modelinin eğitimi tamamlandıktan sonra, modelin performansı test veri seti üzerinde değerlendirilmiştir. Bu değerlendirme sürecinde modelin, daha önce görmediği veriler karşısında ne kadar başarılı tahminler yaptığı analiz edilmiştir. Test veri setinde yer alan her örnek, geçmiş 25 gün boyunca gözlemlenen SLA verilerinden oluşmakta ve model bu verileri kullanarak 26. güne ait tahmini SLA haritasını üretmektedir.

Modelin başarısı hem sayısal hata metrikleri hem de konumsal hataların görselleştirilmesi ile değerlendirilmiştir. Sayısal değerlendirme KOH ve Pearson Korelasyon Katsayısı kullanılmıştır.

Tablo 18. Test veri setinde ConvLSTM model performansları

Performans Ölçütü	Değer
Karesel Ortalama Hata (mm)	6.88
Pearson Korelasyon Katsayısı	0.991

Tablo 18’de ConvLSTM modelinin test veri seti üzerinde elde ettiği temel performans ölçütleri özetlenmiştir. KOH değeri ± 6.88 mm olarak hesaplanmış olup, bu değer tahmin edilen SLA görüntülerinin gerçek verilerden ortalama ne kadar saptığını göstermektedir. Pearson Korelasyon Katsayısı da 0.991 ile oldukça yüksektir. Bu metrikler ConvLSTM modelinin hem konumsal hem de zamansal örüntüleri başarılı şekilde öğrendiğini ve Karadeniz gibi dinamik bir bölgede deniz seviyesi anomalilerini kısa vadeli olarak yüksek doğrulukla tahmin edebildiğini göstermektedir.



Şekil 49. ConvLSTM ağı için KOH dağılımı

Şekil 49’da ConvLSTM modelinin test verileri üzerinden elde ettiği tahmin hatalarının konumsal dağılımı gösterilmektedir. Harita dikkatle incelendiğinde şu bulgular öne çıkmaktadır:

- Açık deniz bölgelerinde (özellikle Karadeniz’in orta ve kuzeydoğu kesimlerinde) model oldukça başarılı tahminler yapmıştır. Bu bölgelerde ortalama KOH değerleri çoğunlukla $\pm 5\text{--}8$ mm seviyesindedir.
- Kıyıya yakın olan bölgelerde (örneğin Boğaziçi çıkışı, Gürcistan kıyıları, Trabzon açıkları) hatalar belirgin şekilde artış göstermektedir. Bu bölgelerde KOH değeri ± 15 mm’yi geçmektedir.

3.3.5. Uygulama 4: Sönümlü Kalıcılık Modeli ile Karadeniz’de Deniz Seviyesi Tahmini

- Yöntemin Tanımı ve Teorik Temeli

Sönümlü kalıcılık modeli (Damped Persistence Model), zaman serilerinde gelecekteki bir değer, geçmiş gözlemlerle tahmin edilmesi prensibine dayanan deterministik ve parametrik olmayan bir yaklaşımdır. Bu yöntem, özellikle meteoroloji, oşinografi ve çevresel süreç modelleme alanlarında hesaplaması kolay ve hızlı çözümler sunması nedeniyle sıklıkla başvurulmuş istatistiksel tahmin yöntemlerinden biridir.

Sönümlü kalıcılık modeli, aşağıdaki şekilde tanımlanır:

$$y_{\{t+k\}} = y_{\{t\}} * \phi^k \quad (74)$$

Burada:

y_{t+k} : $t+k$ zaman adımıdaki tahmin edilen değeri,

y_t : En güncel gözlem (referans) değeri,

ϕ : 0 ile 1 arasında tanımlanan sönümleme katsayısı (*damping factor*),

k : Öngörülen ileri yönlü tahmin adımı sayısı (lead time) olarak tanımlanır.

Bu çalışmada, kullanılan sönümleme katsayısı ϕ değeri, zaman serisinin otokorelasyon yapısı analiz edilerek belirlenmiştir. Tahmin sürecinde farklı tahmin adımlarına (örneğin 1, 2 veya 3 günlük ileri yönlü tahmin) karşılık gelen otokorelasyon değerleri alınmış ve bunların ortalaması kullanılarak sönümleme katsayısı hesaplanmıştır:

$$\phi = \frac{1}{K} \sum_{k=1}^K \rho_k \quad (75)$$

Burada ρ_k , k adımlık ileri yönlü tahmin için otokorelasyon katsayısını, K ise tahmin yapılacak adım sayısıdır (bu çalışmada $K=3$ olarak alınmıştır).

- Sönümlü Kalıcılık Modeli Tahmin Sonuçları

Sönümlü kalıcılık tahmin modeli, bu tez kapsamında yığılmış LSTM ve oto-kodlayıcı LSTM modelleri ile aynı koşullarda uygulanmış; her bir test örneği için geçmiş 25 günlük veriyi kullanarak 1, 2 ve 3 gün ileriye yönelik tahminlerde bulunmuştur. Modelin tahmin performansı aşağıda yer alan Tablo 19’da sunulmaktadır:

Tablo 19. Test veri setinde sönümlü kalıcılık modeli için performans sonuçları

İleri Tahmin	Karesel Ortalama Hata (mm)	Pearson Korelasyon Katsayısı
1 Gün	11.01	0.9913
2 Gün	15.68	0.9823
3 Gün	20.13	0.9707

Sonuçlar, sönümlü kalıcılık modelinin kısa vadeli tahminlerde (özellikle 1 günlük ileri tahmin için) yüksek doğruluk oranına sahip olduğunu göstermektedir. Pearson korelasyon katsayısının 0.9913 değeriyle, modelin gerçek zaman serisiyle güçlü bir doğrusal ilişki kurabildiği görülmektedir. Ancak tahmin ufkuzadıkça, hem KOH değerlerinde belirgin bir artış, hem de korelasyon katsayısında azalma gözlemlenmektedir.


Bu eğilimin, modelin basit yapısından kaynaklanan bir doğal sınırlılıktan kaynaklandığı değerlendirilmektedir. Model, geçmişe olan bağı üstel bir biçimde zayıflatarak geleceği öngörmeye çalışsa da bu yaklaşım karmaşık konumsal-zamansal

örüntülerin var olduğu durumlarda yetersiz kalabilir. Özellikle 3 gün tahminlerinde, hata değerleri derin öğrenme modellerine kıyasla ciddi şekilde artmaktadır.

Bu bağlamda sönümlü kalıcılık modeli:

- Basit, eğitimsiz ve hızlı çalışan bir yaklaşım sunması nedeniyle karşılaştırma amacıyla değerli bir yöntemdir.
- Ancak yüksek çözünürlük ve doğruluk gerektiren uygulamalarda derin öğrenme mimarilerinin gerisinde kalmaktadır.

Sönümlü kalıcılık modeli ile elde edilen tahminlerin konumsal hatalarını görselleştirmek amacıyla her bir tahmin ufku (1, 2 ve 3 gün) için KOH değerleri hesaplanmış ve Karadeniz genelinde haritalanmıştır. Bu görseller, modelin konumsal düzeyde hangi bölgelerde daha yüksek veya daha düşük performans gösterdiğini analiz etmeye olanak sağlamaktadır (Şekil 50).



Şekil 50.Sönümlü Kalıcılık Modeli için karşılaştırmalı KOH haritaları

Şekil 50a, 1 gün ileri tahminler için KOH değerlerinin Karadeniz genelinde düşük düzeyde kaldığını ve homojen bir dağılım sergilediğini göstermektedir. En düşük hata değerleri ± 10 mm civarına kadar inmekte, maksimum KOH ise ± 17 mm civarında seyretmektedir. Bu sonuç, modelin kısa vadeli öngörülerde genel trendleri başarıyla yakaladığını göstermektedir.

Tahmin ufku 2 güne çıktığında, Karadeniz'in özellikle batı ve doğu kıyı kesimlerinde KOH değerlerinin artmaya başladığı gözlemlenmektedir. Hata değerlerinin büyük bölümü ± 15 – 22 mm aralığında yoğunlaşmakta; bu durum, modelin performansının tahmin ufku uzadıkça düştüğünü göstermektedir.

3 gün ileriye yönelik tahminlerde modelin hataları daha da belirgin hale gelmektedir. Özellikle kuzeydoğu ve güneydoğu kıyı kesimlerinde KOH değerleri ± 25 mm'ye yaklaşmaktadır. Bu durum, modelin zaman ilerledikçe geçmiş verinin etkisini aşırıya kaçacak şekilde sönümlendiğini ve karmaşık konumsal dinamikleri yakalayamadığını göstermektedir.

Bu üç harita bir arada değerlendirildiğinde, sönümlü kalıcılık modelinin kısa vadede (1 gün ileri tahmin) makul doğrulukta tahminler üretebildiği; ancak tahmin süresi uzadıkça konumsal doğruluk kaybı yaşadığı görülmektedir.

3.3.6. Modellerin Performans Karşılaştırması ve Analizi

Bu bölümde, farklı derin öğrenme mimarileri (Yığılmış LSTM, Oto-Kodlayıcı LSTM, ConvLSTM) ile geleneksel bir yaklaşım olan Sönümlü Kalıcılık Model'inin, Karadeniz genelindeki deniz seviyesi anomalilerini tahmin etmedeki performansları karşılaştırılmıştır. Modellerin ortalama tahmin performansları, tahmin ufkuna (lead time) bağlı olarak ayrı ayrı değerlendirilmiştir (Tablo 20).

Kısa vadeli tahmin performansı açısından en düşük ortalama KOH değerine Oto-Kodlayıcı LSTM modeli ulaşmıştır ($KOH = \pm 4.633$ mm, $r = 0.9985$). Bu model, zaman serisinin hem konumsal hem zamansal yapısını temsil etmede güçlü bir yetenek sergilemiştir. Yığılmış LSTM modeli de oldukça benzer bir performans göstermiştir ($KOH = \pm 5.291$ mm). ConvLSTM mimarisi ise KOH değeri ± 6.88 mm olarak ölçülmüş ve r değeri 0.9910 ile oldukça yüksektir. Özellikle konumsal örüntülerin korunmasında başarılı olduğu gözlemlenmiştir. Sönümlü Kalıcılık modeli ise $KOH = \pm 11.01$ mm ile daha yüksek hata üretmiştir.

Tahmin süresi uzadıkça, tüm modellerin hata düzeyinde artış gözlemlenmiştir. Ancak bu artışın şiddeti modellere göre değişmektedir:

- 2 günlük tahmin ufku için en düşük KOH yine Oto-Kodlayıcı LSTM modelinde gözlenmiştir (± 8.02 mm). Yığılmış LSTM bu değere oldukça yakın performans sergilemiştir (± 8.37 mm).
- 3 günlük tahmin ufku tahmininde ise Oto-Kodlayıcı LSTM modeli yine bir adım önde olup, KOH değeri ± 11.38 mm olarak hesaplanmıştır.

Sönümlü Kalıcılık modeli, tahmin süresi uzadıkça daha belirgin performans kaybı göstermiştir. 3 gün sonrası için modelin KOH değeri ± 20.13 mm'ye yükselmiş, korelasyon katsayısı ise 0.9707'ye düşmüştür. Bu durum, modelin yapısı gereği uzak gelecek tahminlerinde güvenilirliğinin hızla azaldığını göstermektedir.

Tablo 20. Tahmin model performanslarının tahmin ufkuna göre performansları

Model	Tahmin Ufku	KOH (mm)	r
Yığılmış LSTM	1 Gün	± 5.29	0.9980
	2 Gün	± 8.37	0.9957
	3 Gün	± 11.49	0.9909
Oto-Kodlayıcı LSTM	1 Gün	± 4.63	0.9985
	2 Gün	± 8.02	0.9958
	3 Gün	± 11.38	0.9916
ConvLSTM	1 Gün	± 6.88	0.9910
	2 Gün	–	–
	3 Gün	–	–
Sönümlü Kalıcılık	1 Gün	± 11.01	0.9913
	2 Gün	± 15.68	0.9823
	3 Gün	± 20.13	0.9707


Tüm modellerin kısa vadede yüksek korelasyon değerleri sunduğu görülmekle birlikte, derin öğrenme tabanlı modeller (özellikle Oto-Kodlayıcı LSTM), hem kısa hem de orta vadeli tahminlerde daha düşük hata ile çalışmakta ve zamansal örüntüleri daha başarılı şekilde modelleyebilmektedir.

ConvLSTM, yalnızca 1 gün tahmin üretmiş olmasına rağmen, özellikle konumsal örüntü koruma açısından avantajlıdır. Ancak bu modelin tahmin ufku genişletildiğinde

performansını sürdürüp sürdüremeyeceği ayrı bir araştırma konusu olarak değerlendirilebilir.

Sönümlü Kalıcılık modeli ise hesaplama açısından basit ve hızlı bir referans modeli olmakla birlikte, doğruluk açısından derin öğrenme mimarilerinin gerisinde kalmaktadır.

Modellerin tahmin performanslarını daha detaylı inceleyebilmek amacıyla, Karadeniz'deki belirli bir konuma ait (Şekil 51a kırmızı nokta) deniz seviyesi değişimleri ve model tahminleri farklı tahmin ufukları (1 gün, 2 gün, 3 gün) için Şekil 51'de gösterilmiştir.



Şekil 51. Farklı tahmin modellerinin seçilen noktadaki (51a'da kırmızı işaretli nokta) SLA tahmin performansları


Modellerin ortalama performanslarına ilişkin değerlendirmeler, genel karşılaştırmalar için önemli bir referans sunmakla birlikte, bu tür analizler modelin her bir konumsal noktadaki tahmin başarısının dağılımını yeterince yansıtmayabilir. Özellikle Karadeniz gibi geniş ve dinamik değişkenlik gösteren bir bölgede, konuma bağlı olarak model başarısının ciddi şekilde farklılık gösterebileceği göz önünde bulundurulmalıdır. Bu nedenle, yalnızca ortalama KOH değerlerine odaklanmak yerine, modellerin minimum ve maksimum tahmin hatalarıyla birlikte, özellikle kutu grafikleriyle hata dağılımının görselleştirilmesi, modellerin tahmin kararlılığı ve güvenilirliği hakkında değerlendirmeye yapmaya olanak

tanıyabilir. Aşağıda sunulan Tablo 21, farklı tahmin modelleri için 1, 2 ve 3 günlük tahmin ufuklarında elde edilen en düşük ve en yüksek KOH değerlerini karşılaştırmalı olarak sunmaktadır. Ayrıca Şekil 52’de Karadeniz’deki her farklı konumdan elde edilen KOH değerlerinin dağılımları kutu grafikleri ile sunulmuştur. Böylece her modelin yalnızca ortalama tahmin performansını değil, aynı zamanda tahmin tutarlılığı da değerlendirilmiş olacaktır.


Tablo 21. Farklı tahmin ufuklarında modellerin minimum ve maksimum KOH değerleri

Tahmin Ufku	Model	Minimum KOH (mm)	Maksimum KOH (mm)
1 Gün	Sönümlü Kalıcılık	± 8.54	± 15.13
	Yığılmış LSTM	± 3.80	± 9.00
	Oto-Kodlayıcı LSTM	± 3.41	± 8.64
	ConvLSTM	± 4.17	± 10.08
2 Gün	Sönümlü Kalıcılık	± 12.29	± 21.80
	Yığılmış LSTM	± 5.62	± 13.11
	Oto-Kodlayıcı LSTM	± 5.81	± 12.75
	ConvLSTM	± 4.17	± 10.08
3 Gün	Sönümlü Kalıcılık	± 15.93	± 28.10
	Yığılmış LSTM	± 8.33	± 17.13
	Oto-Kodlayıcı LSTM	± 8.38	± 16.81
	ConvLSTM	± 4.17	± 10.08


Tablo 21’de sunulan değerler incelendiğinde, tüm tahmin ufuklarında, LSTM tabanlı modeller özellikle Oto-Kodlayıcı LSTM modeli en düşük minimum ve maksimum KOH değerleriyle öne çıkmaktadır. Örneğin, 1 günlük tahminlerde Oto-Kodlayıcı LSTM modeli ± 3.41 mm ile en düşük hata değerine ulaşırken, maksimum KOH değeri de yalnızca ± 8.64 mm ile sınırlı kalmıştır. Bu durum, modelin Karadeniz’in farklı bölgelerinde oldukça tutarlı tahminler üretebildiğini ortaya koymaktadır. Benzer şekilde, Yığılmış LSTM modeli de yüksek kararlılık sergileyerek ± 3.80 – 9.00 mm aralığında KOH değerleri üretmiştir. ConvLSTM modeli yalnızca 1 günlük tahminler için değerlendirilmiş olup, ± 4.17 mm’lik minimum ve ± 10.08 mm’lik maksimum KOH değerleriyle başarılı bir performans sunmuştur. Diğer yandan, Sönümlü Kalıcılık modeli tüm tahmin ufuklarında, özellikle 3 günlük tahmin ufukunda, daha yüksek maksimum KOH değerleri üretmiştir. 3 günlük tahminlerde ± 15.93 – 28.10 mm aralığına ulaşan hata değerleri, bu modelin uzun tahmin ufuklarında hem tutarlılığını kaybettiğini hem de bazı bölgelerde ciddi sapmalar oluşturduğunu göstermektedir.



(a)



(b)



(c)

Şekil 52. Yığılmış LSTM, LSTM Oto-Kodlayıcı ve sönümlü kalıcılık modellerine ait 1 gün (üst), 2 gün (orta) ve 3 gün (alt) tahmin ufukları için KOH ve r değerlerinin kutu grafikleri

Şekil 52 incelendiğinde, 1 günlük tahmin ufku için, oto-kodlayıcı LSTM, hem en düşük ortalama KOH değerine hem de en dar dağılıma sahiptir, bu da modelin tüm zaman serileri boyunca istikrarlı bir başarı gösterdiğini kanıtlamaktadır. Yığılmış LSTM ise benzer

düzeyde düşük KOH ve yüksek korelasyon sunmaktadır. Sönümlü kalıcılık modeli, daha yüksek ortalama KOH'a ve daha geniş dağılıma sahip olup, bazı uç değerlerde ciddi sapmalar üretmiştir.

2 günlük tahmin ufku için ise KOH değerleri genel olarak artmıştır, ancak oto-kodlayıcı ve yığılmış LSTM modelleri hala düşük sapma ve yüksek korelasyon düzeyini korumaktadır. Sönümlü kalıcılık modeli, bu tahmin ufkunda hem hata artışı hem de korelasyonda düşüş göstermiş, özellikle bazı zaman serilerinde çok daha büyük sapmalar üretmiştir.

3 günlük tahmin ufku için sönümlü kalıcılık modelinin başarısı belirgin biçimde zayıflamıştır. Hem KOH değerleri çok geniş bir aralıkta dağılmış, hem de korelasyon değerleri ciddi şekilde düşmüştür. Yığılmış LSTM ve oto-kodlayıcı modelleri ise 3 günlük tahminlerde bile dar dağılımlarla güvenilir sonuçlar üretmeye devam etmiş; bu durum da bu modellerin ileriye dönük genelleme yeteneğinin güçlü olduğunu göstermektedir.

Bu bölümde farklı derin öğrenme ve geleneksel istatistiksel modellerin Karadeniz'deki deniz seviyesi anomalilerini tahmin etme performansları hem sayısal metriklerle hem de konumsal-zamansal analizlerle kapsamlı biçimde değerlendirilmiştir. Sonuçlar, LSTM tabanlı modellerin, özellikle Oto-Kodlayıcı mimarisinin, hem düşük karesel ortalama hata oranları hem de yüksek doğruluk düzeyleri ile öne çıktığını göstermektedir. Yığılmış LSTM modeli ise benzer bir başarıyı daha klasik bir yapı ile yakalamayı başarmıştır. ConvLSTM mimarisi ise yalnızca 1 günlük tahminlerde test edilmesine rağmen yüksek tahmin performansı sunmuştur. Buna karşın, sönümlü kalıcılık modeli kısa vadede genel eğilimleri takip etmede yeterli olsa da özellikle tahmin ufku uzadıkça belirgin şekilde performans kaybı yaşamıştır. Bu bölümde sunulan grafikler de göstermiştir ki, derin öğrenme tabanlı modeller yalnızca yüksek doğruluk değil, aynı zamanda zaman serisi boyunca istikrarlı bir genelleme yeteneği sunmaktadır. Bu durum, modellerin sadece öğrenme süreçlerinde değil, gerçek uygulamalarda da güvenilir biçimde kullanılabileceğine işaret etmektedir.

Bu değerlendirmelerin ardından, modellerin yalnızca öğrenildikleri veri kümesi üzerinde değil, farklı kaynaklardan gelen yeni veri kümeleri üzerinde de ne ölçüde başarılı olabildiklerini ortaya koymak amacıyla genelleştirme kapasiteleri analiz edilmiştir. Bu doğrultuda bir sonraki bölümde, DUACS verisiyle eğitilen modellerin CMEMS uydu verileri ve yerinde gözlem (mareograf) istasyon verileri üzerindeki performansları ayrıntılı olarak incelenmiştir.

3.3.7. Genelleştirme Kabiliyeti Analizi ve Model Validasyonu

Derin öğrenme modellerinin performansı yalnızca eğitildikleri veri setleri üzerindeki performansları ile değil, aynı zamanda farklı kaynaklardan gelen veri kümeleri üzerinde de benzer doğruluk düzeylerini sürdürebilmeleriyle değerlendirilmektedir. Bu yetenek, literatürde genelleştirme kabiliyeti (generalization ability) olarak tanımlanmakta ve makine öğrenmesi modellerinin gerçek dünya uygulamaları açısından güvenilirliğinin temel ölçütlerinden biri olarak kabul edilmektedir.

Bu tez kapsamında eğitilen modellerin genelleme kapasitelerinin test edilmesi amacıyla, eğitimde kullanılan DUACS uydu altimetre veri seti dışında kalan farklı türde ve kaynaktan gelen veri kümeleri kullanılmıştır. Bu bağlamda:

- CMEMS (Copernicus Marine Environment Monitoring Service) tarafından sunulan alternatif uydu tabanlı SLA veri seti ve
- Türkiye kıyılarında yer alan TRAB mareograf istasyonundan elde edilen deniz seviyesi ölçüm verileri kullanılarak modellerin gerçek veriye yakın koşullarda test edilmesi sağlanmıştır.

Bu analiz, modellerin yalnızca DUACS veri setindeki örüntüleri öğrenip ezberlemediğini, aynı zamanda farklı çözünürlük, gürültü seviyesi ve kaynak yapısına sahip veriler karşısında da geçerliliğini koruyup koruyamadığını ortaya koymak açısından önemlidir.

Bununla birlikte, çalışmada kullanılan ConvLSTM (Evrişimli Uzun Kısa Süreli Bellek) modeli, diğer derin öğrenme mimarilerinden farklı olarak hem zamansal hem de konumsal örüntüleri birlikte işleyebilen bir yapıya sahiptir. Bu özellik, modelin girdi verisini dört boyutlu bir tensör şeklinde almasını zorunlu kılar: (zaman, yükseklik, genişlik, kanal). Bu tez kapsamında ConvLSTM modeli, DUACS veri setine ait 56×120 piksel boyutundaki SLA görüntülerinden oluşan zaman dizilerini kullanarak eğitilmiştir.

Ancak modelin genelleştirme analizinde kullanılmak istenen CMEMS veri seti, konumsal çözünürlük bakımından DUACS veri setinden oldukça farklıdır ve 261×591 piksel boyutunda çok daha yüksek çözünürlüklü bir konumsal yapı sunar. Bu boyut farkı nedeniyle CMEMS verisi, ConvLSTM modeline doğrudan girdi olarak verilememektedir; çünkü model yalnızca (25, 56, 120, 1) şeklindeki tensör yapısına uygun verileri işleyebilir. Veri yapılarının bu şekilde uyumsuz olması, doğrudan genelleştirme analizinin yapılmasını teknik olarak imkânsız hale getirmektedir.

Veri boyutunu eşleştirmek için uygulanabilecek en olası çözüm, aşağı örnekleme (downsampling) yöntemidir. Ancak yapılan ön denemelerde, yüksek çözünürlüklü CMEMS verisinin DUACS boyutuna indirgenmesi sırasında deniz seviyesi anomalilerine ilişkin önemli konumsal örüntülerin bozulduğu, dolayısıyla modelin gerçek dağılımları öğrenme ve tahmin etme kabiliyetinde ciddi kayıplar yaşandığı gözlemlenmiştir. Bu nedenle, veri boyutlarını zorla eşleştirerek genelleme analizi yapmak yerine, daha sağlıklı ve metodolojik açıdan doğru olduğu değerlendirilen bir yol izlenmiştir.

Bu doğrultuda ConvLSTM modeli, CMEMS veri seti ile yeniden eğitilmiş ve ardından aynı veri seti üzerinde test edilerek modelin performansı incelenmiştir. Bu metodoloji sayesinde modelin yalnızca DUACS verisiyle değil, aynı zamanda farklı konumsal çözünürlüğe sahip bir uydu veri setiyle de başarılı biçimde eğitilip tahmin yapabilir hale geldiği ortaya konmuştur. Bu yaklaşım, ConvLSTM mimarisinin mimari bağımlılıklarını ve çözünürlük duyarlılığını ortaya koymak açısından da değerlidir.

Bu nedenle, diğer modeller için “genelleştirme analizi” başlığı altında sunulan değerlendirme süreci, ConvLSTM modeli için “model validasyonu” başlığı altında ayrı bir başlıklandırma ile ele alınmıştır.

- Modellerin CMEMS Altimetre Veri Setindeki Genelleştirme Performansı
- Yığılmış Uzun Kısa Süreli Bellek Modeli Genelleştirme Performansı

Derin öğrenme tabanlı zaman serisi modellerinin başarısı, yalnızca eğitildikleri veri setleri üzerindeki performanslarıyla değil, aynı zamanda farklı kaynaklardan gelen yeni ve bağımsız veri kümeleri üzerindeki tahmin gücüyle de değerlendirilmelidir. Bu bağlamda, genelleştirme analizi; modelin, öğrenme sürecinde maruz kalmadığı veri karakteristikleri karşısında ne ölçüde doğru ve tutarlı tahminler üretebildiğini ölçmeyi amaçlamaktadır.

Bu bölümde, DUACS radar altimetre veri seti ile eğitilen Yığılmış LSTM modelinin tahmin performansı, farklı bir uydu altimetre ürünü olan CMEMS (Copernicus Marine Environment Monitoring Service) veri seti kullanılarak incelenmiştir. CMEMS, farklı bir uydu kombinasyonuna ve işleme algoritmasına dayandığından, modelin farklı konumsal çözünürlük ve işlenmiş veri yapılarına karşı olan duyarlılığı test edilmiştir.

Bu değerlendirme için KOH istatistiksel metriği kullanılmış, modelin farklı tahmin ufuklarında (1,2 ve 3 gün ileri) tahmin performansı incelenmiştir. Tüm Karadeniz genelinde, 261×591 çözünürlüğündeki CMEMS verisi üzerinde gerçekleştirilen test süreci kapsamında toplam 154.251 farklı zaman serisi değerlendirilmiş ve Yığılmış LSTM modeline ait tahmin performans metrikleri Tablo 22'de sunulmuştur.

Tablo 22. CMEMS veri seti üzerinde yığılmış LSTM modelinin 1 günlük tahmin performansı

Tahmin Ufku	Minimum KOH (mm)	Ortalama KOH (mm)	Maksimum KOH (mm)
1 Gün	± 4.69	± 23.61	± 74.36
2 Gün	± 16.64	± 39.62	± 133.01
3 Gün	± 16.64	± 43.00	± 133.67

Tablo 22’de sunulan sonuçlar, Yığılmış LSTM modelinin farklı tahmin ufuklarındaki genelleme kabiliyeti hakkında önemli bilgiler sağlamaktadır.


1 günlük tahminler için elde edilen minimum KOH değeri ± 4.69 mm gibi oldukça düşük bir hata düzeyine işaret etmekte, bu da modelin kısa vadeli öngörülerde yüksek doğrulukla çalışabildiğini göstermektedir. Ortalama KOH ’nın ± 23.61 mm olması, modelin Karadeniz genelinde kısa süreli öngörülerde genel hatlarıyla başarılı bir tahmin yapabildiğini teyit etmektedir. Bununla birlikte, ± 74.36 mm’lik maksimum hata değeri, özellikle kıyıya yakın veya hidro-dinamik açıdan karmaşık bölgelerde modelin performansının yer yer bozulabildiğini ortaya koymaktadır.

Tahmin ufku iki güne çıkarıldığında, hata değerlerinde belirgin bir artış gözlemlenmiştir. Ortalama KOH ± 39.62 mm’ye yükselirken, maksimum hata ± 133.01 mm’ye kadar çıkmıştır. Bu durum, modelin zaman ilerledikçe geçmiş veriye dayalı öngörü kabiliyetinin zayıfladığını göstermektedir.

Üç günlük tahminler için ortalama KOH değeri ± 43.00 mm olup, maksimum hata değeri ± 133.67 mm ile 2 günlük tahmin değerine yakın kalmıştır.

Genel olarak değerlendirildiğinde, Yığılmış LSTM modeli, kısa vadeli (1 günlük) tahminlerde oldukça güçlü ve güvenilir sonuçlar üretmektedir. Ancak tahmin ufku uzadıkça, modelin belirsizlikleri başa çıkma kabiliyeti azalmıştır.

Modelin konumsal tahmin performansını daha ayrıntılı analiz etmek amacıyla, Karadeniz genelinde CMEMS veri seti üzerinde hesaplanan KOH değerlerinin konumsal dağılımı görselleştirilmiştir. Şekil 53’te, modelin farklı bölgelerdeki tahmin performans farklılıklarını ortaya koymaktadır.



Şekil 53. CMEMS verisi üzerinde yığılmış LSTM modelinin KOH dağılımı (a – 1 gün ileri tahmin, b – 2 gün ileri tahmin, c – 3 gün ileri tahmin)

Şekil 53'te sunulan KOH dağılım haritaları, Yığılmış LSTM modelinin CMEMS veri seti üzerindeki konumsal tahmin başarımını farklı tahmin ufukları (1, 2 ve 3 gün) için ayrıntılı biçimde ortaya koymaktadır.

1 günlük tahminlerde (Şekil 53a), model genel olarak Karadeniz'in büyük bölümünde düşük hata seviyeleri sergilemiştir. Özellikle açık deniz bölgelerinde KOH değerleri $\pm 10-30$ mm aralığında kalmış, tahmin doğruluğu oldukça yüksek olmuştur. Ancak Batı Karadeniz kıyılarına yakın bölgelerde, özellikle Romanya ve Bulgaristan sahilleri civarında KOH değerlerinde artış gözlenmiştir.

2 günlük tahminlerde (Şekil 53b), genel hata seviyelerinde artış belirgin hale gelmiştir. Açık deniz alanlarında dahi KOH değerlerinin ortalama $\pm 30-50$ mm seviyelerine yükseldiği, kıyı bölgelerinde ise bu değerlerin ± 60 mm'nin üzerine çıktığı görülmüştür. Bu durum, tahmin ufku arttıkça hem zamansal hem de konumsal örüntü tahmininin zorlaştığını göstermektedir.

3 günlük tahminler (Şekil 53c) ise hata dağılımındaki artış eğiliminin devam ettiğini ve daha da belirginleştiğini ortaya koymuştur. Özellikle kuzeybatı Karadeniz kıyıları boyunca (örneğin Tuna Nehri'nin denize döküldüğü alan civarında) KOH değerlerinin ± 70 mm'yi aşan seviyelere ulaştığı görülmektedir. Açık denizlerde ise hata artışı daha sınırlı olmakla birlikte genel doğrulukta kayıplar yaşanmıştır.

Bu haritalar, Yığılmış LSTM modelinin açık denizlerde daha kararlı tahminler üretebildiğini, buna karşın kıyı bölgeleri ve karmaşık dinamiklere sahip alanlarda tahmin hatasının daha hızlı arttığını göstermektedir. Ayrıca tahmin ufku uzadıkça, özellikle kıyıya yakın bölgelerde hata büyümesinin daha belirgin olduğu anlaşılmaktadır. Bu bulgu, modelin kısa vadeli öngörülerde güçlü performans sergilediğini, ancak tahmin ufku uzadıkça modelin tahmin performansının azaldığını göstermektedir.

CMEMS model tahminlerinde özellikle dikkat çekici bir durum, kuzeybatı Karadeniz kıyılarında, özellikle Tuna Nehri'nin denize döküldüğü bölgelerde gözlenen yüksek hata değerleridir. Tuna Nehri'nin taşıdığı büyük miktarda tatlı su, sediment ve besin elementleri, bölgedeki hidro-dinamik yapının son derece heterojen ve zamansal olarak değişken olmasına yol açmaktadır.

Bu fiziksel karmaşıklık, derin öğrenme modellerinin, deniz seviyesi anomalilerini doğru şekilde tahmin etmesini güçleştirmektedir. Özellikle sediment birikimi, yoğunluk değişimleri ve lokal akıntıların etkisiyle, modelin eğitim verilerinde bulunmayan örüntüler ortaya çıkmakta ve bu da bölgesel tahmin hatalarının artmasına sebep olmaktadır.

Dolayısıyla, Tuna Nehri'nin Karadeniz'e döküldüğü delta bölgesi gibi karmaşık hidrografik alanlar model genelleme kapasitesi açısından doğası gereği daha yüksek hata seviyeleriyle ilişkilendirilmektedir.

– Oto-Kodlayıcı Uzun Kısa Süreli Bellek Modeli Genelleştirme Performansı

Bu bölümde, DUACS veri seti kullanılarak eğitilmiş olan Oto-Kodlayıcı LSTM modeli için farklı bir uydu veri kaynağı olan CMEMS (Copernicus Marine Environment Monitoring Service) veri seti üzerinde gerçekleştirilen genelleme testi sonuçları sunulmaktadır.

Oto-kodlayıcı yapılar, veriyi daha düşük boyutlu vektörlerle temsil ederek karmaşık zamansal örüntüleri öğrenme ve yeniden yapılandırma yetenekleriyle bilinir. Bu nedenle, modelin farklı bir veri kaynağı karşısındaki performansı, hem öğrenme sürecindeki örüntü kavrama başarısını hem de aşırı öğrenmeden (overfitting) kaçınma kapasitesini değerlendirmek açısından önemlidir.

Bu kapsamda, model doğrudan CMEMS veri seti üzerinde 1 günlük ileriye dönük tahminler üretmiş; elde edilen tahminler gerçek CMEMS SLA gözlemleri ile karşılaştırılmıştır (Tablo 23).

Tablo 23. CMEMS veri seti üzerinde Oto-Kodlayıcı LSTM modelinin tahmin performansı

Tahmin Ufku	Minimum KOH (mm)	Ortalama KOH (mm)	Maksimum KOH (mm)
1 Gün	± 10.40	± 21.86	± 67.83
2 Gün	± 14.88	± 29.18	± 72.22
3 Gün	± 19.41	± 34.91	± 75.84

1 günlük tahminler için modelin minimum KOH değeri ± 10.40 mm olarak hesaplanmış, ortalama hata değeri ise ± 21.86 mm olarak bulunmuştur. Bu sonuçlar, modelin kısa vadeli öngörülerde Karadeniz genelinde oldukça makul bir doğruluk düzeyine ulaştığını göstermektedir. Maksimum hata değeri olan ± 67.83 mm ise, belirli bölgelerde (muhtemelen kıyı etkileşimlerinin yoğun olduğu alanlarda) tahmin sapmalarının meydana geldiğini işaret etmektedir.

2 günlük tahminlerde, tahmin doğruluğunda azalma gözlenmiş; ortalama KOH değeri ± 29.18 mm'ye yükselmiş, maksimum hata değeri ise ± 72.22 mm'ye çıkmıştır. Bu eğilim, tahmin ufku uzadıkça, modelin örüntüleri tam olarak sürdürememe eğilimine girdiğini göstermektedir.

3 günlük tahminlerde ise ortalama KOH değeri ± 34.91 mm'ye ulaşmış ve maksimum hata ± 75.84 mm olarak ölçülmüştür. Bu sonuçlar, uzun vadeli öngörülerde modelin doğruluğunda kademeli bir düşüş yaşandığını ortaya koymaktadır.

Genel olarak değerlendirildiğinde, Oto-Kodlayıcı LSTM modeli, CMEMS veri seti üzerinde yüksek doğruluk sunmakta, ancak tahmin süresi uzadıkça hata seviyelerinde doğal bir artış gözlemlenmektedir.


Şekil 54'te sunulan KHO dağılım haritaları, Oto-Kodlayıcı LSTM modelinin CMEMS veri seti üzerindeki konumsal tahmin başarısını farklı tahmin ufukları için görselleştirmektedir.

1 günlük tahminlerde (Şekil 54a), modelin Karadeniz genelinde düşük hata değerleri sunduğu gözlemlenmektedir. Özellikle açık deniz bölgelerinde KOH değerlerinin ± 10 – 30 mm aralığında olduğu, kıyıya yaklaştıkça ise hata seviyelerinde kısmi bir artış eğilimi

görüldüğü dikkat çekmektedir. Bu sonuç, 1 günlük öngörülerde modelin zamansal başarıyla yakalayabildiğini göstermektedir.

2 günlük tahminlerde (Şekil 54b), genel hata seviyelerinde artış gözlenmiştir. Özellikle kuzeybatı Karadeniz kıyılarında (Tuna Nehri ağzı çevresi) ve doğu kıyı bölgelerinde KOH değerlerinin belirgin şekilde yükseldiği, ± 50 – 60 mm seviyelerine ulaştığı dikkat çekmektedir. Açık deniz alanlarında ise hata artışı görece daha sınırlı kalmıştır.

3 günlük tahminler (Şekil 54c) ise hata dağılımındaki artışın daha belirgin hale geldiğini göstermektedir. Kıyıya yakın bölgelerde KOH değerlerinin ± 60 mm'yi aştığı, bazı alanlarda ise ± 70 mm'ye yaklaşan hata seviyelerinin olduğu gözlemlenmiştir. Açık denizlerde dahi hata seviyelerinde artış eğilimi ortaya çıkmıştır.



Şekil 54. CMEMS verisi üzerinde Oto-Kodlayıcı LSTM modelinin KOH dağılımı (a – 1 gün ileri tahmin, b – 2 gün ileri tahmin, c – 3 gün ileri tahmin)

Elde edilen sonuçlar genel olarak değerlendirildiğinde, Oto-Kodlayıcı LSTM modeli CMEMS veri seti üzerinde kısa vadeli (1 günlük) tahminlerde güçlü bir genelleme performansı sergilemiştir. Ortalama hata değerleri ve konumsal hata dağılımı, modelin Karadeniz genelinde istikrarlı tahminler üretebildiğini göstermektedir.

Bununla birlikte, tahmin ufku uzadıkça (2 ve 3 gün) ortalama hata seviyelerinde artış gözlenmiştir. Özellikle kıyıya yakın ve hidro-dinamik açıdan karmaşık bölgelerde modelin tahmin doğruluğunda belirgin bir azalma meydana gelmiştir.

Buna karşın, tahmin ufku uzasa da hatalar nispeten kademeli bir şekilde artmış; herhangi bir tahmin ufkunda ani performans kayıpları veya modelin tamamen başarısız olduğu öngörüler gözlemlenmemiştir. Bu bulgu, oto-kodlayıcı mimarisinin, öğrenme sürecinde yakaladığı zamansal örüntülerin, farklı veri kaynakları üzerinde de belirli bir başarıyla sürdürülebildiğini göstermektedir.

Sonuç olarak, Oto-Kodlayıcı LSTM modeli, yalnızca DUACS veri seti üzerinde değil, aynı zamanda farklı kaynaklardan gelen yeni veriler üzerinde de yüksek doğruluk ve tutarlı genelleme kabiliyeti sergileyebilen bir derin öğrenme mimarisi olduğunu ortaya koymuştur.

- Evrişimli Uzun Kısa Süreli Bellek (ConvLSTM) Modelinin Validasyonu

Bu bölümde, DUACS veri seti ile eğitilen Evrişimli Uzun Kısa Süreli Bellek (ConvLSTM) modelinin CMEMS veri seti üzerindeki performansı değerlendirilmiştir. Ancak diğer modellerden farklı olarak, ConvLSTM modelinin giriş veri yapısı nedeniyle doğrudan genelleme analizi yapılamamıştır.

ConvLSTM modeli, (25, 56, 120, 1) şeklindeki dört boyutlu tensör yapısına dayalı olarak eğitilmiş olup, bu girdi veri formatı CMEMS veri setinin sunduğu (261, 591) çözünürlükle doğrudan uyumlu değildir. Farklı çözünürlükler arasında çözünürlük düşürme (downsampling) yapılmaya çalışıldığında ise ciddi bilgi kayıpları meydana gelmekte, bu da modelin gerçek performansını adil şekilde test etmeyi engellemektedir.

Bu nedenle, ConvLSTM modeli için klasik bir genelleme analizi yerine, CMEMS verisi kullanılarak modelin *yeniden eğitilmesi ve test edilmesi* stratejisi benimsenmiştir. Böylece modelin farklı bir veri kaynağındaki örüntüleri öğrenme performansı değerlendirilebilmiştir.

Aşağıda, CMEMS veri seti üzerinde yeniden eğitilen ConvLSTM modelinin eğitim süreci, performans metrikleri ve konumsal doğruluk dağılımına ilişkin analiz sonuçları sunulmaktadır.

– CMEMS Veri Seti Ön İşleme Süreçleri

Kullanılan veri seti, Copernicus Marine Environment Monitoring Service (CMEMS) tarafından sağlanan, günlük deniz seviyesi anomali (SLA) ölçümlerinden oluşmaktadır ve her bir gün için 261×591 piksel boyutunda NetCDF formatında veri içermektedir. İlk olarak, NetCDF formatındaki SLA verileri, matris formatına dönüştürülmüş ardından bu matrisler ConvLSTM modelinin görüntüler ile çalışıyor olması nedeniyle tek bantlı (siyah-beyaz) gri tonlamalı TIF görüntülerine çevrilmiştir. Tek bantlı TIF görüntüleri derin öğrenme mimarisinin eğitiminde ve test aşamalarında kullanılmadan önce normalize edilerek (minimum-maksimum normalizasyon ile) $[0,1]$ aralığına sıkıştırılmıştır.

Görüntülerin ön işleme sürecinin bir diğer önemli adımı da ConvLSTM mimarisinin kullanacağı tahmin penceresi boyutunun belirlenmesidir. Önceki çalışmada ConvLSTM mimarisi geçmiş 25 günlük veriden yararlanarak sonraki 1 günü tahmin etmekteydi. Ancak CMEMS veri seti çözünürlüğünün yüksek olması, hesaplama güçlükleri (yüksek işlemci kapasitesi gereklilikleri) nedeniyle 1 haftalık (7 günlük) tahmin penceresi kullanılmış, tahmin ufku ise önceki çalışmada olduğu gibi 1 gün olarak belirlenmiştir. Yani model geçmiş 1 haftalık verileri analiz ederek sonraki 1 güne ait deniz seviyesi anomali değerlerini tahmin etmektedir. Bu yapılandırma sonucunda, her bir giriş verisi (örnek) dört boyutlu bir tensör şeklinde tanımlanmıştır $(7,261,591,1)$.

Burada:

- 7 : Tahmin penceresi boyutu (geçmiş 7 gün),
- 261×591 : Konumsal çözünürlük (piksel boyutu),
- 1 : Kanal sayısıdır (tek bantlı gri tonlamalı görüntü).

Ön işleme süreci tamamlanan CMEMS deniz seviyesi anomali (SLA) veri seti, modelin eğitim, doğrulama ve test işlemleri için yeniden yapılandırılmıştır. Toplamda 741 günlük görüntüden oluşan bu veri seti, zaman sıralaması korunarak iki ana bölüme ayrılmıştır:

- İlk 630 günlük veri, modelin eğitim ve doğrulama süreçlerinde kullanılmak üzere tanımlanmıştır.
- Son 111 günlük veri ise test verisi olarak ayrılmıştır.

Eğitim ve doğrulama veri setleri 630 görüntü içerisinde, zaman sırası bozulmadan, 7 ardışık günden oluşan örnekler (mini yığınlar) rastgele seçilmiştir. Böylece hem zamansal örüntüler korunmuş hem de modelin öğrenme sürecinde farklı zaman aralıklarından gelen örneklerle karşılaşması sağlanarak etkin bir öğrenme süreci geçirmesi hedeflenmiştir.

Bu yapılandırma sonucunda oluşturulan veri setlerinin boyutları aşağıdaki gibidir:


Eğitim verisi : (75, 7, 261, 591, 1)

Doğrulama verisi : (15, 7, 261, 591, 1)

Test verisi : (104, 7, 261, 591, 1)

Buradaki “7” ifadesi, her bir örneğin geçmiş 7 günün SLA haritasını içerdiğini gösterir. İlk boyuttaki 75, 15 ve 104 sayıları ise oluşturulan mini yığın (mini batch) sayısını belirtir.

Test veri setinde ayrıca kayan pencere (sliding window) mekanizması uygulanmıştır. Bu mekanizma sayesinde, test verileri içinden çok sayıda ardışık örnek oluşturulabilmiş ve modelin genelleme yeteneği daha ayrıntılı biçimde değerlendirilebilmiştir. Veri bölüntüleme yapısına ilişkin ayrıntılar Şekil 55’te görsel olarak sunulmuştur.



Şekil 55. ConvLSTM modelinde kullanılan CMEMS veri setinin yeniden yapılandırılması.

– ConvLSTM Modelinin CMEMS Veri Seti Üzerinde Eğitilmesi

Bu bölümde, ConvLSTM mimarisine sahip derin öğrenme modelinin CMEMS veri seti kullanılarak yeniden eğitilme süreci detaylandırılmaktadır. Her bir mini yığın, geçmiş 7 ardışık günün SLA görüntülerini içermekte olup model, bu 7 günlük diziyi kullanarak 8. güne ait SLA haritasını tahmin etmeyi amaçlamaktadır. Girdi örnekleri bu nedenle (7, 261, 591, 1) boyutundaki tensörler şeklinde yapılandırılmıştır.

Kullanılan CMEMS veri seti, toplam 741 günlük SLA görüntüsünden oluşmaktadır.

Bu görüntüler:

- İlk 630 gün: Eğitim ve doğrulama amaçlı,
- Son 111 gün: Test amaçlı

olarak ayrılmıştır. İlk 630 günlük veri, zaman sıralaması bozulmadan ardışık 7 günlük bloklar hâlinde yeniden şekillendirilmiş; bu bloklar arasından rastgele seçim yapılarak eğitim ve doğrulama veri setleri oluşturulmuştur. Bu sayede model, farklı dönemlere ait örüntüleri öğrenme fırsatı bulmuş ve aşırı uyum (overfitting) riski azaltılmıştır.

Test veri setinde ise sabit adımlı (1 günlük) kayan pencere (sliding window) mekanizması kullanılmış; her adımda pencere bir gün ileri kaydırılarak test setinden 104 örnek oluşturulmuştur.

Modelin eğitimi sırasında kullanılan temel ayarlar aşağıdaki gibidir:


- Hata fonksiyonu (Loss function): Binary Cross-Entropy
- Optimizasyon algoritması: Adam
- Öğrenme oranı (initial): 0.001
- Mini yığın boyutu (Batch size): 8
- Epoch sayısı: 100
- Değerlendirme metrikleri: KOH

Model eğitimi sırasında yalnızca veriyle öğrenme değil, aynı zamanda çeşitli öğrenme stratejileri de kullanılmıştır. Bu kapsamda aşağıdaki stratejiler uygulanmıştır:

- Erken durdurma (Early stopping): Modelin doğrulama kaybı (val_loss) 20 ardışık epok boyunca iyileşme göstermemesi hâlinde eğitim süreci otomatik olarak durdurulmuştur. Bu yöntem, gereksiz eğitimi engelleyerek aşırı uyumun önüne geçmiştir.
- Modeli en iyi anda kaydetme (Model checkpoint): Eğitim sürecinde en düşük doğrulama kaybının elde edildiği epoğa ait model ağırlıkları otomatik olarak kaydedilmiş ve nihai model olarak bu sürüm korunmuştur.
- Öğrenme oranı ayarlama (Learning rate scheduling): Eğitim süresince, modelin daha verimli ve istikrarlı öğrenebilmesi için aşamalı bir öğrenme oranı azaltımı uygulanmıştır. Eğitim ilk 15 epok boyunca 0.001 öğrenme oranıyla yürütülmüş, ardından bu oran sırasıyla yarıya, dörtte bire, altıda bire ve sekizde bire düşürülmüştür. Böylece model önce genel örüntüleri öğrenmiş, ardından hassas detaylara odaklanabilmiştir.
- Eğitim günlüğü (Loglama): Eğitim sürecine ait hata ve doğruluk verileri CSV formatında kaydedilerek, sürecin hem metinsel hem de görsel olarak izlenebilirliği sağlanmıştır.

Eğitimde kullanılan yığın (batch) boyutu 8 olarak belirlenmiş; model her iterasyonda 8 farklı (7 günlük) veri bloğunu işleyerek ağırlıklarını güncellemiştir.

Eğitim sürecinde elde edilen eğitim ve doğrulama kaybı değerlerinin epoklara göre değişimi Şekil 56’da grafiksel olarak sunulmuştur. Grafikten de görüleceği üzere, her iki hata değeri de düzenli biçimde azalarak, modelin dengeli ve başarılı bir öğrenme gerçekleştirdiğini göstermektedir.



Şekil 56. ConvLSTM modelinin CMEMS veri seti ile eğitimine ilişkin eğitim ve doğrulama hata eğrileri

– CMEMS Veri Seti Üzerinde ConvLSTM Modelinin Test Sonuçları ve Model Performansının Değerlendirilmesi


Eğitim sürecinin ardından ConvLSTM modeli, CMEMS test veri seti ile değerlendirilmiş ve Karadeniz genelinde günlük deniz seviyesi anomalilerini (SLA) tahmin etme performansı ölçülmüştür.

Modelin test aşamasındaki performansı, tahmin edilen SLA haritaları ile gerçek gözlemler arasındaki farklara dayalı olarak hesaplanan Karesel Ortalama Hata metriği ile değerlendirilmiştir. ConvLSTM modelinin CMEMS veri seti test aşamasına ilişkin performansı Tablo 24’te sunulmuştur.

Tablo 24. CMEMS veri setinde ConvLSTM modelinin yeniden eğitim performansı

Tahmin Ufku	Minimum KOH (mm)	Ortalama KOH (mm)	Maksimum KOH (mm)
1 Gün	±1.24	±10.62	±18.10

Tablo 24 incelendiğinde, ConvLSTM modelinin CMEMS veri seti üzerindeki test performansının oldukça başarılı olduğu görülmektedir. Model, 1 günlük tahmin ufkunda Karadeniz genelinde minimum ± 1.24 mm, ortalama ± 10.62 mm ve maksimum ± 18.10 mm’lik bir karesel ortalama hatayla tahminler üretmiştir. Bu değerler, modelin düşük hata oranlarıyla çalıştığını göstermektedir. Özellikle maksimum hata değerinin ± 20 mm’nin altında kalması, ConvLSTM mimarisinin CMEMS veri setine de uyum sağlama kapasitesinin yüksek olduğunu ve SLA tahminlerinde güvenilir çıktılar ürettiğini ortaya koymaktadır. Modelin konumsal tahmin başarısını daha ayrıntılı değerlendirebilmek amacıyla, test sürecinde hesaplanan KOH değerlerinin Karadeniz genelindeki dağılımını gösteren hata haritası Şekil 57’de sunulmuştur.



Şekil 57. ConvLSTM modeli CMEMS test veri seti hata haritası

Şekil 57’de sunulan KOH haritası, ConvLSTM modelinin CMEMS test verisi üzerindeki konumsal tahmin performansını detaylı biçimde ortaya koymaktadır. Haritada genel olarak Karadeniz’in tamamında düşük hata değerleri gözlemlenmekte, bu durum modelin geniş coğrafi alanda istikrarlı bir tahmin başarısı sergilediğini göstermektedir. Karesel ortalama hatanın büyük bölümde ± 4 – 8 mm aralığında sınırlı kalması, modelin oldukça yüksek doğrulukla çalıştığını ortaya koymaktadır. Özellikle Karadeniz’in merkez kesimlerinde ve batı havzasının derin bölgelerinde hata düzeyleri minimum seviyelere yaklaşmıştır. Kıyı bölgelerinde ise görece daha yüksek hata değerleri gözlemlenmektedir.

Bununla birlikte, modelin hiçbir bölgede aşırı sapma göstermemesi, deniz seviyesi tahmininde ConvLSTM mimarisinin genel geçer bir başarıya ulaştığını gösterebilir.

- Derin Öğrenme Modellerinin Yerinde Gözlem Verileri Üzerindeki Genelleme Performansının Analizi


Bu bölümde, yalnızca uydu verisi (DUACS) ile eğitilen Yığılmış LSTM ve Oto-Kodlayıcı LSTM modellerinin, uydu dışı bağımsız bir veri kaynağı olan mareograf istasyonu verisi üzerindeki genelleme performansı değerlendirilmektedir. CMEMS uydu veri seti üzerinde yapılan genelleştirme analizleri, modelin farklı bir altimetre kaynağı karşısındaki genelleme yeteneğini ortaya koymuştur. Ancak modelin gerçek gözlemlerle olan uyumu, yalnızca uydu temelli veri ürünleriyle sınırlı kalmamalı; aynı zamanda yersel gözlem (in-situ) verileri ile de test edilmelidir. Bu kapsamda, Karadeniz kıyısında bulunan bir mareograf istasyonuna ait (TRAB) bağıl deniz seviyesi zaman serisi kullanılarak, modellerin konum ve veri kaynağı açısından farklı koşullarda gösterdiği tahmin başarısı analiz edilmiştir. Mareograf verileri, uydu altimetre sistemlerinden farklı olarak doğrudan karaya kurulan sensörler aracılığıyla ölçülmekte ve karasal bir noktaya göre bağıl su seviyesi değişimlerini yansıtmaktadır. Bu nedenle, modelin farklı veri türlerinden gelen verilerle yaptığı tahminlerin gerçek tahminlere ne ölçüde yaklaşabildiği konusunda önemli ve bağımsız bir test imkanı sunmaktadır. Böylece modellerin yalnızca eğitimde kullanılan veriye değil, farklı kaynaklardan gelen gerçek dünya gözlemlerine karşı da ne ölçüde genelleştirme yeteneğine sahip olduğu ortaya konulmuştur. Bu kapsamda, Karadeniz kıyısında Trabzon'da yer alan TRAB mareograf istasyonlarından elde edilen bağıl deniz seviyesi gözlemleri, DUACS veri seti ile eğitilmiş modellere girdi olarak verilmiş ve modelin bu istasyonlardaki tahmin performansı değerlendirilmiştir.

Bu analiz sürecine ConvLSTM modeli dahil edilmemiştir. Bunun nedeni, ConvLSTM mimarisinin eğitildiği veri formatının (görüntü temelli) mareograf istasyonu gibi noktasal zaman serileriyle uyumlu olmamasıdır. ConvLSTM modeli konumsal bilgi içeren veri yapısına ihtiyaç duymakta, oysa mareograf verileri yalnızca bir noktaya ait zamansal veriyi temsil etmektedir. Bu yapısal uyumsuzluk nedeniyle, ConvLSTM modelinin bu karşılaştırmaya dahil edilmesi mümkün olmamıştır. Bu bölümde yapılan analiz kapsamında, modellerin günlük bağıl deniz seviyesi tahminleri ile gerçek gözlem verileri karşılaştırılmış; KOH ve r metrikleri hesaplanmıştır.

Bu bölümde, DUACS veri seti kullanılarak tahmin ufukları 1, 2 ve 3 gün olacak şekilde ayrı ayrı eğitilmiş olan Yığılmış LSTM ve LSTM Oto-Kodlayıcı modellerinin, TRAB

mareograf verisi üzerindeki genelleştirme performansı analiz edilmiştir. Böylece her bir tahmin ufku için daha önce uydu altimetre verisi ile ayrı ayrı eğitilmiş olan modellerin, eğitimde hiç kullanılmamış ve uydu verilerinden tamamen bağımsız bir gözlem kaynağı üzerinde gösterdiği performans değerlendirilmektedir. Bu değerlendirme, modellerin farklı tahmin ufuklarında ne ölçüde genelleştirme yapabildiğini ve zamansal olarak ne kadar ileriye dönük başarılı öngörüler yapabildiğini anlamak açısından önem arz etmektedir. Elde edilen sonuçlar Tablo 25'e ve Şekil 58'de sunulmuştur.





Şekil 58. TRAB mareograf verisinde derin öğrenme model tahminleri

Tablo 25. TRAB bağıl deniz seviyesi zaman serisinde derin öğrenme modellerinin genelleştirme performansı

Tahmin Ufku	Model Adı	KOH (mm)	r
1 Gün	Yığılmış LSTM	± 41.29	0.9427
	Oto-Kodlayıcı LSTM	± 38.29	0.9474
2 Gün	Yığılmış LSTM	± 69.94	0.8542
	Oto-Kodlayıcı LSTM	± 56.28	0.8801
3 Gün	Yığılmış LSTM	± 83.30	0.7896
	Oto-Kodlayıcı LSTM	± 70.82	0.8092

Tablo 25’te sunulan sayısal sonuçlar ve Şekil 58 hem Yığılmış LSTM hem de Oto-Kodlayıcı LSTM modellerinin, yalnızca DUACS uydu altimetre verisi ile eğitilmiş olmalarına rağmen, mareograf istasyonundan elde edilen bağımsız gözlem verileri üzerinde anlamlı bir genelleme yeteneğine sahip olduklarını göstermektedir. Özellikle 1 günlük tahminlerde modellerin Pearson korelasyon değeri 0.94’ün üzerine çıkmış, Oto-Kodlayıcı LSTM modeli 38.29 mm KOH ve 0.9474 korelasyon değeri ile en başarılı sonucu üretmiştir. Grafiklerde de bu durum, tahmin eğrilerinin gözlem verisine oldukça yakın seyretmesiyle doğrulanmaktadır.

Burada özellikle vurgulanması gereken bir diğer önemli husus ise, modelin eğitildiği DUACS verisinin, ortalama deniz seviyesinden sapmayı (anomaliyi) ifade eden mutlak deniz seviyesi anomalisi (SLA) değerlerinden oluşmasına karşın; mareograf verilerinin ise yalnızca tek bir konumda ölçülen bağıl deniz seviyesi değişimlerini yansıttığı olmasıdır. Bu iki veri tipi ölçüm tekniği ve referans noktası açısından birbirinden oldukça farklıdır. SLA verileri uydu altimetrelerinden geniş alansal kapsama ile elde edilirken, mareograf verileri yerel etkileri de barındıran noktasal ölçümlerdir. Buna rağmen modellerin bu kadar yakın tahminler üretmesi, öğrenilen zamansal desenlerin, farklı veri kaynaklarına da başarıyla aktarılabilirdiğini ortaya koymaktadır.

Tahmin ufku arttıkça (2 ve 3 gün) model performansında azalma gözlense de Oto-Kodlayıcı LSTM modeli tüm adımlarda daha düşük KOH ve daha yüksek korelasyon değeriyle üstünlüğünü korumuştur. Özellikle 3 günlük tahminlerde bile genel eğilimin doğru şekilde yakalanması, eğitimin yalnızca DUACS verisiyle yapılmış olmasına karşın modellerin yüksek düzeyde genellenebilir örüntüler öğrenebildiğini göstermektedir.


3.4. Karadeniz Deniz Seviyesi Erken Uyarı Sisteminin Tasarımı ve Uygulaması: TideGuard Yazılımı

Bu bölümde, derin öğrenme temelli bir deniz seviyesi erken uyarı sisteminin tasarımı ve uygulanması anlatılmaktadır. TideGuard adı verilen bu sistem, daha önce CMEMS uydu verisi ile yeniden eğitilmiş olan ConvLSTM mimarili model temel alınarak geliştirilmiştir. Amaç, Karadeniz genelinde günlük deniz seviyesi anomalilerini öngörerek, olası risklere karşı erken uyarı sağlayacak bir yazılım altyapısı oluşturmaktır.

TideGuard yazılımı, modelin tahmin yeteneğini 15 güne kadar uzatmak için ardışık genişleyen pencere (expanding window) yaklaşımını kullanır. Bu yaklaşımda modelin her yeni tahmini, bir sonraki tahminin girdisine dahil edilir. Bu yaklaşım aşağıdaki şekilde çalışır:

1. Model, geçmiş 7 günlük gerçek SLA verisini alır ve 8. günü tahmin eder.
2. Tahmin edilen 8. gün verisi, artık girdi verisinin bir parçası olur. Model bu kez 1–8. gün verisini kullanarak 9. günü tahmin eder.
3. Bu döngü, tahmin edilen her yeni günü girdi kümesine ekleyerek 15. güne kadar devam eder.

Yani model, başta yalnızca gözlemlenen verilerle çalışırken, tahmin ilerledikçe kendi ürettiği tahminleri de girdi verisi olarak kullanmaya başlar. Bu sayede tahmin penceresi zaman içinde genişler (Şekil 59). Ancak bu yöntemin doğal bir sınırlılığı vardır: Her yeni tahmin önceki tahminlere dayanarak üretildiğinden için, model hataları zamanla birikebilir ve modelin tahmin doğruluğunda azalma görülebilir. Bu nedenle, sistemin uzun vadeli tutarlılığı bu bölümde özel olarak incelenmiştir.



Şekil 59. Erken uyarı sisteminde kullanılan ardışık genişleyen pencere yaklaşımı

3.4.1. Sistem Mimarisi ve Fonksiyonları

TideGuard, Karadeniz bölgesi için geliştirilen ve deniz seviyesi anomalisi tahminlerine dayalı erken uyarı sağlayan masaüstü bir yazılımdır. Python programlama diliyle geliştirilen yazılım, PyQt5 ile oluşturulmuş modern bir grafiksel kullanıcı arayüzü (GUI) sunmakta ve arka planda TensorFlow-Keras tabanlı bir ConvLSTM modeli barındırmaktadır. TideGuard'ın temel amacı, geçmiş deniz seviyesi anomalisi (SLA) verilerini kullanarak, kullanıcı tanımlı uzunlukta geleceğe yönelik tahminler üretmek ve bu tahminleri görselleştirilmiş harita formatında kullanıcılara sunmaktır.

Sistem içerisinde, Copernicus Marine Environment Monitoring Service (CMEMS) veri merkezine bağlanan özel bir FTP (Dosya Transfer Protokolü – File Transfer Protocol) istemcisi yer almaktadır. Bu sayede kullanıcılar herhangi bir harici dosya indirmesi gerçekleştirilmeden, yalnızca CMEMS veri merkezi kullanıcı adı ve şifre bilgilerini girerek güncel SLA verilerini doğrudan TideGuard arayüzü üzerinden edinebilmektedir. Ardından, kullanıcı tahmin süresini (örneğin 1 ila 15 gün arası) belirleyerek modeli çalıştırabilir.

Yazılım, tahmin işlemlerini bilgisayarda yerel olarak tutulan .keras uzantılı, önceden eğitilmiş bir ConvLSTM modeli aracılığıyla gerçekleştirir. Tahmin süreci, ardışık genişleyen pencere yaklaşımıyla ilerler: İlk 7 günün verisiyle 8. gün tahmin edilir, daha sonra bu tahmin 9. gün tahmini için girdi verisine eklenir ve bu şekilde 15. güne kadar iteratif tahmin gerçekleştirilir.

Tahmin tamamlandıktan sonra elde edilen SLA haritaları sistem arayüzünde görselleştirilir. Kullanıcılar, bu çıktıları farklı dosya formatlarında (.tif, .xlsx, .npy, .txt, .csv) dışa aktarabilir. Ayrıca çözünürlük (300 dpi) ve çıktı klasörü kullanıcı tarafından özelleştirilebilir. Yazılımın kullanıcı dostu arayüzü, karmaşık model süreçlerini son kullanıcı için sade ve erişilebilir hale getirir.


3.4.2. Kullanıcı Arayüzü Tasarımı

TideGuard yazılımının kullanıcı arayüzü, sade ve yönlendirici bir yapıda tasarlanmış olup, farklı işlevlerin tek bir pencere üzerinden yönetilebildiği Stacked Widget yaklaşımı ile yapılandırılmıştır. Bu yapı sayesinde kullanıcı, adım adım ilerleyerek veri indirme, tahmin ayarlarını yapma, tahminleri başlatma ve sonuçları görüntüleme işlemlerini sıralı bir akış

içerisinde gerçekleştirebilmektedir (Şekil 60). Her işlem adımı, bir önceki tamamlandıktan sonra otomatik olarak bir sonraki pencereye geçiş sağlar.

Kullanıcılar arayüz üzerinden yalnızca Copernicus Marine Environment Monitoring Service (CMEMS) veri merkezine ait FTP bağlantısı bilgilerini girerek, güncel deniz seviyesi anomali (SLA) verilerini kolaylıkla indirebilmektedir. İndirme işlemi sonrası kullanıcı, tahmin süresini (1 ila 15 gün arası) seçerek tahmin işlemini başlatabilir. Tahmin süreci tamamlandığında elde edilen tüm SLA haritaları otomatik olarak arayüzde görselleştirilir. Her bir gün için üretilen tahmin sonuçları ayrı ayrı harita panelinde görüntülenir.

Arayüz, yalnızca İngilizce dil desteği ile sunulmuştur. Görselleştirme bölümünde, kullanıcı fare imlecini harita üzerinde gezdirerek, o konuma ait tahmin edilen SLA değerini doğrudan inceleyebilir. Böylece kullanıcı, sayısal veriye doğrudan görsel arayüz üzerinden erişim sağlayabilmektedir. Bu özellik, karar vericiler ve araştırmacılar açısından görsel-analitik bütünlüğü sağlamada önemli bir kolaylık sunmaktadır.




Şekil 60. Tideguard yazılımı arayüzü iş akışı

3.4.3. Erken Uyarı Sisteminin Performans Analizi ve Simülasyonlar


Bu bölümde, geliştirilen TideGuard yazılımının erken uyarı sistemi olarak performansı detaylı bir şekilde analiz edilmiştir. Yazılımın temelini oluşturan ConvLSTM modeli, daha önce CMEMS uydu verileriyle eğitilmiş olup, bu bölümde ardışık tahmin üretme yeteneği ayrıntılı olarak değerlendirilmiştir. Modelin performansı yalnızca tek adımlık tahminlerle sınırlı kalmayıp, 15 gün ileriye dönük ardışık tahminleri kapsayacak şekilde test edilmiştir. Erken uyarı sisteminin değerlendirilmesi amacıyla, farklı tarih aralıklarına yayılan toplam 75 simülasyon gerçekleştirilmiş ve her biri 15 günlük ardışık tahmin içerecek şekilde yapılandırılmıştır. Bu simülasyonlar 2021 Ekim ile 2023 Temmuz arasındaki dönemi kapsamaktadır.

Her bir simülasyonda, model geçmiş 7 günün SLA haritalarını kullanarak 8. günü tahmin etmiş; ardından bu tahmini giriş verisine ekleyerek 9. günü, 10. günü vb. olmak üzere toplam 15 güne kadar tahmin zinciri oluşturmuştur. Bu yöntemde, tahmin edilen her yeni gün verisi, bir sonraki tahminin girdisine dahil edilmektedir.

Modelin her tahmin günündeki performansı, tahmin edilen SLA haritaları ile gözlemlenen gerçek SLA verileri arasındaki farklara göre hesaplanan KOH ve Pearson Korelasyon Katsayısı (r) metrikleri ile değerlendirilmiştir. Bu metrikler hem günlük bazda hem de tüm simülasyonlar üzerinden istatistiksel olarak analiz edilmiştir. Şekil 61 ve 62 ısı haritaları, sırasıyla her bir simülasyona ve tahmin gününe karşılık gelen Pearson korelasyon katsayısı ve KOH değerlerini göstermektedir.



Şekil 61. Simülasyonlar sonucunda elde edilen korelasyon ısı haritası




Şekil 62. Simülasyonlar sonucunda elde edilen KOH ısı haritası


Şekil 61 incelendiğinde genel olarak yüksek korelasyon katsayılarının baskın olduğu görülmektedir. Birçok simülasyon boyunca 0.8 ve üzeri korelasyon değerleri elde edilmiştir. Bu durum modelin tahmin ettiği zaman serilerinin genel eğilim ve örüntüleri doğru şekilde

yansıttığını göstermektedir. Bununla birlikte bazı simülasyonlarda (örneğin 12–20. simülasyonlar arası) korelasyonun 0.4'ün altına düşebildiği ve modelin zayıf tahmin yaptığı örneklerin olduğu gözlemlenmektedir. Bu tür durumların olası nedenleri, kullanılan eğitimin bu dönemlere ait örüntüleri yeterince kapsayamamış olması ya da deniz seviyesi anomalilerinin bu dönemlerde beklenmedik değişimlere uğraması olabilir.

Benzer bir eğilim KOH haritasında da gözlemlenmektedir. Pek çok gün ve simülasyon boyunca hataların ± 10 mm'nin altında kaldığı görülmektedir. Ancak bazı örneklerde (örneğin 5. ve 44. simülasyonlarda) tahmin hatalarının yer yer yükseldiği dikkat çekmektedir. Yine de genel eğilim değerlendirildiğinde hem korelasyon hem de KOH metrikleri, ardışık tahminlerde modelin başarılı bir şekilde eğitildiğini ve erken uyarı sistemi olarak kullanılabilir bir doğruluk sunduğunu göstermektedir. Şekil 63 ve 64'te 75 simülasyon boyunca her güne ait ortalama tahmin performansları verilmiştir.



Şekil 63. Simülasyonlar sonucunda tahmin günlerine göre elde edilen ortalama korelasyon katsayıları



Şekil 64. Simülasyonlar sonucunda tahmin günlerine göre elde edilen ortalama KOH değerleri

Şekil 63 ve Şekil 64, TideGuard erken uyarı sisteminin ardışık 15 günlük tahmin sürecine ilişkin ortalama performans düzeylerini zamansal olarak özetlemektedir. Şekil 63'te her bir tahmin günü için korelasyon katsayısı ortalamaları; Şekil 64'te ise KOH değerlerinin ortalamaları sunulmaktadır. Bu grafikler, sistemin tahmin doğruluğunun zaman içerisinde nasıl değiştiğine ilişkin genel eğilimleri ortaya koymaktadır.

Şekil 63'e göre, 1. gün tahminlerinin ortalama korelasyon katsayısı 0.88 gibi oldukça yüksek bir düzeydedir. Bu değer, 6. günden itibaren 0.80 seviyelerine kadar düşmekte, ancak 15. güne kadar tekrar toparlanma eğilimi göstermektedir. Tüm günler için ortalama korelasyon değerlerinin 0.80'in üzerinde kalmış olması, sistemin uzatılmış tahmin ufuklarında dahi konumsal-zamansal örüntüleri büyük ölçüde koruyabildiğini göstermektedir.

Şekil 64 incelendiğinde, tahmin süresi ilerledikçe doğruluğun kademeli bir şekilde bozulduğu yönünde net bir eğilim bulunmadığı gözlemlenmektedir. Örneğin, 1. gün için ortalama KOH değeri ± 4.33 mm iken, bu değer 2. ve 3. günlerde sırasıyla ± 5.30 mm ve ± 5.50 mm'ye yükselmekte, ancak 4. gün için tekrar ± 4.71 mm'ye düşmektedir. Benzer şekilde, 6. ve 7. günlerde artış görülse de 10. günde hata değeri yeniden azalarak ± 5.06 mm'ye düşmektedir.

Bu dalgalı yapı, ardışık tahmin mekanizmasından kaynaklanan potansiyel hata birikiminin, her zaman doğrusal ya da istikrarlı bir artış şeklinde tezahür etmediğini göstermektedir. Bununla birlikte, tüm tahmin günlerinde KOH değerlerinin ± 7 mm'nin


altında kalması, sistemin hata düzeyini kontrol altında tutabildiğini ve erken uyarı uygulamaları için güvenilir bir çözüm sunduğunu desteklemektedir.

TideGuard erken uyarı sisteminin performansını daha kapsamlı değerlendirmek amacıyla, 75 farklı tarih aralığında gerçekleştirilen 15 günlük simülasyonlara ait tahmin sonuçları istatistiksel olarak da analiz edilmiştir. Bu analiz kapsamında, hem tahmin edilen deniz seviyesi anomali değerlerinin gözlemlerle olan doğrusal ilişkisini (korelasyon katsayısı) hem de mutlak hata büyüklüklerini (Karesel Ortalama Hata) gösteren iki ayrı histogram grafiği hazırlanmıştır. Bu görseller, sistemin tahmin performansını yalnızca tekil örnekler bazında değil, genel dağılım eğilimleriyle de ortaya koymaktadır (Şekil 65 ve 66).


Şekil 65, 75 farklı simülasyonun her biri için hesaplanan günlük korelasyon katsayılarının frekans dağılımını göstermektedir. Dağılımın büyük ölçüde 0.8–0.95 aralığında yoğunlaştığı, mod değerinin ise yaklaşık 0.9 seviyesinde olduğu görülmektedir. Bu durum, tahmin edilen SLA verilerinin çoğunlukla gerçek verilerle yüksek doğrusal uyum gösterdiğini kanıtlamaktadır. Korelasyon katsayısının düşük olduğu uç örnekler az sayıda olup, sistemin genelde istikrarlı doğruluk sunduğunu desteklemektedir.

Şekil 66 ise tüm simülasyon günleri boyunca elde edilen karesel ortalama hata değerlerinin dağılımını göstermektedir. En sık gözlemlenen hata değerleri ± 0 –10 mm aralığında yoğunlaşmakta olup, bu da modelin yüksek hassasiyetle çalıştığını ortaya koymaktadır. KOH değerlerinin çoğunlukla ± 5 mm civarında olduğu, ancak birkaç uç simülasyonda ± 40 mm'ye kadar çıktığı görülmektedir. Bu, sistemin zaman zaman spesifik tarih veya koşullarda hata birikimine maruz kalabileceğini, ancak genel hatlarıyla yüksek performans gösterdiğini ortaya koymaktadır.

Her iki grafik birlikte değerlendirildiğinde, TideGuard sisteminin yalnızca ortalama metrikler bazında değil, aynı zamanda istatistiksel dağılımlar açısından da güvenilir ve tutarlı bir tahmin performansı sunduğu sonucuna ulaşılabilir.




Şekil 65. Simülasyonlar sonucunda elde edilen korelasyon sonuçlarının dağılımı




Şekil 66. Simülasyonlar sonucunda elde edilen KOH sonuçlarının dağılımı

Benzer sonuçlar KOH ve Pearson korelasyon sonuçlarının kümülatif dağılım grafiklerinde daha açık şekilde gözlemlenebilir (Şekil 67 ve 68).



Şekil 67. Simülasyonlar sonucunda elde edilen korelasyon sonuçlarının kümülatif dağılımı



Şekil 68. Simülasyonlar sonucunda elde edilen KOH sonuçlarının kümülatif dağılımı

Şekil 67’de yer alan korelasyon katsayısı kümülatif dağılımına göre, tüm tahmin sonuçlarının yaklaşık sadece %23’ü 0.8 altında korelasyon düzeyine sahiptir. Yani tüm tahmin sonuçlarının yaklaşık %77’si 0.8 ve üzeri korelasyon düzeyine ulaşmıştır. Bu durum, modelin tahmin ettiği deniz seviyesi anomalisi verileri ile gözlenen veriler arasında yüksek derecede doğrusal bir ilişki bulunduğunu göstermektedir. Şekil 68’deki KOH kümülatif dağılım grafiği ise, tahminlerin %86’sının ± 10 mm’nin altında bir hata ile üretildiğini ortaya koymaktadır. Bu sonuçlara göre erken uyarı sistemi genellikle düşük hata düzeyiyle

çalışmakta ve tahmin performansının uygulamada kabul edilebilir sınırlar içinde kaldığını teyit etmektedir.

TideGuard erken uyarı yazılımı ile yürütülen ardışık tahmin simülasyonları, modelin Karadeniz'deki deniz seviyesi anomalilerini 15 güne kadar tahmin etme yeteneğini kapsamlı bir şekilde ortaya koymuştur. Gerçekleştirilen 75 bağımsız simülasyonun her biri, geçmiş 7 günlük SLA verisinden başlayarak gün gün tahminlerin genişletildiği ve bu tahminlerin bir sonrakine girdi olarak kullanıldığı ardışık yapı sayesinde hem kısa hem de orta vadeli öngörü performansını değerlendirme olanağı sağlamıştır. Simülasyonların her bir günü için hesaplanan KOH ve korelasyon katsayısı değerleri, sistemin farklı günlerdeki tahmin güvenilirliğini nicel olarak değerlendirmiştir.

Isı haritaları (Şekil 61 ve 62) üzerinden yapılan görsel analizler, özellikle çoğu günde yüksek korelasyon ve düşük hata düzeylerinin sistematik şekilde sağlandığını, ancak bazı örneklem aralıklarında hata birikiminin etkilerinin kısmi olarak görülebildiğini göstermektedir. Bununla birlikte, ortalama metrik değerlerinin günlük bazda incelendiği sütun grafikler (Şekil 63 ve 64), sistemin istikrarlı bir performans sergilediğini ortaya koymuştur. Ortalama KOH değeri 1. tahmin günü için ± 4.33 mm iken, bu değer en yüksek seviyeye 12. günde ± 6.56 mm olarak ulaşmıştır. Bu artış beklenen bir eğilim olmakla birlikte, ardışık yapıya rağmen performansta ani düşüşlerin yaşanmamış olması, modelin uzun vadede de tahmin performansını koruyabildiğini göstermektedir. Benzer şekilde, ortalama korelasyon katsayısı tüm günler boyunca 0.80'in üzerinde seyretmiş; bu da sistemin tahmin edilen veriler ile gerçek gözlemler arasındaki doğrusal ilişkiyi yüksek düzeyde koruduğunu kanıtlamaktadır.

Dağılım grafikleri ve kümülatif dağılım fonksiyonları incelendiğinde (Şekil 65, 66, 67 ve 68), tahminlerin çok büyük bir kısmının düşük hata ve yüksek korelasyon aralığında yoğunlaştığı görülmektedir. Korelasyon katsayısı dağılımına göre tahminlerin %77'si 0.80 üzerindeyken, KOH dağılımına göre tahminlerin %86'sı ± 10 mm altında kalmıştır. Bu bulgular, yalnızca ortalama metriklerin değil, aynı zamanda dağılımların da performans açısından elverişli olduğunu ortaya koymaktadır.

Genel değerlendirme açısından bakıldığında, TideGuard yazılımı hem bilimsel doğruluk hem de operasyonel kullanılabilirlik açısından güçlü bir erken uyarı sistemi prototipi olarak öne çıkmaktadır. Sistem, yalnızca geçmiş verilerden yola çıkarak öngörü üretmekle kalmamakta; aynı zamanda tahmin çıktılarının kullanıcıya görsel olarak sunulması, esnek tahmin uzunluğu belirlenebilmesi, veri dışı aktarımı gibi nitelikleriyle de

kullanıcı dostu bir karar destek aracı kimliği kazanmaktadır. Bu kapsamda yapılan simülasyonlar, erken uyarı sisteminin sahada kullanılabilirliğini doğrulamakta ve ilerleyen dönemlerde farklı deniz alanlarına da genişletilebilecek potansiyele sahip olduğunu göstermektedir.

3.5. Çevresel Modelleme İçin Açık Kaynak Kodlu Derin Öğrenme Yazılımı Tasarımı ve Uygulaması: Envilearn Yazılımı

Bu tez çalışmasında elde edilen bilimsel ve teknik bilgi birikiminin, yalnızca teorik düzeyde kalmayıp pratik bir uygulama aracına da dönüştürülmesi hedeflenmiştir. Bu kapsamda geliştirilen Envilearn yazılımı, çevresel değişkenlerin derin öğrenme mimarileri ile modellenmesini kolaylaştırmak amacıyla tasarlanmış açık kaynak kodlu bir masaüstü uygulamasıdır. Python programlama diliyle geliştirilen ve kullanıcı arayüzü PyQt5 modülü kullanılarak oluşturulan yazılım, herhangi bir programlama bilgisine sahip olmayan kullanıcıların dahi karmaşık derin öğrenme modellerini tanımlayabilmesini, eğitebilmesini, değerlendirebilmesini ve görselleştirebilmesini sağlamaktadır. Envilearn yazılımı hem zaman serisi verilerinin hem de konumsal-zamansal yapıya sahip görüntü verilerinin modellenmesine olanak tanımaktadır.

Yazılım, LSTM ağları ile zaman serisi modelleme ve ConvLSTM ağları ile zamansal ve konumsal bağımlılık içeren veri yapılarını desteklemektedir. Kullanıcılar, veri yükleme sürecinden modelin katman mimarisinin tanımlanmasına, hiperparametrelerin ayarlanmasından model eğitimi sırasında kullanılacak eğitim stratejilerinin entegrasyonuna kadar tüm süreci yazılım arayüzü üzerinden gerçekleştirebilmektedir. Ayrıca eğitim sürecine ait hata grafiklerinin görselleştirilmesi, eğitilmiş modelin kaydedilmesi ve daha sonra yüklenerek yeniden tahmin yapılabilmesi gibi ileri seviye işlevler de yazılıma entegre edilmiştir.

Envilearn yazılımı, esas olarak Karadeniz'deki deniz seviyesi değişimlerinin tahminine yönelik olarak geliştirilen bu doktora çalışmasının bir çıktısı olmakla birlikte; sunduğu esnek veri girdi formatları (tiff, txt, csv), çoklu modelleme mimarisi ve kullanıcı dostu yapısı sayesinde farklı çevresel modelleme problemleri için de geniş bir uygulama alanı sunmaktadır.


3.5.1. Arayüz Tasarımı ve Geliştirme Süreci

Envilearn yazılımının arayüz tasarımı, kullanıcıların herhangi bir programlama bilgisine sahip olmadan derin öğrenme temelli çevresel modelleme süreçlerini yönetebilmelerine olanak tanıyacak şekilde yapılandırılmıştır. Geliştirme sürecinde Python programlama dili ve PyQt5 grafik kullanıcı arayüzü (GUI) kütüphanesi kullanılmış, arayüzün görsel tasarımı ise Qt Designer aracı ile gerçekleştirilmiştir. Tasarım sürecinde hedef, sade, anlaşılır ve işlevsel bir kullanıcı deneyimi sunarak modelleme sürecini herkes için erişilebilir kılmaktır.

Arayüz, temel işlevsel bölümleri birden fazla sekmeye ayıran QTabWidget yapısı ile organize edilmiştir. Bu sekmeler, kullanıcıya veri girişi, model mimarisi tanımlama, eğitim işlemleri, tahmin üretimi ve sonuç görselleştirme gibi adımları adım adım takip edebileceği yönlendirmeli bir kullanım akışı sunmaktadır. Her sekme, kendi iç işlevlerini barındıran bileşenlerle donatılmıştır ve kullanıcı arayüzü bu yapıyla hem yeni başlayanlar hem de ileri düzey kullanıcılar için öğrenme eğrisini önemli ölçüde azaltmaktadır.


Tasarım sürecinde özellikle model mimarilerinin dinamik olarak tanımlanabilmesi, kullanıcıdan alınan hiperparametrelerin arka planda modele aktarılması ve eğitim sürecine ait hata grafiklerinin güncellenmesi gibi işlevler için etkileşimli ve modüler bir yapı benimsenmiştir. Eğitim süreci tamamlandıktan sonra kullanıcı, tahmin çıktılarının görsellerine ulaşabilmekte ve bu sonuçları çeşitli formatlarda dışa aktarabilmektedir.

Envilearn yazılımının “Load File” sekmesi, kullanıcıların modelleme sürecine başlamadan önce eğitim, doğrulama ve test verilerini sisteme tanımlamalarını sağlar (Şekil 69). Bu arayüzde hem zaman serisi hem de görüntü verileriyle çalışmayı mümkün kılan farklı veri türlerine yönelik bölümler bulunmaktadır. Kullanıcılar; .npy uzantılı NumPy dizilerini, .tif formatındaki görüntü klasörlerini veya .txt ve .csv gibi düz metin dosyalarını bu sekme üzerinden kolaylıkla sisteme yükleyebilirler. Arayüzde yer alan sekmeler, sezgisel olarak gruplanmış olup veri kaynağının türüne göre özelleşmiş giriş alanları ve yükleme butonları içerir. Sayfanın alt kısmında, yüklenen veriye ilişkin temel istatistiklerin listeleneceği “Variable Properties” alanı ve veri yükleme sürecini izlemeye yarayan bir ilerleme çubuğu yer almaktadır.



Şekil 69. Envilearn yazılımı veri yükleme sekmesi

Şekil 70’te kullanıcı tarafından bir LSTM modeli oluşturulmak üzere yapılandırılmış “Build Model” sekmesi görülmektedir. Bu sekme üzerinden kullanıcı, model türü (LSTM veya ConvLSTM), aktivasyon fonksiyonu, bellek hücresi sayısı, öğrenme oranı, optimizasyon algoritması, çıktı boyutu, hata fonksiyonu, zaman adımı (time step), yığılmış katman sayısı ve metrik gibi birçok hiperparametreyi manuel olarak belirleyebilmektedir. Gösterilen örnekte, dört katmandan oluşan yığılmış bir LSTM ağı ReLU aktivasyon fonksiyonu ile tanımlanmış ve her bir katmanda farklı sayıda bellek hücresi kullanılmıştır. Kullanıcının ayarları doğrultusunda model başarıyla oluşturulmuş ve sağ alt bölümde model mimarisi Python koduna benzer bir özetle kullanıcıya sunulmuştur.



Şekil 70. Envilearn yazılımında LSTM mimarisi ile derin öğrenme modelinin yapılandırıldığı model geliştirme sekmesinin arayüz görünümü.


Şekil 71, Envilearn yazılımının “Train Model” sekmesinde model eğitimi için gerekli tüm parametrelerin kullanıcı tarafından ayarlanabildiği esnek bir yapı sunmaktadır. Bu sekme aracılığıyla kullanıcılar yığın boyutu, epok sayısı, validasyon bölme oranı gibi temel eğitim parametrelerini belirleyebilmekte, ayrıca erken durdurma (Early Stopping), öğrenme oranı azaltma (Reduce LR), CSV kayıt sistemi ve en iyi modeli kaydetme gibi farklı eğitim strateji fonksiyonlarını devreye alabilmektedir.

Arayüzde, her bir eğitim stratejisi için hangi metriğin (örneğin “Validasyon Kaybı”) izleneceği kullanıcı tarafından atanabilmektedir. Kullanıcı ayrıca eğitilen modelin .h5 uzantılı hali ve eğitim süreci kayıtları için klasör yolu belirleyebilir.

Alt bölümde, her epok için hesaplanan eğitim hata değerleri metin kutusunda sıralı biçimde kullanıcıya sunulmakta, sağ tarafta ise hata grafikleri olarak görselleştirilmektedir. Bu grafik, modelin zaman içindeki öğrenme eğilimini anlamak açısından önemli bir geri bildirim sunar.

Alt kısımda yer alan yeşil durum çubuğu ve “Training completed” mesajı ise modelin başarıyla eğitildiğini bildirmektedir. Bu yapı sayesinde kullanıcılar, derin öğrenme


modellerini herhangi bir kodlama bilgisine gerek duymadan eğitebilmekte ve süreç boyunca gerekli ayarlamaları arayüz üzerinden rahatlıkla gerçekleştirebilmektedir.



Şekil 71. Envilearn yazılımı model eğitimi sekmesi

Şekil 72, kullanıcıların eğitilmiş modelleri kullanarak yeni tahminler gerçekleştirmesine olanak tanıyan “Evaluate Model” sekmesini göstermektedir. Bu bölümde kullanıcılar önceden eğitilmiş bir modeli yükleyebilir ve tahmin işlemi için kullanılacak veri kaynağını seçebilirler.


Veri seti yüklendikten sonra, tahmin süreci “Predict” butonuna basılarak başlatılır. Tahmin süreci boyunca işlem durumu, sol alttaki “Status Window” alanında gerçek zamanlı olarak izlenebilmektedir. “Prediction Start”, “Please wait...” ve “Prediction Completed” gibi mesajlar ile süreç hakkında kullanıcı bilgilendirilir. Tahmin tamamlandıktan sonra elde edilen çıktılar çeşitli formatlarda (örneğin .txt, .csv, .xlsx, .tiff, .json, .npy) dışa aktarılabilir. Bu işlem “Save Predictions” alanından klasör yolu ve dosya formatı seçilerek gerçekleştirilir.



Şekil 72. Envilearn yazılımı model tahminleme sekmesi

Şekil 73’te görülen Model Performans sekmesi, kullanıcıların eğitilmiş modellerin tahmin doğruluğunu değerlendirmesine olanak tanıyan analiz araçları sunmaktadır. Bu sekme aracılığıyla kullanıcılar, model çıktıları ile gerçek gözlemler arasındaki ilişkiyi çeşitli metrikler ve görseller üzerinden inceleyebilmektedir. Sekmede yer alan metrikler arasında R-kare (R^2), Karesel Ortalama Hata (KOH), Pearson Korelasyon Katsayısı (R) ve tanımlayıcı istatistikler (ortalama, standart sapma, yüzdelikler) bulunmaktadır. Kullanıcı, hesaplama işlemlerini “Metrik Hesaplama” düğmesiyle başlatarak özet performans çıktıları elde edebilmektedir.

Ayrıca, model performansına dair görsel analiz seçenekleri de sunulmaktadır. “Line Plot” seçeneği ile tahmin edilen değerler ve gözlemsel veriler zaman serisi ekseninde üst üste çizilerek tahmin doğruluğu doğrudan görselleştirilmektedir. Alternatif olarak, “Comparative Plot” seçeneğiyle tahmin ve gözlem değerlerinin dağılımı karşılaştırmalı olarak sunulmakta; doğrusal referans çizgisi etrafındaki dağılım, modelin öngörü başarısını görsel olarak ortaya koymaktadır. Her iki grafik de PNG formatında dışa aktarılabilmekte ve sonuçlar Excel dosyası olarak kaydedilebilmektedir. Bu özellikler sayesinde Model Performans sekmesi, kullanıcıların modellerini nicel ve görsel olarak değerlendirmesine olanak tanıyan bir yapıdadır.



Şekil 73. Envilearn yazılımı model performans sekmesi

Sonuç olarak, EnviLearn yazılımı; çevresel değişkenlerin yapay sinir ağları ile modellenmesine olanak tanıyan, kullanıcı dostu ve açık kaynak kodlu bir platform olarak geliştirilmiştir. Bu yazılım, tez kapsamında elde edilen bilgi birikiminin somut bir çıktıya dönüştürülmesi amacıyla tasarlanmış ve hem zaman serisi hem de görüntü tabanlı veriler üzerinde çalışabilme esnekliği ile çevresel modelleme uygulamalarında geniş bir kullanım alanı sunmuştur. Geliştirilen grafiksel arayüz aracılığıyla kullanıcılar, herhangi bir kodlama bilgisine sahip olmaksızın veri yükleme, model oluşturma, eğitim, değerlendirme ve çıktı

alma işlemlerini kolaylıkla gerçekleştirebilmektedir. Yazılım, derin öğrenme modellerinin eğitiminde gerekli olan tüm teknik adımları tek bir platformda bütünleştirerek, araştırmacılar ve uygulayıcılar için erişilebilir, özelleştirilebilir ve etkili bir modelleme aracı sunmaktadır.



4. TARTIŞMA VE DEĞERLENDİRME

4.1. Bulguların Literatürle Karşılaştırılması

Bu tez kapsamında geliştirilen modellerin performansını değerlendirebilmek amacıyla, literatürde deniz seviyesi tahmini üzerine yapılan çalışmaların sonuçları Tablo 26’da özetlenmiştir. Farklı makine öğrenmesi ve istatistiksel yöntemler kullanılarak elde edilen KOH değerleri bu çalışmanın bulgularıyla kıyaslanarak metodolojik etkinlik ortaya konmuştur.

Tablo 26. Literatürdeki deniz seviyesi tahmin çalışmalarında kullanılan yöntemler ve performansları

Yapılan Çalışma	Yöntem	KOH (mm)	Hiperparametre Optimizasyon Yöntemi
(Makarynsky, Makarynska, Kuhn, & Featherstone, 2004)	ANN	151	Manuel
(Niedzielski & Kosek, 2009)	LS	35	-
	LS+AR	26	
(Imani, You, & Kuo, 2013)	HWES	70	Manuel
	ANN	60	
(Imani, You, & Kuo, 2014)	PCA+ARIMA	51	-
(Imani, You, & Kuo, 2014)	MLP	54	Manuel
	RBF	42	
	GRNN	59	
	ARMA	119	
(Imani, You, & Kuo, 2014)	SVR	35	Manuel
(Imani, Kao, Lan, & Kuo, 2018)	ELM	35	Manuel
	RBF	36	
	RVM	34	
	SVM	35	
(Fu, Zhou, Sun, & Tang, 2019)	EMD+SSA+LS	13	-
(Zhao, Cai, & Fan, 2019)	MLFF	18	Manuel
	RBF	16	
	GRNN	16	
	ARMA	28	
(Ishida, 2020)	LSTM	102	Manuel
(Riazi, 2020)		48	-
(Yang, 2020)	LSTM	50	Manuel
(Winona, 2020)	LSTM	20	Manuel
(Yavuzdoğan & Tanır Kayıkçı, 2021)	CP Model	22	-
(Adebisi & Balogun, 2021)	LSTM	60	Manuel
(Accarino, 2021)	LSTM	11	Manuel
(Žust, 2021)	LSTM	64	Manuel
Bu Tez Çalışması	Y. LSTM	5,2	Otomatik
	O.K. - LSTM	4,6	Otomatik
	ConvLSTM	6.88	Manuel
	S.K	11	-

Tablo 26’da sunulan karşılaştırmalı değerlendirme, deniz seviyesi tahmini konusundaki önceki çalışmalar ile bu tez kapsamında geliştirilen modellerin performansını ele almaktadır. Örneğin, klasik yapay sinir ağı (ANN) modelleriyle (Makarynsky, Makarynska, Kuhn, & Featherstone, 2004) tarafından 1 aylık tahminlerde elde edilen ± 151 mm KOH değeri, bu çalışmada Oto-Kodlayıcı LSTM Modeli ile ulaşılan ± 4.6 mm gibi oldukça düşük bir hata değeriyle karşılaştırıldığında anlamlı bir fark ortaya koymaktadır.

Literatürde sıkça başvurulanan yöntemler arasında yer alan destek vektör regresyonu (SVR), ekstrem öğrenme makineleri (ELM), gradyan geriye yayılım (GRNN) veya regresyon vektör makineleri (RVM) gibi klasik makine öğrenimi yöntemleri ile yapılan çalışmalarda genellikle ± 30 – 70 mm aralığında KOH sonuçları raporlanmış; örneğin (Imani, Kao, Lan, & Kuo, 2018) çalışmasında en düşük değer ± 34 mm olmuştur. Yine (Accarino, 2021) çalışmasında LSTM kullanılarak ± 11 mm KOH değeri elde edilmiştir ve bu sonuç literatürdeki en düşük değerlerden biri olarak göze çarpmaktadır.

Ek olarak, bu tez çalışmasında hiperparametre optimizasyon sürecinin otomatik olarak gerçekleştirilmiş olması da metodolojik üstünlükler arasında sayılmalıdır. Literatürdeki birçok çalışmada hiperparametreler genellikle manuel yollarla belirlenmiştir ve bu da model başarısının rastlantısal faktörlere bağımlı kalmasına neden olabilirken, bu tezde kullanılan sistematik optimizasyon yaklaşımı modelin daha güvenilir biçimde yapılandırılmasını sağlamıştır.

Sonuç olarak, bu tezde geliştirilen derin öğrenme temelli modeller, literatürdeki mevcut yöntemlerle kıyaslandığında hem daha düşük hata oranları hem de uzun vadeli ve geniş kapsamlı veriyle çalışabilme yetenekleri açısından belirgin bir ilerlemeye işaret etmektedir.

4.2. Modellerin Genelleştirme ve Validasyon Performanslarının Karşılaştırılması

Bu bölümde, tez kapsamında DUACS veri seti ile eğitilmiş derin öğrenme modellerinin (Yığılmış LSTM ve Oto-Kodlayıcı LSTM) farklı bir uydu kaynağından gelen CMEMS (Copernicus Marine Environment Monitoring Service) veri seti üzerinde test edilerek gösterdiği genelleştirme kabiliyeti, ayrıca CMEMS verileriyle eğitilen ConvLSTM mimarisinin kendi test veri seti üzerindeki performansı karşılaştırmalı olarak ele alınmıştır. Bu analiz, modellerin yalnızca eğitildikleri veri kümesinde değil, farklı kaynaklardan gelen uydu verileri ya da yer gözlem verileri karşısında da ne düzeyde geçerliliğe sahip olduğunu

değerlendirme amacı taşımaktadır. Daha önce DUACS veri seti ile eğitilmiş Yığılmış LSTM ve Oto-Kodlayıcı LSTM modelleri, CMEMS veri seti ile doğrudan test edilmiş; ConvLSTM modeli ise görüntü tabanlı bir yapı gerektirdiğinden, bu veri setiyle yeniden eğitilerek test edilmiştir. Böylece, modellerin genelleştirme ve validasyon performanslarına dair değerlendirme yapılması sağlanmıştır.

Yığılmış LSTM modeli, CMEMS veri seti ile yapılan testlerde 1 günlük tahmin ufku için ortalama ± 23.61 mm, 2 gün için ± 39.62 mm ve 3 gün için ± 43.00 KOH değeri üretmiştir. Oto-kodlayıcı LSTM modeli ise aynı veri setinde 1 gün için ± 21.86 mm, 2 gün için ± 29.18 mm ve 3 gün için ± 34.91 mm ortalama KOH değerleri ile daha düşük hata seviyeleri sergilemiştir. Bu sonuçlar, DUACS veri seti ile eğitilen her iki modelin de CMEMS gibi bağımsız bir kaynak üzerindeki tahminlerde tatmin edici genelleştirme performansı sunduğunu ortaya koymaktadır. Özellikle oto-kodlayıcı LSTM mimarisi, tüm tahmin ufuklarında ortalama hatayı daha düşük seviyelerde tutarak, zaman içinde daha kararlı bir tahmin yeteneği sergilemiştir.

Bununla birlikte, ConvLSTM modeli doğrudan CMEMS veri seti ile eğitilmiş ve yalnızca 1 günlük tahmin üzerinde test edilmiştir. Bu model, minimum ± 1.24 mm, ortalama ± 10.62 mm ve maksimum ± 18.10 mm KOH değeri ile, yeniden eğitildiği veri setinde oldukça yüksek bir tahmin doğruluğu sunmuştur. Modelin görüntü temelli yapısı nedeniyle sadece 1 gün için tahmin yapılabilmiş olsa da bu sonuçlar konumsal örüntüleri öğrenme kapasitesinin güçlü olduğunu ve erken uyarı sistemi gibi uygulamalarda kullanılabilecek bir yapıya sahip olduğunu göstermektedir.

Genel olarak değerlendirildiğinde hem yığılmış LSTM hem de oto-kodlayıcı LSTM modelleri farklı çözünürlükte bir uydu verisi ile test edildiğinde bile performanslarını sürdürebilmiş; oto-kodlayıcı yapı ise genelleme açısından bir adım öne çıkmıştır. ConvLSTM mimarisi ise, aynı veri setiyle yeniden eğitilerek test edildiğinde yüksek doğrulukla tahminler üretmiştir.

DUACS veri seti ile eğitilen modellerin yalnızca farklı bir uydu veri kaynağı (CMEMS) üzerindeki değil, aynı zamanda doğrudan yer gözlemine dayalı bağımsız bir veri kümesi (mareograf istasyonları) üzerinde de test edilmesi, model genelleştirme kapasitesinin bütüncül bir şekilde değerlendirilmesini sağlamıştır. Bu kapsamda, Karadeniz kıyısında bulunan TRAB mareograf istasyonuna ait rölatif (bağıl) deniz seviyesi gözlem verileri, eğitim sürecinde hiçbir şekilde modele sunulmamış olup, tamamen bağımsız bir test ortamı sunmuştur. Yığılmış LSTM modeli bu istasyonda, 1 günlük tahmin için ± 41.29 mm KOH ve

0.9427 Pearson korelasyon katsayısı üretmiştir. Aynı tahmin ufkunda, Oto-Kodlayıcı LSTM modeli ± 38.29 mm KOH ve 0.9474 r değeri ile daha düşük hata ve daha güçlü korelasyon sunarak öne çıkmıştır.

2 ve 3 günlük tahminlerde, tüm modeller hata artışı göstermektedir. Yığılmış LSTM için 3 günlük tahmin karesel ortalama hatası ± 83.30 mm, korelasyonu ise 0.7896 seviyesine gerilerken, Oto-Kodlayıcı LSTM aynı tahmin ufkunda ± 70.82 mm KOH ve 0.8092 r değerine ulaşmıştır. Ancak yine de Oto-Kodlayıcı mimarinin uzun vadeli genelleştirme performansında görece üstünlüğünü koruduğunu ortaya koymaktadır.

CMEMS verileri ile yapılan testlerde her iki model de 1 günlük tahmin için yaklaşık $\pm 22-24$ mm seviyesinde ortalama KOH değerlerine sahipken, TRAB istasyonundaki testte bu hatalar daha yüksek çıkmıştır. Bu farklılık, yer gözlemlerinin daha yerel, anlık ve çevresel etkilerden daha fazla etkilenen bir yapıya sahip olması ile açıklanabilir. Buna rağmen, modellerin bu tür verilerle dahi anlamlı korelasyonlar ve kabul edilebilir hata seviyeleri sunabilmesi, yüksek derecede genelleştirme yeteneğine sahip olduklarını göstermektedir.

Sonuç olarak, TRAB istasyonuna dayalı testler, DUACS ile eğitilen modellerin yalnızca farklı altimetre kaynaklarına değil, aynı zamanda yersel ölçüm tekniklerine de başarılı bir şekilde genellenebileceğini ortaya koymuştur. Bu durum, LSTM tabanlı modellerin hem bilimsel araştırma hem de operasyonel erken uyarı sistemleri bağlamında güvenilirliğini güçlendirmektedir.

4.3. Erken Uyarı Sisteminin Performansının Tartışılması

TideGuard yazılımı, CMEMS uydu verisi ile eğitilen ConvLSTM modeline dayalı olarak geliştirilmiş, deniz seviyesi anomalilerinin 15 güne kadar öngörülebilmesini sağlayan bir erken uyarı sistemi prototipidir. Sistem, ardışık tahmin yapısı sayesinde her yeni günün tahminini bir önceki tahmini de girdi verisine dahil ederek gerçekleştirmekte, böylece öngörü süresi uzadıkça artabilecek hata birikimini doğal veri akışı içerisinde değerlendirmektedir. Bu mimari, modelin yalnızca kısa vadeli doğruluk sunmakla kalmayıp, zaman içinde örüntüleri sürdürebilme kapasitesini de test etme imkânı sağlamaktadır.

Gerçekleştirilen 75 simülasyon boyunca elde edilen performans metrikleri değerlendirildiğinde, sistemin genel olarak güvenilir ve kararlı bir yapı sunduğu görülmektedir. Ortalama KOH değerlerinin 1. günde ± 4.33 mm ile başladığı ve 15. gün sonunda dahi ± 7 mm'nin altında kaldığı gözlemlenmiştir. Benzer şekilde, korelasyon

değerleri tüm tahmin günleri boyunca 0.80'in üzerinde seyretmiş; bu da tahmin edilen değerler ile gerçek gözlemler arasındaki yüksek doğrusal ilişkiyi göstermiştir. Şekil 63 ve 64'te sunulan günlük ortalama performans grafiklerinde, hata ve korelasyon değerlerinin zaman içinde dalgalı ancak sınırlı bir artış gösterdiği, özellikle belirli günlerde tahmin doğruluğunun yeniden toparlandığı gözlemlenmektedir. Bu durum, ardışık tahmin sürecinde olası hata birikiminin doğrusal şekilde ilerlemediğini ve sistemin öngörü stabilitesini büyük ölçüde koruyabildiğini göstermektedir.

Kümülatif dağılım analizleri de bu değerlendirmeyi destekler niteliktedir. Gerçekleştirilen tüm tahminlerin %86'sının ± 10 mm altı KOH değerine ve %77'sinin 0.80 üzeri korelasyon katsayısına sahip olması, TideGuard yazılımının hem doğruluk hem de süreklilik açısından erken uyarı sistemleri için uygulanabilir ve güvenilir bir araç olduğunu kanıtlamaktadır. Yazılımın kullanıcı dostu yapısı, görsel arayüzü ve tahminlerin dışa aktarılabilirliği gibi nitelikleri, bu yazılımı yalnızca bir araştırma prototipi değil, aynı zamanda sahada kullanılabilir operasyonel bir karar destek sistemi adayı haline getirmektedir.

5. SONUÇLAR VE ÖNERİLER

Bu tez çalışmasında, Karadeniz’de deniz seviyesi anomalilerinin modellenmesi amacıyla üç farklı derin öğrenme mimarisi (Yığılmış LSTM, Oto-Kodlayıcı LSTM ve ConvLSTM) ve bir adet istatistiksel tahmin modeli (sönümlü-kalıcılık) geliştirilmiş ve değerlendirilmiştir. Tahmin modelleri, DUACS radar altimetre verileri ile eğitilmiş, ardından CMEMS veri seti ve yer gözlemi verileri (mareograf) ile test edilerek genelleme kapasiteleri analiz edilmiştir. Ayrıca, ConvLSTM modeli üzerine inşa edilen ve deniz seviyesi tahmini yapabilen TideGuard deniz seviyesi erken uyarı sistemi ile derin öğrenme yaklaşımlarının çevresel karar destek sistemlerinde operatif kullanım potansiyeli ortaya konmuştur.

Tez kapsamında yapılan deneysel çalışmaların sonuçları, deniz seviyesi tahmininde özellikle LSTM temelli derin öğrenme modellerinin oldukça güçlü bir tahmin kapasitesi sunduğunu göstermiştir. DUACS veri seti ile eğitilen modeller, 1–3 günlük tahmin ufuklarında düşük hata oranları ve yüksek korelasyon değerleri ile dikkat çekmiştir. Buna karşın sönümlü kalıcılık istatistiksel modeli tahmin performansı bakımından derin öğrenme modellerinin oldukça gerisinde kalmıştır. Bu durum derin öğrenme modellerinin istatistiksel yaklaşımlar karşısında deniz seviyesi tahmini açısından üstünlüğünü vurgulamaktadır. Derin öğrenme modellerinden Yığılmış LSTM modeli, 1 günlük tahmin için ± 5.29 mm KOH ve 0.9980 korelasyon değeri üretirken, Oto-Kodlayıcı LSTM modeli aynı tahmin ufukunda ± 4.63 mm KOH ve 0.9985 r değeri ile daha iyi bir performans sergilemiştir. Aslında oto-kodlayıcı LSTM modeli hem test hem de genelleştirme performansı açısından tüm tahmin ufuklarında daha başarılı tahmin performansı sergilemiştir. ConvLSTM modeli ise yalnızca 1 günlük tahmin için test edilmiş ancak ± 6.88 mm KOH ve 0.9910 r değeri ile tutarlılık açısından oldukça başarılı bulunmuştur.

Geliştirilen modeller yalnızca DUACS veri seti üzerinde değil, farklı kaynaklardan elde edilen veriler üzerinde de test edilerek genelleştirme yetenekleri açısından değerlendirilmiştir. CMEMS veri seti üzerinde test edilen Yığılmış LSTM ve Oto-Kodlayıcı LSTM modelleri, tahmin ufku arttıkça hata oranlarında artış sergilese de özellikle Oto-Kodlayıcı yapının genelleme kapasitesinin daha yüksek olduğu görülmüştür. Örneğin, 3 günlük tahmin için Oto-Kodlayıcı LSTM modeli CMEMS verisinde ± 34.91 mm ortalama KOH ve 0.91’e yakın korelasyon sunarken, Yığılmış LSTM modelinin hata değeri ± 43.00

mm'ye ulaşmıştır. Bu sonuçlar, eğitim sürecinde zamansal desenleri sıkıştırarak öğrenebilen Oto-Kodlayıcı yapının daha kararlı genelleme sunduğunu göstermektedir.

Yer gözlemlerine dayanan mareograf verileriyle yapılan testler, modellerin genelleme potansiyelini ölçmek açısından kritik öneme sahiptir. TRAB mareograf istasyonundan alınan bağıl deniz seviyesi gözlemleri üzerinde yapılan testler, modellerin sadece uydu verileriyle değil, aynı zamanda tamamen bağımsız ve yapısal olarak farklı yersel veri türleriyle de başarılı şekilde tahmin gerçekleştirebildiğini göstermiştir. Bu analizlerde Oto-Kodlayıcı LSTM, 1 günlük tahmin için ± 38.29 mm KOH ve 0.9474 r değeriyle en iyi sonucu verirken, Yığılmış LSTM modeli ± 41.29 mm KOH ve 0.9427 korelasyon ile yakın performans göstermiştir. Bu bulgular, modellerin farklı veri kaynakları karşısında tutarlı genelleştirme başarısı sergilediğini ve eğitildikleri sınırlı örneklerin ötesine geçebildiklerini ortaya koymuştur.

Ayrıca bu tez çalışmasının literatüre en önemli katkılarından biri, geliştirilen derin öğrenme modellerinin tahmin performanslarının önceki çalışmalarla karşılaştırıldığında şimdiye kadar ulaşılan en yüksek doğruluk seviyelerine ulaşmış olmasıdır. Yığılmış LSTM ve Oto-Kodlayıcı LSTM modelleri, hem DUACS veri seti üzerindeki düşük KOH değerleri hem de farklı veri kaynakları üzerindeki güçlü genelleştirme performansları ile dikkat çekmiştir. Bu yüksek performans seviyesinde, tezin bir diğer yenilikçi katkısı olan çoklu hiperparametre arama yöntemlerinin uygulanmış olması da belirleyici bir rol oynamıştır. Bu tez çalışması ile, deniz seviyesi anomalisi tahmini alanında ilk defa çoklu hiperparametre optimizasyonu entegre edilmiş; bu yöntem sayesinde model mimarileri, öğrenme oranları, aktivasyon fonksiyonları, katman sayıları gibi parametreler sistematik biçimde taranarak en uygun kombinasyonlar elde edilmiştir.

Bu tez kapsamında geliştirilen en özgün yapı, ConvLSTM mimarisi üzerine inşa edilen TideGuard yazılımı olmuştur. Bu yazılım, CMEMS verisiyle yeniden eğitilen ConvLSTM modeli sayesinde geçmiş 7 günlük SLA haritalarını kullanarak ardışık biçimde 15 güne kadar tahmin üretmekte, her yeni gün tahminini bir önceki günün tahminini de giriş verisine ekleyerek gerçekleştirmektedir. Gerçekleştirilen 75 farklı tarih aralığına ait simülasyonlarda, sistem her gün için KOH ve korelasyon değerleri ile değerlendirilmiştir. Sonuçlar göstermiştir ki, 1. günde ± 4.33 mm KOH ile başlayan hata seviyesi, 12. günde ± 6.56 mm'ye kadar çıkmakta; buna karşın tüm tahmin süresi boyunca korelasyon değerleri 0.80'in üzerinde seyretmektedir. Bu sonuçlar, ardışık tahmin yapısına rağmen sistemin doğruluğu

sürdürebildiğini ve özellikle erken uyarı sistemleri için güvenilir çıktı üretme potansiyeline sahip olduğunu göstermektedir.

Erken uyarı sisteminin tahmin performansına ilişkin dağılım analizleri de bu güvenilirliği destekler niteliktedir. 75 simülasyon boyunca elde edilen tahmin sonuçlarının %86'sı ± 10 mm'nin altında KOH değeriyle, %77'si ise 0.80 üzeri korelasyonla gerçekleşmiştir. Bu, yalnızca ortalama performansların değil, aynı zamanda istatistiksel dağılımın da sistematik olarak yüksek doğruluk sunduğunu ortaya koymaktadır. Yazılımın kullanıcı dostu arayüzü, veri erişim ve dışa aktarım modülleri, tahmin süresi seçimi gibi esnek yapıları sayesinde hem araştırmacılar hem de karar vericiler için pratik bir araç haline gelmiştir.

Tez çalışması yalnızca başarılı modeller geliştirmekle kalmamış, aynı zamanda elde edilen bilgi birikiminin açık kaynak kodlu yazılımlara dönüştürülmesiyle çevresel modelleme topluluğuna katkı sağlamıştır. Bu bağlamda geliştirilen EnviLearn yazılımı hem zaman serisi hem de görüntü tabanlı derin öğrenme modellerini destekleyen, hiperparametre yapılandırması ve eğitim sürecini kodlama bilgisi gerektirmeden yürütebilen kullanıcı dostu bir platform sunmaktadır. Bu yazılım, araştırmacılar için erişilebilirliği artırmakta ve çevresel modelleme alanında yapay zeka tabanlı yaklaşımların yaygınlaşmasına katkı sağlamaktadır.

Sonuç olarak bu tez çalışması, Karadeniz'deki deniz seviyesi anomalilerinin tahmini için derin öğrenme tabanlı yöntemlerin güçlü bir alternatif sunduğunu ortaya koymakta, farklı veri kaynakları üzerindeki genelleştirme yetenekleri ile modellerin yalnızca akademik bağlamda değil, operasyonel bağlamda da kullanılabilir olduğunu göstermektedir. Özellikle ConvLSTM mimarisi ile geliştirilen TideGuard yazılımı, erken uyarı sistemleri açısından yenilikçi ve uygulanabilir bir yaklaşım sunmaktadır.

İleride yapılacak çalışmalar kapsamında, önerilen model mimarilerinin diğer deniz alanlarında test edilmesi, farklı hiperparametre optimizasyon yöntemleriyle yeniden eğitilmesi ve çok kaynaklı veri girişlerinin entegre edilmesi önerilmektedir. Ayrıca, yazılım temelli çözümlerin mobil platformlara entegre edilmesi, çevrimiçi çalışabilecek altyapıların oluşturulması ve kullanıcı deneyimi odaklı iyileştirmelerin yapılması, sistemin pratikte daha geniş kullanıcı kitlesine ulaşmasını sağlayacaktır. Bu kapsamda hem bilimsel hem de operasyonel düzlemde geliştirilen sistemlerin daha yaygın ve etkin biçimde kullanılabilmesi hedeflenmelidir.

6. KAYNAKLAR

- Accarino, G. C. (2021). A multi-model architecture based on Long Short-Term Memory neural networks for multi-step sea level forecasting. *Future Generation Computer Systems*, 124, 1-9.
- Adebisi, N., & Balogun, A. (2021). A deep-learning model for national scale modelling and mapping of Sea level rise in Malaysia: The past, present, and future. *Geocarto International*, 1-23.
- Agency, E. (2024, 9 12). *Flood and coastal erosion risk management*. Flood and coastal erosion risk management: <https://www.gov.uk/government/organisations/environment-agency> adresinden alındı
- Alpar, B. &. (1998). Sea-level variations and their interactions between the Black Sea and the Aegean Sea. *Estuarine, Coastal and Shelf Science*, 46(5), 609-619.
- Amin, H., Sjöberg, L., & Bagherbandi, M. (2019). A global vertical datum defined by the conventional geoid potential and the Earth ellipsoid parameters. *Journal of Geodesy*, 93(10), 1943-1961.
- Arns, A., Wahl, T., Wolff, C., Vafeidis, A. T., Haigh, I. D., Woodworth, P., . . . Jensen, J. (2020). Non-linear interaction modulates global extreme sea levels, coastal flood exposure, and impacts. *Nature communications*, 11(1), 1-9.
- Australian Government. (2024, 11 29). *Australian Tsunami Warning System*. Australian Tsunami Warning System: <http://www.bom.gov.au/tsunami/about/atws.shtml> adresinden alındı
- Avsar, N. B., Jin, S., Kutoglu, H., & Gurbuz, G. (2016). Sea level change along the Black Sea coast from satellite altimetry, tide gauge and GPS observations. *Geodesy and Geodynamics*, 7(1), 50-55.
- Azevedo de Almeida, B., & Mostafavi, A. (2016). Resilience of Infrastructure Systems to Sea-Level Rise in Coastal Areas: Impacts, Adaptation Measures, and Implementation Challenges. *Sustainability*, 8(11), 1115.
- Azlan, A., Yusof, Y., & Mohsin, M. (2019). Determining the impact of window length on time series forecasting using deep learning. *International Journal of Advanced Computer Research*, 9, 260-267.
- Balabanov, I. P. (2007). Holocene sea-level changes of the Black Sea. I. P. Balabanov içinde, *The Black Sea Flood Question: Changes in Coastline, Climate, and Human Settlement* (s. 711-730). London: Springer.
- Balogun, A.-L., & Adebisi, N. (2021). Sea level prediction using ARIMA, SVR and LSTM neural network: assessing the impact of ensemble Ocean-Atmospheric processes on models' accuracy. *Geomatics, Natural Hazards and Risk*, 12(1), 653-674.

- Bandara, K. B. (2020). Forecasting across time series databases using recurrent neural networks on groups of similar series: A clustering approach. *Expert Systems with Applications*, 140, 112896.
- Bengio, Y., Courville, A., & Vincent, P. (2013). Representation Learning: A Review and New Perspectives. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 35(3), 1798-1828.
- Bergstra, J., & Bengio, Y. (2012). Random search for hyper-parameter optimization. *Journal of machine learning research*, 13(2), 1-20.
- Beşel, C. (2023). *Türkiye Kıyılarında Deniz Seviyesi Değişiminin GNSS İnterferometrik Reflektometri Tekniği ile Araştırılması (Doktora Tezi)*. Trabzon: Karadeniz Teknik Üniversitesi.
- Bezděk, A., & Sebera, J. (2013). Matlab script for 3D visualizing geodata on a rotating globe. *Computers & Geosciences*, 56, 127-130.
- BfG. (2024, 12 9). *Federal Institute of Hydrology, Germany*. BfG: <https://www.bafg.de> adresinden alındı
- Bishop, C. (2016). *Pattern Recognition and Machine Learning*. New York: Springer.
- Borretti, C., Degrace, J.-N., & Cova, P. (2012). The French Vigilance System. Contributing to the Reduction of Disaster Risks in France. M. Golnaraghi içinde, *Institutional Partnerships in Multi-Hazard Early Warning Systems: A Compilation of Seven National Good Practices and Guiding Principles* (s. 63-93). Berlin, Heidelberg: Springer Berlin Heidelberg.
- Brand, F., Seiler, J., & Kaup, A. (2021). Generalized difference coder: a novel conditional autoencoder structure for video compression. *arXiv preprint*, arXiv:2112.08011.
- Cazenave, A., & Llovel, W. (2010). Contemporary sea level rise. *Annual review of marine science*, 2, 145-173.
- Cazenave, A., & Nerem, R. S. (2004). Present-day sea level change: Observations and causes. *Reviews of Geophysics*, 42(3), 1-20.
- Cazenave, A., Bonnefond, P., Mercier, F., Dominh, K., & Tournazou, V. (2002). Sea level variations in the Mediterranean Sea and Black Sea from satellite altimetry and tide gauges. *Global and Planetary Change*, 59-86.
- Cazenave, A., Meyssignac, B., Ablain, M., Balmaseda, M., Bamber, J., Barletta, V., & Blazquez, A. (2018). Global sea-level budget 1993-present. *Earth System Science Data*, 10(3), 1551-1590.
- Chanklan, R., Kaoungku, N., Suksut, K., Kerdprasop, K., & Kerdprasop, N. (2018). Runoff Prediction with a combined artificial neural network and support vector regression. *International Journal of Machine Learning and Computing*, 8(1), 1-20.

- Chen, J., Wang, Z., Tuo, D., Wu, Z., Kang, S., & Meng, H. (2022). IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). *Fullsubnet+: Channel attention fullsubnet with complex spectrograms for speech enhancement* (s. 7857-7861). Singapore: IEEE.
- Chen, X., Zhang, X., Church, J. A., Watson, C. S., King, M. A., Monselesan, D., & Harig, C. (2017). The increasing rate of global mean sea-level rise during 1993–2014. *Nature Climate Change*, 7(7), 492-495.
- Chi, Y. N. (2020). Analyzing Long-Term Records of Global Average Sea Level Change Using ARIMA Model. *Journal of Economics and Business*, 3(2), 100-107.
- Cho, H., Kim, Y., Lee, E., Choi, D., Lee, Y., & Rhee, W. (2020). Basic enhancement strategies when using bayesian optimization for hyperparameter tuning of deep neural networks. *IEEE Access*, 8, 52588–52608. doi:10.1109/ACCESS.2020.2981072
- Chou, J., & Nguyen, T. (2018). Forward forecast of stock price using sliding window metaheuristic-optimized machine-learning regression. *IEEE Transactions on Industrial Informatics*, 14, 3132–3142.
- Chung, J., Gulcehre, C., Cho, K., & Bengio, Y. (2014). Empirical evaluation of gated recurrent neural networks on sequence modeling. *arXiv [Cs.NE]*, 1. <http://arxiv.org/abs/1412.3555> adresinden alındı
- Church, J. C. (2013). *Sea Level Change*. London: PM Cambridge University Press.
- CMEMS. (2022, 01 10). *Copernicus Marine Environment Monitoring System*. <https://cds.climate.copernicus.eu> adresinden alındı
- Contestabile, M. (2018). Wastewater disruptions. *Nature Sustainability*, 1(4), 158-158.
- Copernicus. (2025, 01 27). *Climate Data Store - Catalogue*. Copernicus Data Store: <https://cds.climate.copernicus.eu/datasets> adresinden alındı
- Cortes, C., & Vapnik, V. (1995). Support-vector networks. *Machine Learning*, 273–297.
- Costa, C. G., Leite, J. R., Castro, B. M., Blumberg, A. F., Georgas, N., Dottori, M., & Jordi, A. (2020). An operational forecasting system for physical processes in the Santos-Sao Vicente-Bertioga Estuarine System, Southeast Brazil. *Ocean Dynamics*, 70(2), 257-271.
- Dasgupta, S. L. (2009). The impact of sea level rise on developing countries: a comparative analysis. *Climate Change*, 93, 379–388. doi:10.1007/s10584-008-9499-5
- de Boer, B. v. (2013). A continuous simulation of global ice volume over the past 1 million years with 3-D ice-sheet models. *Climate Dynamics*, 41, 1365–1384. doi:10.1007/s00382-012-1562-2

- Demirbağ, E., Gökaşan, E., Oktay, F. Y., Şimşek, M., & Yüce, H. (1999). The last sea level changes in the Black Sea: evidence from the seismic data. *Marine Geology*, 157(3-4), 249-265.
- Demyshev, S. G. (2012). A numerical model of online forecasting Black Sea currents. *Atmospheric and Oceanic Physics*, 48(1), 120-132.
- Drucker, H., Burges, C. J., Kaufman, L., Smola, A., & Vapnik, V. (1997). Support vector regression machines. *Advances in Neural Information Processing Systems*. Amerika Birleşik Devletleri: MIT Press.
- ECCC. (2024, 12 9). *Environment and Climate Change Canada*. Environment and Climate Change Canada: <https://www.canada.ca/en/environment-climate-change.html> adresinden alındı
- Eggenberger, K., Feurer, M., Hutter, F., Bergstra, J., Snoek, J., Hoos, H., & Leyton-Brown, K. (2013). Towards an empirical foundation for assessing bayesian optimization of hyperparameters. *NIPS workshop on Bayesian Optimization in Theory and Practice* (s. Eggenberger, K., Feurer, M., Hutter, F., Bergstra, J., Snoek, J., Hoos, H., & Leyton-Brown, K. (2013, December). Towards an empirical foundation for assessing bayesian optimization of hyperparameters. In NIPS workshop on Bayesian Optimization in Theory a). CA, ABD: .
- Elman, J. L. (1990). Finding structure in time. *Cognitive science*, 14(2), 179-211.
- Escudier, R., Clementi, E., Omar, M., Cipollone, A., Pistoia, J., Aydogdu, A., Pinardi, N. (2023, Haziran 6). *Mediterranean Sea Physical Reanalysis (CMEMS MED-Currents) (Version 1) [Data set]*. Copernicus Monitoring Environment Marine Service (CMEMS): https://doi.org/10.25423/CMCC/MEDSEA_MULTIYEAR_PHY_006_004_E3R1 adresinden alındı
- Fernandez, F. R., Po Iii, R., Montero, N., & Addawe, R. (2017). Prediction of South China sea level using seasonal ARIMA models. *AIP Conference Proceedings* (s. 1). Kedah, Malezya: AIP Publishing.
- Franceschi, L., Frasconi, P., Salzo, S., Grazzi, R., & Pontil, M. (2018). Bilevel programming for hyperparameter optimization and meta-learning. *International conference on machine learning* (s. 1568-1577). San Francisco, CA: PMLR.
- Fu, Y., Zhou, X., Sun, W., & Tang, Q. (2019). Hybrid model combining empirical mode decomposition, singular spectrum analysis, and least squares for satellite-derived sea-level anomaly prediction. *International journal of remote sensing*, 40, 7817–7829.
- Garner, K. L., Chang, M. Y., Fulda, M. T., Berlin, J. A., Freed, R. E., Soo-Hoo, M. M., & Kendall, B. E. (2015). Impacts of sea level rise and climate change on coastal plant species in the central California coast. *PeerJ* 3, e958.

- GeoNet. (2024, 12 9). *Geological hazard information for New Zealand*. GeoNet: <https://www.geonet.org.nz> adresinden alındı
- Géron, A. (2019). Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow. O. Media içinde, *Concepts, Tools, and Techniques To Build Intelligent Systems* (s. 1-20). London: O'Reilly Media.
- Gong, D. L., Mansour, M. R., Venkatesh, S., & Hengel, A. V. (2019). IEEE/CVF International Conference on Computer Vision. *Memorizing normality to detect anomaly: Memory-augmented deep autoencoder for unsupervised anomaly detection* (s. 1705-1714). -: IEEE.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. United States: MIT Press.
- Gornitz, V. (1995). Sea-level rise: A review of recent past and near-future trends. *Earth surface processes and landforms*, 20(1), 7-20.
- Gupta, R., Srivastava, D., Sahu, M., Tiwari, S., Ambasta, R. K., & Kumar, P. (2021). Artificial intelligence to deep learning: machine intelligence approach for drug discovery. *Molecular diversity*, 1315-1360.
- Guyon, I., & Elisseeff, A. (2003). An introduction to variable and feature selection. *Journal of machine learning research*, 1157-1182.
- Gülaçar, H. (2018). *Nesnelerin İnterneti Platformları İçin Makine Öğrenmesi Tabanlı Bir Tahmin Modülü. (Yüksek Lisans Tezi)*. İstanbul, Türkiye: İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü.
- Han, S. H., Kim, K. W., Kim, S., & Youn, Y. C. (2018). Artificial neural network: understanding the basic concepts without mathematics. *Dementia and neurocognitive disorders*, 17(3), 83-89.
- Hannah, J. (1989). A long-term sea level change scenario and its implications for geodetic networks. *Marine Geodesy*, 13(2), 91-100.
- Hasegawa, N., Harada, S., Tanaka, S., Ogawa, S., Goto, A., Sasagawa, Y., & Washitake, N. (2012). Multi-Hazard Early Warning System in Japan. M. Golnaraghi içinde, *Institutional Partnerships in Multi-Hazard Early Warning Systems: A Compilation of Seven National Good Practices and Guiding Principles* (s. 181-215). Berlin, Heidelberg: Springer Berlin Heidelberg.
- Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*. New York, NY: Springer. doi:10.1007/978-0-387-84858-7
- Hewamalage, H., Bergmeir, C., & Bandara, K. (2021). Recurrent neural networks for time series forecasting: Current status and future directions. *International Journal of Forecasting*, 37(1), 388-427.

- HGM. (2019, 06 06). *Türkiye Ulusal Deniz Seviyesi İzleme Sistemi*. TUDES: <https://tudes.harita.gov.tr> adresinden alındı
- HGM. (2024, 12 10). *Türkiye Ulusal Deniz Seviyesi İzleme Sistemi*. TUDES: <https://tudes.harita.gov.tr/> adresinden alındı
- Hinton, G. E., & Zemel, R. (1993). Autoencoders, minimum description length and Helmholtz free energy. *Advances in neural information processing systems*, 6.
- Hinton, G., & Salakhutdinov, R. (2006). Reducing the Dimensionality of Data with Neural Networks. *Science*, 313(5786), 504-507. doi:10.1126/science.1127647
- Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 1735-1780.
- Imani, M., Kao, H. C., Lan, W. H., & Kuo, C. Y. (2018). Daily sea level prediction at Chiayi coast, Taiwan using extreme learning machine and relevance vector machine. *Global Planetary change*, 161, 211-221.
- Imani, M., You, R. J., & Kuo, C.-Y. (2013). Accurate Forecasting of the satellite-derived seasonal Caspian sea level anomaly using polynomial interpolation and holt-winters exponential smoothing. *Terrestrial, Atmospheric Oceanic Sciences*, 24(4), 521-535.
- Imani, M., You, R. J., & Kuo, C.-Y. (2014). Forecasting Caspian Sea level changes using satellite altimetry data (June 1992–December 2013) based on evolutionary support vector regression algorithms and gene expression programming. *Global and Planetary Change*, 121, 53-63.
- Imani, M., You, R., & Kuo, C. (2014). Analysis and prediction of caspian sea level pattern anomalies observed by satellite altimetry using autoregressive integrated moving average models. *Arabian journal of geosciences*, 7, 3339–3348.
- Imani, M., You, R., & Kuo, C. (2014). Caspian sea level prediction using satellite altimetry by artificial neural networks. *International journal of environmental science and technology*, 11, 1035–1042.
- Ince, E. S. (2019). ICGEM–15 years of successful collection and distribution of global gravitational models, associated services, and future plans. *Earth System Science Data*, 11(2), 647-674.
- INCOIS. (2024, 12 9). *Indian National Centre for Ocean Information Services*. Indian National Centre for Ocean Information Services: <https://incois.gov.in> adresinden alındı
- Institute, N. M. (2024, 12 9). *Norwegian Meteorological Institute*. <https://www.met.no> adresinden alındı

- Ishida, K. T. (2020). Hourly-scale coastal sea level modeling in a changing climate using long short-term memory neural network. *Science of The Total Environment*, 720, 137613.
- Iz, H. (2018). Why and how to predict sea level changes at a tide gauge station with prediction intervals. *Journal of Geodetic Science*, 8, 121 - 129. doi:10.1515/jogs-2018-0012
- Jaderberg, M., Dalibard, V., Osindero, S., Czarnecki, W. M., Donahue, J., Razavi, A., & Kavukcuoglu, K. (2017). Population based training of neural networks. *arXiv*, preprint arXiv:1711.09846.
- Jansen, E., Martins, D., Stefanizzi, L., Ciliberti, S. A., Gunduz, M., Ilıcak, M., Valchev, N. (2025, 01 03). *Black Sea Physical Analysis and Forecast (Copernicus Marine Service BS-Currents, EAS5 system) (Version 1) Data set*. Copernicus Monitoring Environment Marine Service (CMEMS): https://doi.org/10.25423/cmcc/blksea_analysisforecast_phy_007_001_eas5 adresinden alındı
- Jordan, M. I., & Mitchell, T. M. (2015). Machine learning: Trends, perspectives, and prospects. *Science*, 349(6245), 255-260.
- Junninen, H., Niska, H., Tuppurainen, K., Ruuskanen, J., & Kolehmainen, M. (2004). Methods for imputation of missing values in air quality data sets. *Atmospheric Environment*, 38(18), 2895-2907. doi:10.1016/j.atmosenv.2004.02.026
- Juva, K., Flögel, S., Karstensen, J., Linke, P., & Dullo, W. C. (2020). Tidal dynamics control on cold-water coral growth: A high-resolution multivariable study on eastern Atlantic cold-water coral sites. *Frontiers in Marine Science*, 7(132), 1-20.
- Keskar, N. S., Mudigere, D., Nocedal, J., Smelyanskiy, M., & Tang, P. T. (2016). On large-batch training for deep learning: Generalization gap and sharp minima. *arXiv preprint*, arXiv:1609.04836.
- Khalid, S., Khalil, T., & Nasreen, S. (2014). A survey of feature selection and feature extraction techniques in machine learning. *2014 science and information conference* (s. 372-378). London, UK: IEEE.
- Kim, J., Kong, J., & Son, J. (2021). International Conference on Machine Learning. *Conditional variational autoencoder with adversarial learning for end-to-end text-to-speech* (s. 5530-5540). -: PMLR.
- Kingma, D. P. (2013). Auto-Encoding Variational Bayes. *arXiv preprint arXiv:1312.6114*.
- Kingma, D. P., & Ba, J. (2017). Adam: A Method for Stochastic Optimization. *arXiv*, preprint arXiv:1412.6980.
- Kohavi, R., & Provost, F. (1998). Glossary of terms. *Machine Learning*, 271–274.

- Kordzadze, A. A., & Demetrashvili, D. I. (2011). Operational forecast of hydrophysical fields in the Georgian Black Sea coastal zone within the ECOOP. *Ocean Science*, 793-803.
- Kordzadze, A., & Demetrashvili, D. (2012). Coastal forecasting system for the easternmost part of the Black Sea. *Turkish Journal of Fisheries and Aquatic Sciences*, 12(5), 471-477.
- Korotaev, G. K., Ratner, Y. B., Ivanchik, M. V., Kholod, A. L., & Ivanchik, A. M. (2016). Operational system for diagnosis and forecast of hydrophysical characteristics of the Black Sea. *Izvestiya, Atmospheric and Oceanic Physics*, 52(5), 542-549.
- Kortcheva, A., Dimitrova, M., & Galabov, V. (2012). A wave prediction system for real time sea state forecasting in Black Sea. *arXiv*, preprint arXiv:1212.2123. .
- Kramer, M. A. (1991). Nonlinear principal component analysis using autoassociative neural networks. *AIChE journal*, 37(2), 233-243.
- Kramer, O., Ciaurri, D., & Koziel, S. (2011). Derivative-free optimization. *Computational optimization, methods and algorithms* (s. 61-83). içinde Springer.
- KRDAE. (2024, 12 10). *Bölgesel Deprem-Tsunami İzleme ve Değerlendirme Merkezi*. <http://www.koeri.boun.edu.tr/sismo/2/tr/> adresinden alındı
- Kubryakov, A. I., Korotaev, G. K., Dorofeev, V. L., Ratner, Y. B., Palazov, A., Valchev, N., Oguz, T. (2012). Black Sea coastal forecasting system. *Ocean Science*, 8(2), 183-196.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436-444.
- Leinfelder, R. S. (1993). Sea level change: a philosophical approach. *Geologische Rundschau*, 82, 159-172. doi:10.1007/BF00191822.
- Lericolais, G., Bulois, C., Gillet, H., & Guichard, F. (2009). High frequency sea level fluctuations recorded in the Black Sea since the LGM. *Global and Planetary Change*, 66(1-2), 65-75.
- Li, L., Jamieson, K., DeSalvo, G., Rostamizadeh, A., & Talwalkar, A. (2018). Hyperband: A novel ban-dit-based approach to hyperparameter optimization. *The Journal of Machine Learning Research*, 18, 6765–6816.
- Loshchilov, I., & Hutter, F. (2017). Fixing weight decay regularization in adam. *arXiv*, preprint arXiv:1711.05101, 5.
- Luaran, N. A. (2020). A Review on Deep Learning Approaches to Forecasting the Changes of Sea Level. *Computational Science Technology*, 563.

- Luque, P., Gómez-Pujol, L., Marcos, M., & Orfila, A. (2021). Coastal Flooding in the Balearic Islands During the Twenty-First Century Caused by Sea-Level Rise and Extreme Events. *Frontiers in Marine Science*, 8(1), 676452.
- Makarynsky, O., Makarynska, D., Kuhn, M., & Featherstone, W. (2004). Predicting sea level variations with artificial neural networks at Hillarys Boat Harbour, western Australia. *Estuarine, Coastal and Shelf Science*, 61, 351–360. <https://www.sciencedirect.com/science/article/pii/S0272771404001337>, doi:<https://doi.org/10.1016/j.ecss.2004.06.004>
- Makridakis, S., Spiliotis, E., & Assimakopoulos, V. (2018). Statistical and Machine Learning forecasting methods: Concerns and ways forward. *PloS one*, 13(3), e0194889.
- Mazhar, S., Pellegrini, E., Contin, M., Bravo, C., & De Nobili, M. (2022). Impacts of salinization caused by sea level rise on the biological processes of coastal soils—a review. *Frontiers in Environmental Science*, 10, 909415.
- Melet, A., Buontempo, C., Mattiuzzi, M., Salamon, P., Baharel, P., Breyiannis, G., Voukouvalas, E. (2021). European Copernicus Services to Inform on Sea-Level Rise Adaptation: Current Status and Perspectives. *Frontiers in Marine Science*, 8, 703425. doi:10.3389/fmars.2021.703425
- Miller, A., & Luscher, A. (2018). NOAA's national water level observation network (NWLON). *Journal of Operational Oceanography*, 12(2), 57–66. doi:<https://doi.org/10.1080/1755876X.2018.1523301>
- Moftakhari, H. R., AghaKouchak, A., Sanders, B. F., Feldman, D. L., Sweet, W., Matthew, R. A., & Luke, A. (2015). Increased nuisance flooding along the coasts of the United States due to sea level rise: Past and future. *Geophysical Research Letters*, 42(22), 9846–9852.
- Mohandes, M., Halawani, T., Rehman, S., & Hussain, A. (2004). Support vector machines for wind speed prediction. *Renewable Energy*, 29(6), 939–947. doi:10.1016/j.renene.2003.11.009
- Müller, F. L., Wekerle, C., Dettmering, D., Passaro, M., Bosch, W., & Seitz, F. (2019). Dynamic ocean topography of the northern Nordic seas: a comparison between satellite altimetry and ocean modeling. *The Cryosphere*, 13(2), 611–626.
- Müller, K. R., Smola, A. J., Rätsch, G., Schölkopf, B., Kohlmorgen, J., & Vapnik, V. (1997). Predicting time series with support vector machines. *International Conference on Artificial Neural Networks* (s. 999–1004). Berlin, Heidelberg: Springer.
- Nacar, S., Bayram, A., Baki, O. T., Kankal, M., & Aras, E. (2020). Spatial forecasting of dissolved oxygen concentration in the Eastern Black Sea Basin, Turkey. *Water*, 12(4), 1041.

- Nevermann, H., AghaKouchak, A., & Shokri, N. (2021). Sea-level rise driven soil salinization. *EGU General Assembly 2021 online, 19–30 Apr 2021* (s. EGU21-14453). Online: European Geoscience Union.
- NHC. (2024, 11 29). *Storm Surge Warning System*. National Hurricane Center: <https://www.nhc.noaa.gov/surge/warning/> adresinden alındı
- Niedzielski, T., & Kosek, W. (2009). Forecasting sea level anomalies from topex/poseidon and jason-1 satellite altimetry. *Journal of geodesy*, 83, 469–476.
- Niu, J., Li, S., and Mo, S., Guo, Y., & Wang, L. (2018). Affective Analysis for Video Frames Using ConvLSTM Network. *2018 IEEE International Conference on Communications (ICC)* (s. 1-6). Kansas City: USA.
- Osborne, J. W., & Waters, E. (2002). Four assumptions of multiple regression that researchers should always test. *Practical assessment, research, and evaluation*, 8(1), 1-10.
- Öztürk, E., & Şerbetçi, M. (1992). *Dengeleme Hesabı III*. Trabzon: 539.
- PAGASA. (2024, 12 9). *Philippine Atmospheric, Geophysical and Astronomical Services Administration*. Philippine Atmospheric, Geophysical and Astronomical Services Administration: <https://www.pagasa.dost.gov.ph> adresinden alındı
- Papoulis, A., & Unnikrishna Pillai, S. (2002). *Probability, Random Variables and Stochastic Processes*. New York, NY, USA: McGraw-Hill.
- Pascanu, R., Mikolov, T., & Bengio, Y. (2013). International conference on machine learning. *On the difficulty of training recurrent neural networks* (s. 1310-1318). Atlanta: Pmlr.
- Paul, A., & Rahman, M. (2006). Cyclone mitigation perspectives in the Islands of Bangladesh: a case of Sandwip and Hatia Islands. *Coastal Management*, 34(2), 199-215.
- Paul, B., & Dutt, S. (2010). Hazard warnings and responses to evacuation orders: the case of Bangladesh's cyclone Sidr. *Geographical Review*, 336-355.
- Pavlis, N. K., Holmes, S. A., Kenyon, S. C., & Factor, J. K. (2012). The development and evaluation of the Earth Gravitational Model 2008 (EGM2008). *Journal of geophysical research: solid earth*, 117, 1.
- Pawlowicz, R., Beardsley, B., & Lentz, S. (2002). Classical tidal harmonic analysis including error estimates in MATLAB using T_TIDE. *Computers & Geosciences*, 28(8), 929-937.
- Poole, D. I., Goebel, R. G., & Mackworth, A. K. (1998). *Computational intelligence*. Oxford, UK: Oxford University Press.

- Provost, F. J., Fawcett, T., & Kohavi, R. (1998). The case against accuracy estimation for comparing induction algorithms. *Proceedings of the 15th International Conference on Machine Learning* (s. 445-453). San Francisco, CA: Morgan Kaufmann.
- Pugh, D. T. (1996). *Tides, surges and mean sea-level (reprinted with corrections)*. Chichester, UK: John Wiley & Sons Co.
- Riazi, A. (2020). Accurate tide level estimation: A deep learning approach. *Ocean Engineering*, 198, 107013.
- Roshni, T., Samui, P., & Drisya, J. (2019). Operational use of machine learning models for sea-level modeling. *Indian Journal of Geo Marine Sciences*, 48(9), 1427-1434.
- Ruder, S. (2016). An overview of gradient descent optimization algorithms. *arXiv preprint arXiv:1609.04747*.
- Rudloff, A., Lauterjung, J., Münch, U., & Tinti, S. (2009). Preface" The GITEWS Project (German-Indonesian Tsunami Early Warning System)". *Natural Hazards and Earth System Sciences*, 1381-1382.
- Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning representations by back-propagating errors. *Nature*, 533-536.
- Saeipourdizaj, P., Sarbakhsh, P., & Gholampour, A. (2021). Application of imputation methods for missing values of PM10 and O3 data: Interpolation, moving average and K-nearest neighbor methods. *Environmental Health Engineering and Management Journal*, 215-226.
- Samuel, A. L. (1959). Some Studies in Machine Learning Using the Game of Checkers. *IBM Journal of Research and Development*, 3(3), 210-229. doi:10.1147/rd.33.0210
- Segal, M. R. (2004). Machine Learning Benchmarks and Random Forest Regression. *UCSF: Center for Bioinformatics and Molecular Biostatistics*, 1. <https://escholarship.org/uc/item/35x3v9t4> adresinden alındı
- Sezen, E. (2006). *Antalya-I (1935-1977) ve Antalya-II (1985-2005) Mareograf İstasyonlarında Deniz Seviyesi Değişimlerinin Araştırılması (Yüksek Lisans Tezi)*. Afyonkarahisar, Türkiye: Afyon Kocatepe Üniversitesi.
- Shackleton, N. (1987). Oxygen isotopes, ice volume and sea level. *Quaternary Science Reviews*, 6(3-4), 183-190. doi:10.1016/0277-3791(87)90003-5
- Shaig, A. (2011). *Survey of climate change adaptation measures in the Maldives. Integration of climate change risks into resilient island planning in the Maldives Project. Final Report*. . Ministry of Housing and Environment and United Nations Development Programme.

- Shi, X., Chen, Z., Wang, H., Yeung, D. Y., Wong, W. K., & Woo, W. C. (2015). Convolutional LSTM network: A machine learning approach for precipitation nowcasting. *Advances in Neural Information Processing Systems* (s. 1-20). Curran Associates.
- Shorten, C., & Khoshgoftaar, T. M. (2019). A survey on image data augmentation for deep learning. *Journal of big data*, 6(1), 1-48.
- Shum, C. K. (1995). The accuracy and applications of satellite altimetry. *Geophysical Journal International*, 12(2), 321-336.
- Siegismund, F., Köhl, A., Rummel, R., & Stammer, D. (2020). Temporal variations of the marine geoid. *Journal of Geophysical Research: Oceans*, 125(11), 1-2.
- Simav, M. (2007). *Doğu Akdeniz' de Uydu Altimetre Verileri İle Deniz Seviyesi Değişimlerinin Araştırılması*. İstanbul Teknik Üniversitesi, Jeodezi ve Fotogrametri Mühendisliği. İstanbul: İstanbul Teknik Üniversitesi.
- Smola, A. J., & Schölkopf, B. (2004). A tutorial on support vector regression. *Statistics and computing*, 14, 199-222.
- Snoek, J., Larochelle, H., & Adams, R. P. (2012). Practical bayesian optimization of machine learning algorithms. *Advances in neural information processing systems*, 25, 1-20.
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. (2014). Dropout: a simple way to prevent neural networks from overfitting. *The journal of machine learning research*, 15(1), 1929-1958.
- Srivastava, P. K., Islam, T., Singh, S. K., Petropoulos, G. P., Gupta, M., & Dai, Q. (2016). Forecasting Arabian Sea level rise using exponential smoothing state space models and ARIMA from TOPEX and Jason satellite radar altimeter data. *Meteorological Applications*, 23(4), 633-639.
- Stanev, E. V., & Peneva, E. L. (2001). Regional sea level response to global climatic change: Black Sea examples. *Global and Planetary Change*, 32(1), 33-47.
- Stauffer, P. R., & Paulides, M. (2014). *Comprehensive Biomedical Physics*. Londra: Elsevier.
- Tarca, A., Carey, V., Chen, X., Romero, R., & Drăghici, S. (2007). Machine Learning and Its Applications to Biology. *PLOS Computational Biology*, 3(6), e116. doi:10.1371/journal.pcbi.0030116
- Teferle, F. N. (2003). *Strategies for Long Term Monitoring of Tide Gauges Using GPS. (Doktora Tezi)*. Nottingham, UK: University of Nottingham.
- Thornton, C., Hutter, F., Hoos, H., & Leyton-Brown, K. (2013). Auto-weka: Combined selection and hyperparameter optimization of classification algorithms. *Proceedings of the 19th ACM SIGKDD international conference on Knowledge discovery and data mining* (s. 847-855). New York, NY, USA: Association for Computing Machinery. doi:10.1145/2487575.2487629

- Tieleman, T., & Hinton, G. (2017). Rmsprop: Divide the gradient by a running average of its recent magnitude. coursera: Neural networks for machine learning. *International Conference on Machine Learning* (s. 1-20). San Diego, CA, USA: PMLR.
- Tsimplis, M. N., Josey, S. A., Rixen, M., & Stanev, E. V. (2004). On the forcing of sea level in the Black Sea. *Journal of Geophysical Research: Oceans*, 109(C8).
- TUBITAK. (2024, 12 10). *Denizlerde Bütünleşik Kirlilik İzleme Programı (DEN-İZ)*. DEN-İZ: <https://www.den-iz.org/> adresinden alındı
- Tulus, R., Adytia, D., Subasita, N., & Tarwidi, D. (2020). Sea Level Prediction by Using Seasonal Autoregressive Integrated Moving Average Model, Case Study in Semarang, Indonesia. *2020 8th International Conference on Information and Communication Technology (ICoICT)* (s. 1-5). Yogyakarta, Indonesia: IEEE. doi:10.1109/ICoICT49345.2020.9166423
- Turley, C. (2008). Impacts of changing ocean chemistry in a high-CO2 world. *Mineralogical Magazine*, 72, 359 - 362. doi:10.1180/minmag.2008.072.1.359.
- Uchiike, H., & Hosono, K. (1995). Japan Tsunami Warning System; Present Status and Future Plan. Y. Tsuchiya içinde, *Tsunami: Progress in Prediction, Disaster Prevention and Warning* (s. 305-322). Dordrecht: Springer Netherlands.
- Udama, Z., Claessens, S., Anjasmara, I., & Syafarianty, A. (2023). Analysis of different combinations of gravity data types in gravimetric geoid determination over Bali. *Journal of Applied Geodesy*, 1. doi:10.1515/jag-2023-0042
- UNISDR. (2015). Sendai framework for disaster risk reduction 2015–2030. *The 3rd United Nations World Conference on Disaster Risk Reduction (WCDRR)* (s. 14–18). Sendai, Japan: UNISDR.
- Vafaeipour, M., Rahbari, O., Rosen, M., Fazelpour, F., & Ansarirad, P. (2014). Application of sliding window technique for prediction of wind velocity time series. *International Journal of Energy and Environmental Engineering*, 5, 1-7.
- Van Alphen, J. (2016). The Delta Programme and updated flood risk management policies in the Netherlands. *Journal of Flood Risk Management*, 310-319.
- Van Buuren, S., & Groothuis-Oudshoorn, K. (2011). mice: Multivariate imputation by chained equations in R. *Journal of statistical software*, 45, 1-67.
- Vandenbulcke, L., & Barth, A. (2015). A stochastic operational forecasting system of the Black Sea: Technique and validation. *Ocean Modelling*, 93, 7-21.
- Vanicek, M. P. (1993). *Geoid and its geophysical interpretations*. Londra: CRC Press.
- Varbla S, Ellmann A, & Delpeche-Ellmann N. (2020). Validation of marine geoid models by utilizing hydrodynamic model and shipborne GNSS profiles. *Marine Geodesy*, 43, 134–162.

- Varbla, S., & Ellmann, A. (2023). Iterative data assimilation approach for the refinement of marine geoid models using sea surface height and dynamic topography datasets. *Journal of Geodesy*, 97(3), 24.
- Vaziri, M. (1997). Predicting Caspian Sea surface water level by ANN and ARIMA models. *Journal of waterway, port, coastal, and ocean engineering*, 123(4), 158-162.
- Vincent, P., Larochelle, H., Bengio, Y., & Manzagol, P.-A. (2008). Extracting and composing robust features with denoising autoencoders. *Proceedings of the 25th international conference on Machine learning* (s. 1096-1103). New York, NY, United States: Association for Computing Machinery.
- Westhausen, N. L., & Meyer, B. T. (2020). Dual-signal transformation lstm network for real-time noise suppression. *arXiv preprint arXiv:2005.07551*, arXiv:2005.07551.
- Winona, A. Y. (2020). Short Term Forecasting of Sea Level by Using LSTM with Limited Historical Data. *Toplantıda Sunulan Bildiri*, 1.
- WMO. (2014). *Küresel İklim Hizmetleri Çerçevesi Uygulama Planı*. Geneva, Spain: WMO.
- WMO. (2018). Multi-hazard early warning systems: A checklist. *Multi-hazard Early Warning Conference* (s. 1-10). Cancun, Mexico: World Meteorological Organization.
- WMO. (2022). *Guidelines on Implementation of a Coastal Inundation Forecasting–Early Warning System (WMO-No. 1293)*. Geneva: World Meteorological Organization.
- Wouters, B. &. (2018). Global sea-level budget 1993–present. *Earth System Science Data*, 10(3), 1551-1590.
- Wu, J., Chen, X., Zhang, H., Xiong, L., Lei, H., & Deng, S. (2019). Hyperparameter optimization for machine learning models based on bayesian optimization. *Journal of Electronic Science and Technology*, 17, 26-40. doi:<https://doi.org/10.11989/JEST.1674-862X.80904120>
- Yang, C.-H. W.-H.-M. (2020). Long short-term memory recurrent neural network for tidal level forecasting. *IEEE Access*, 8, 159389-159401., 8, 159389-159401.
- Yavuzdoğan, A., & Kayıkçı, E. T. (2021). Ege Denizi'nde makine öğrenimi yöntemleri ile anlık deniz seviyesi değişimlerinin tahmini. *Jeodezi ve Jeoinformasyon Dergisi*, 8(2), 84-103.
- Yavuzdoğan, A., & Tanır Kayıkçı, E. (2021). A copula approach for sea level anomaly prediction: a case study for the Black Sea. *Survey Review*, 436-446. doi:[10.1080/00396265.2020.1816314](https://doi.org/10.1080/00396265.2020.1816314)
- Yavuzdoğan, A., & Tanır Kayıkçı, E. (2024). Advancing sea level anomaly modeling in the black sea with LSTM Auto-Encoders: A novel approach. *Ocean Modelling*, 193, 102463. doi:<https://doi.org/10.1016/j.ocemod.2024.102463>

- Yin, C., Zhang, S., Wang, J., & Xiong, N. N. (2020). Anomaly detection based on convolutional recurrent autoencoder for IoT time series. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, (s. 112-122).
- Yu, Y., Si, X., Hu, C., & Zhang, J. (2019). A Review of Recurrent Neural Networks: LSTM Cells and Network Architectures. *Neural Computation*, 1235-1270.
- Yüksel, Y., & Esin, Ç. (2016). *Kıyı Mühendisliği*. İstanbul: BETA Yayınevi.
- Yüksel, Y., Öztürk, M., Şahin, C., Halat, O., Doğan, U., Yüksel, Z. T., & Karova, C. (2018). Türkiye Denizlerinde Su Seviyesi Değişimi. 9. *Kıyı Mühendisliği Sempozyumu* (s. 1-10). Adana, Türkiye.: İnşaat Mühendisleri Odası.
- Zaitsev, A. I., & Pelinovsky, E. N. (2011). Forecasting of tsunami wave heights at the Russian Coast of the Black Sea. *Oceanology*, 51(6), 907-915.
- Zalesny, V. B., Diansky, A., N., Fomin, V. V., Moshonkin, S. N., & Demyshev, S. G. (2012). Numerical model of the circulation of the Black Sea and the Sea of Azov. *Russian Journal of Numerical Analysis and Mathematical Modelling*, 27(1), 95-112.
- Zeiler, M. D. (2012). Adadelata: an adaptive learning rate method. *arXiv preprint arXiv:1212.5701*.
- Zhang, C., Bengio, S., Hardt, M., Recht, B., & Vinyals, O. (2021). Understanding deep learning (still) requires rethinking generalization. *Communications of the ACM* (s. 107-115). San Juan, Puerto Rico: ICLR Foundation.
- Zhang, M., Li, X., & Wang, L. (2019). An adaptive outlier detection and processing approach towards time series sensor data. *IEEE Access*, 7, 175192-175212.
- Zhao, J., Cai, R., & Fan, Y. (2019). Prediction of sea level nonlinear trends around shandong peninsula from satellite altimetry. *Sensors*, 19-35.
- Zhou, C., & Paffenroth, R. C. (2017). Anomaly Detection with Robust Deep Autoencoders. *23rd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining* (s. 665–674). New York, NY, United States: Association for Computing Machinery.
- Zhu, X., & Goldberg, A. B. (2022). *Introduction to semi-supervised learning*. İsviçre: Springer Nature.
- Žust, L. F. (2021). HIDRA 1.0: deep-learning-based ensemble sea level forecasting in the northern Adriatic. *Geoscientific Model Development*, 14(4), 2057-2074.

ÖZGEÇMİŞ

Ahmet YAVUZDOĞAN, 2012 yılında Karadeniz Teknik Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği bölümüne başlamış ve 2016 yılında mezun olmuştur. 2017 yılında aynı üniversitenin Fen Bilimleri Enstitüsü, Harita Mühendisliği anabilim dalında yüksek lisans eğitimine başlamış, 2019 yılında “Ege Denizi’nde Bağlı Deniz Seviyesi Değişimlerinin Kapula Fonksiyonları ile İncelenmesi” başlıklı tez çalışmasıyla yüksek lisansını tamamlamıştır. 2019 yılında Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Harita Mühendisliği anabilim dalında doktora eğitimine başlamıştır.

2017 yılında Gümüşhane Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Harita Mühendisliği bölümüne Araştırma Görevlisi olarak atanmış olup halen aynı görevini sürdürmektedir. Doktora süreci boyunca deniz seviyesi anomalilerinin modellenmesi, iklim değişikliğinin etkileri ve yapay zekâ tabanlı erken uyarı sistemleri üzerine yoğunlaşmıştır.

Çalışmaları ile farklı dönemlerde ödüllere layık görülmüştür. 2018 yılında Türkiye Ulusal Jeodezi Komisyonu (TUJK) En İyi Poster Bildiri Ödülü’nü, 2021 yılında ise Harita ve Kadastro Mühendisleri Odası En İyi Poster Sunumu Ödülü’nü kazanmıştır.

Araştırma alanları arasında deniz seviyesi değişimleri, iklim değişikliği, derin öğrenme yöntemleri, yapay sinir ağları ve çevresel modelleme bulunmaktadır. Yabancı dili İngilizcedir. Aşağıda seçili bazı yayınları verilmiştir.

Hakemli Dergilerde Yayımlanan Makaleler:

- Yavuzdoğan, A., Tanır Kayıkçı, E. (2025). Advancing sea level anomaly modeling in the Black Sea with LSTM Auto-Encoders: A novel approach. *Ocean Modelling*, 193, 102463–102480. <https://doi.org/10.1016/j.ocemod.2024.102463>
- Özdemir, S., Yavuzdoğan, A. (2025). Vision Foundation Models and Rule-Based Approaches for Roof Surface Segmentation and Photovoltaic Potential Analysis in Urban Areas. *Turkish Journal of Remote Sensing and GIS*, 6. <https://doi.org/10.48123/rsgis.1606873>
- Özdemir, S., Yavuzdoğan, A., Bilgilioğlu, B.B., Akbulut, Z. (2023). SPAN: An open-source plugin for photovoltaic potential estimation of individual roof segments using point cloud data. *Renewable Energy*, 216. <https://doi.org/10.1016/j.renene.2023.119022>

- Yavuzdoğan, A., Tanır Kayıkçı, E. (2021). A copula approach for sea level anomaly prediction: A case study for the Black Sea. *Survey Review*, 1–11. <https://doi.org/10.1080/00396265.2020.1816314>
- Yavuzdoğan, A., Tanır Kayıkçı, E. (2021). Ege Denizi'nde makine öğrenimi yöntemleri ile anlık deniz seviyesi değişimlerinin tahmini. *Jeodezi ve Jeoinformasyon Dergisi (Online)*, 8(2), 84–103.
- Yavuzdoğan, A., Tanır Kayıkçı, E. (2020). Ege Denizi Bağlı Deniz Seviyesi Değişimlerinde Kapula Fonksiyonları ile Trend Analizleri. *Doğal Afetler ve Çevre Dergisi*, 6(1), 49–65. <https://doi.org/10.21324/dacd.574930>

