

T.C.
SİNOP ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
DİSİPLİNLERARASI NÜKLEER ENERJİ VE ENERJİ
SİSTEMLERİ ANABİLİM DALI



MAKİNE ÖĞRENMESİ İLE DALGA GÜCÜNDEN ELEKTRİK
ENERJİSİ TAHMİNİ

DUYGU SAYDAM İRİM

YÜKSEK LİSANS TEZİ

DANIŞMAN
PROF. DR. MURAT SARIKAYA

II. DANIŞMAN
DR. ÖĞR. ÜYESİ SALİH DAĞLI

SİNOP- 2025

TEZ KABUL

Duygu SAYDAM İRİM tarafından hazırlanan “**MAKİNE ÖĞRENMESİ İLE DALGA GÜCÜNDEN ELEKTRİK ENERJİSİ TAHMİNİ** ” başlıklı bu çalışma, 06/01/2025 tarihinde yapılan savunma sınavı sonucunda başarılı bulunarak, jürimiz tarafından **YÜKSEK LİSANS tezi** olarak kabul edilmiştir.

Başkan

Prof. Dr. Turgay KIVAK
Düzce Üniversitesi / Mühendislik Fakültesi

İmza

**Üye
(Danışman)**

Prof. Dr. Murat SARIKAYA
Sinop Üniversitesi / Mühendislik ve Mimarlık Fakültesi

İmza

Üye

Doç. Dr. Mustafa Kemal BALKİ
Sinop Üniversitesi / Mühendislik ve Mimarlık Fakültesi

İmza

Enstitü Müdürü

Doç. Dr. Hüseyin Turan ARAT

.....

ETİK BEYANI

Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmasında; tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi, tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu, tez çalışmasında yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi, kullanılan verilerde herhangi bir değişiklik yapmadığımı, bu tezde sunduğum çalışmanın özgün olduğunu, bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

Duygu SAYDAM İRİM

ÖZET

YÜKSEK LİSANS TEZİ

MAKİNE ÖĞRENMESİ İLE DALGA GÜCÜNDEN ELEKTRİK ENERJİSİ TAHMİNİ

DUYGU SAYDAM İRİM

SİNOP ÜNİVERSİTESİ LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ DISİPLINLERARASI NÜKLEER ENERJİ VE ENERJİ SİSTEMLERİ ANABİLİM DALI

DANIŞMAN: PROF. DR. MURAT SARIKAYA

II. DANIŞMAN: DR. ÖĞR. ÜYESİ SALİH DAĞLI

Bu tezde, Karadeniz'deki meteorolojik veriler kullanılarak dalga gücünden üretilen elektrik enerjisi miktarının tahmini için makine öğrenmesi tabanlı bir hibrit model geliştirilmiştir. Çalışmada, Meteoroloji Genel Müdürlüğü'nden elde edilen Samsun ve Ordu şamandıralarına ait 2023 yılına ilişkin 1 yıllık veri seti kullanılmıştır. Bu veri setinde dalga yüksekliği, dalga periyodu, rüzgâr hızı ve su sıcaklığı gibi parametrelere yer verilmiştir. Dalga gücü tahmini için öncelikle LSTM, ELM, ResNet, SVM, Bayesian ve RNN algoritmalarını içeren temel regresyon modelleri geliştirilmiş ve bu modellerin güçlü ve zayıf yönleri analiz edilmiştir. Daha sonra, temel modellerin performansını iyileştirmek amacıyla XGB algoritması ile yığınlama (stacking) yaklaşımı uygulanarak hibrit bir model oluşturulmuştur. Hibrit modelin performansı, MAE, RMSE, MSE ve R^2 gibi göstergeler kullanılarak değerlendirilmiş ve XGB algoritmasının diğer modellere kıyasla daha iyi sonuçlar verdiği gözlemlenmiştir. Örneğin, Samsun şamandırasındaki tahminlerde ResNet algoritması için 0.0491 olan MAE değeri, hibrit modelde 0.0079'a düşürülmüştür. Bu sonuçlar, hibrit modelin dalga gücü tahmininde yüksek doğruluk sağladığını ve dalga enerjisinin düzensiz karakteristiğini düzenlemede etkili bir araç olduğunu kanıtlamıştır. Tezin sonucunda, önerilen modelin kısa vadede dalga gücünden üretilen elektrik enerjisinin sistemdeki düzensizliklerini tahmin ederek enerji düzenlemesine katkı sağlayabileceği sonucuna varılmıştır. Ayrıca, modelin uzun vadede dalga enerji dönüşüm sistemlerinin kurulacağı bölgelerin aylık ve yıllık elektrik üretim potansiyelinin hesaplanmasında kullanılabileceği de öngörülmektedir. Bu çalışma, dalga enerjisi tahmini alanında makine öğrenmesi algoritmalarının etkinliğini ortaya koymakta ve enerji dönüşüm sistemlerinin planlanması için yenilikçi bir yaklaşım sunmaktadır.

ANAHTAR KELİMELELER: ResNet; Yığınlama Yaklaşımı; XGB Algoritması; Dalga Gücü

Ocak 2025, 163 Sayfa

ABSTRACT

MSC THESIS

ESTIMATING ELECTRIC ENERGY FROM WAVEPOWER WITH MACHINE LEARNING

DUYGU SAYDAM İRİM

**SINOP UNIVERSITY INSTITUTE OF GRADUATE PROGRAMS
INTERDISCIPLINARY DEPARTMENT OF NUCLEAR ENERGY AND
ENERGY SYSTEMS**

**SUPERVISOR: PROF. DR. MURAT SARIKAYA
CO-SUPERVISOR: ASST. PROF. DR. SALİH DAĞLI**

In this thesis, a machine learning-based hybrid model is developed to predict the electrical energy generated from wave power using meteorological data in the Black Sea. In the study, a one-year dataset for the Samsun and Ordu buoys, obtained from the General Directorate of Meteorology for the year 2023, was used. This dataset contains parameters such as wave height, wave period, wind speed, water temperature and so on. To predict wave power, basic regression models including LSTM, ELM, ResNet, SVM, Bayesian, and RNN algorithms were developed, and their strengths and weaknesses were analyzed. A hybrid model was created by applying a stacking approach using the XGB algorithm to improve the performance of the base models. The performance of the hybrid model was evaluated using MAE, RMSE, MSE, and R^2 metrics, and it was observed that the XGB algorithm produced better results compared to other models. For example, in the forecasts at the Samsun buoy, the MAE value of 0.0491 for the ResNet algorithm was reduced to 0.0079 in the hybrid model. These results prove that the hybrid model provides high accuracy in wave power prediction and serves as an effective tool for regulating the irregular characteristics of wave energy. As a result of the thesis, it is concluded that the proposed model can contribute to energy regulation by predicting the irregularities in the electrical energy system generated from wave power in the short term. It is also expected that the model can be used to calculate the monthly and annual electricity generation potential in regions where wave energy conversion systems are planned for long-term deployment. This study demonstrates the effectiveness of machine learning algorithms in wave energy forecasting and offers an innovative approach to energy conversion system planning.

KEYWORDS: ResNet; Stacking Approaches; XGB Algorithm; Wave Power

January 2025, 163 Pages

TEŞEKKÜR

Bu tez çalışmasında, bana daima yol gösteren ve kıymetli bilgilerini benimle paylaşan değerli danışmanım Sayın Prof. Dr. Murat SARIKAYA'ya, bilgi ve birikimlerini çalışma süresi boyunca paylaşan eş danışman hocam Sayın Dr. Öğr. Üyesi Salih DAĞLI'ya, tez savunma jürimde yer alan değerli hocalarıma ve her zaman yanımda olan aileme sonsuz teşekkür ve saygılarımı sunarım. Tez çalışmasında kullanılan şamandıra verilerinin sağlanması konusunda Meteoroloji Genel Müdürlüğü'ne teşekkürlerimi sunarım.

Duygu SAYDAM İRİM



İÇİNDEKİLER

Sayfa

TEZ KABUL	i
ETİK BEYANI.....	ii
ÖZET	iii
ABSTRACT.....	iv
TEŞEKKÜR	v
İÇİNDEKİLER.....	vi
ŞEKİLLER DİZİNİ.....	ix
TABLolar DİZİNİ.....	xiii
SİMGELER VE KISALTMALAR DİZİNİ.....	xvii
1. GİRİŞ.....	1
2. ENERJİ.....	3
2.1 Yenilebilir Enerji Kaynakları.....	5
2.1.1 Güneş enerjisi	6
2.1.2 Rüzgar enerjisi	7
2.1.3 Jeotermal enerji.....	8
2.1.4 Hidroelektrik enerji.....	9
2.1.5 Biyokütle enerji.....	11
2.1.6 Dalga enerjisi	12
2.1.7 Hidrojen enerjisi	12
3. DALGA ENERJİSİ.....	14
3.1 Dünya’da Dalga Enerjisi.....	16
3.2 Türkiye’de Dalga Enerjisi.....	16
3.3 Dalga Enerjisinin Avantajları ve Dezavantajları	19
3.4 Dalga Enerjisinin Hesabı	21
3.5 Dalga Enerji Sistemlerinde Derin Öğrenme Algoritmalarının Kullanımı	22
4. LİTERATÜR TARAMASI.....	27
5. MATERYAL VE YÖNTEM.....	36
5.1 Veri Setinin Oluşturulması	36
5.2 Aşırı Öğrenme Makinesi (ELM).....	38
5.3 Bayes Regresyon.....	40

5.4 Uzun-Kısa Süreli Bellek (LSTM).....	42
5.5 Tekrarlayan Sinir Ağı (RNN)	47
5.6 Destek Vektör Makinesi (SVM).....	48
5.7 Artık Sinir Ağı (ResNet).....	50
5.8 Yığınlama Algoritmaları (Stacking Algorithm)	52
5.9 Metrik Değerlendirme Parametreleri	55
5.10 Sistem Tasarımı	56
6. BULGULAR	59
6.1 Ordu Şamandıra Dalga Yüksekliği ve Periyodu Tahminleri	65
6.1.1 ResNet regresyon modeli performansı	65
6.1.2 ELM regresyon modeli performansı.....	68
6.1.3 Bayesian regresyon modeli performansı.....	70
6.1.4 LSTM regresyon modeli performansı.....	73
6.1.5 RNN regresyon modeli performansı.....	75
6.1.6 SVM regresyon modeli performansı.....	78
6.2 Samsun Şamandıra Dalga Yüksekliği ve Periyodu Tahminleri.....	80
6.2.1 ResNet regresyon modeli performansı	80
6.2.2 ELM regresyon modeli performansı.....	83
6.2.3 Bayesian regresyon modeli performansı.....	86
6.2.4 LSTM regresyon modeli performansı.....	89
6.2.5 RNN regresyon modeli performansı.....	92
6.2.6 SVM regresyon modeli performansı.....	95
6.3 Ordu Şamandırası için Regresyon Modellerinin Saat Aralıklarındaki Performanslarının Karşılaştırılması	98
6.3.1 Dalga boyu yüksekliği tahmini	98
6.3.2 Dalga periyodu tahmini	103
6.4 Samsun Şamandırası için Regresyon Modellerinin Saat Aralıklarındaki Performanslarının Karşılaştırılması	107
6.4.1 Dalga boyu yüksekliği tahmini	107
6.4.2 Dalga periyodu tahmini	111
6.5 Yığınlama Yaklaşımının Ordu ve Samsun Şamandıra Verilerindeki Performansı	115
6.6 Dalga Gücünün Hesaplanması ve Sistem Performansının Değerlendirilmesi.....	120
7. TARTIŞMA	124
8. SONUÇLAR VE ÖNERİLER	134

KAYNAKLAR	139
ÖZGEÇMİŞ	145



ŞEKİLLER DİZİNİ

	Sayfa
Şekil 2.1 Enerji kaynaklarının sınıflandırılması	4
Şekil 2.2 Enerji (a) Türkiye’de enerji kaynaklarının kullanım oranları; (b) Dünya’da enerji kaynaklarının kullanım oranları (Koç ve Şenel, 2013).....	5
Şekil 2.3 Yenilebilir enerji türleri ve kaynakları	6
Şekil 2.4 Türkiye’de kurulu güneş enerji gücü (Enerji ve Tabi Kaynaklar Bakanlığı, 2022)	7
Şekil 2.5 Türkiye’de kurulu rüzgar enerji sistemlerinin yıllara göre toplam gücü (Enerji ve Tabi Kaynaklar Bakanlığı, 2022).....	8
Şekil 2.6 Türkiye’de jeotermal enerji sistemlerinin toplam kurulu gücünün yıllara göre değeri (Enerji ve Tabi Kaynaklar Bakanlığı, 2022).....	9
Şekil 2.7 Türkiye’de hidrolik enerji sistemlerinin toplam kurulu gücünün yıllara göre değeri (Enerji ve Tabi Kaynaklar Bakanlığı, 2022).....	10
Şekil 2.8 Türkiye’de biyokütle enerji sistemlerinin toplam kurulu gücünün yıllara göre değeri (Enerji ve Tabi Kaynaklar Bakanlığı, 2022).....	12
Şekil 3.1 Yaygın olarak uygulanan doğrudan ve dolaylı yapay zeka tabanlı algoritmalarının sınıflandırılması (Clemente vd., 2023)	25
Şekil 5.1 Ordu (17397) şamandırasının Türkiye haritası üzerindeki konumu	36
Şekil 5.2 Samsun (17391) şamandırasının Türkiye haritası üzerindeki konumu	37
Şekil 5.3 ELM’nin regresyon yapısı.....	40
Şekil 5.4 Bayesian regresyon algoritmasının çalışma prensibi	41
Şekil 5.5 LSTM hücresinin yapısı	43
Şekil 5.6 Unutma (forgot) kapısının akış şeması.....	44
Şekil 5.7 Bilgi güncelleme işleminin akış şeması	45
Şekil 5.8 Yeni hücre bilgisinin oluşturulmasına ait akış şeması	45
Şekil 5.9 Çıktı değerlerinin hesaplanmasına ait akış şeması	46
Şekil 5.10 İleri beslemeli sinir ağı ve RNN arasındaki yapısal farklılık	47
Şekil 5.11 RNN algoritmasının yapısal döngüsü.....	48
Şekil 5.12 Destek vektör makinesinin çalışma prensibi	49
Şekil 5.13 Res-Net algoritmasının yapısı	51
Şekil 5.14 Yığınlama yaklaşımı ile regresyon işleminin akış şeması.....	53

Şekil 5.15 XGBoost algoritmasının akış şeması	54
Şekil 5.16 Sistemin akış şeması.....	58
Şekil 6.1 Ordu şamandırasının 1 yıllık ölçülen dalga boyu yüksekliği değerleri.....	59
Şekil 6.2 Ordu şamandırasının 1 yıllık ölçülen dalga periyodu değerleri	59
Şekil 6.3 Samsun şamandırasının 1 yıllık ölçülen dalga boyu yüksekliği değerleri	60
Şekil 6.4 Samsun şamandırasının 1 yıllık ölçülen dalga periyodu değerleri.....	60
Şekil 6.5 ResNet regresyon modelinin dalga yüksekliği için 1 saatlik tahmin ve test verilerinin karşılaştırılması	65
Şekil 6.6 ResNet regresyon modelinin dalga periyodu için 1 saatlik tahmin ve test verilerinin karşılaştırılması	67
Şekil 6.7 ELM regresyon modelinin dalga yüksekliği için 24 saatlik tahmin ve test verilerinin karşılaştırılması	68
Şekil 6.8 ELM regresyon modelinin dalga periyodu için 24 saatlik tahmin ve test verilerinin karşılaştırılması	69
Şekil 6.9 Bayesian regresyon modelinin dalga yüksekliği için 6 saatlik tahmin ve test verilerinin karşılaştırılması	71
Şekil 6.10 Bayesian regresyon modelinin dalga periyodu için 6 saatlik tahmin ve test verilerinin karşılaştırılması	72
Şekil 6.11 LSTM regresyon modelinin dalga yüksekliği için 3 saatlik tahmin ve test verilerinin karşılaştırılması	73
Şekil 6.12 LSTM regresyon modelinin dalga periyodu için 3 saatlik tahmin ve test verilerinin karşılaştırılması	74
Şekil 6.13 RNN regresyon modelinin dalga yüksekliği için 12 saatlik tahmin ve test verilerinin karşılaştırılması	76
Şekil 6.14 RNN regresyon modelinin dalga periyodu için 12 saatlik tahmin ve test verilerinin karşılaştırılması	77
Şekil 6.15 SVM regresyon modelinin dalga yüksekliği için 72 saatlik tahmin ve test verilerinin karşılaştırılması	78
Şekil 6.16 SVM regresyon modelinin dalga periyodu için 72 saatlik tahmin ve test verilerinin karşılaştırılması	79
Şekil 6.17 ResNet regresyon modelinin dalga yüksekliği için 1 saatlik tahmin ve test verilerinin karşılaştırılması	81
Şekil 6.18 ResNet regresyon modelinin dalga periyodu için 1 saatlik tahmin ve test verilerinin karşılaştırılması	82

Şekil 6.19 ELM regresyon modelinin dalga yüksekliği için 24 saatlik tahmin ve test verilerinin karşılaştırılması	83
Şekil 6.20 ELM regresyon modelinin dalga periyodu için 24 saatlik tahmin ve test verilerinin karşılaştırılması	85
Şekil 6.21 Bayesian regresyon modelinin dalga yüksekliği için 6 saatlik tahmin ve test verilerinin karşılaştırılması	86
Şekil 6.22 Bayesian regresyon modelinin dalga periyodu için 6 saatlik tahmin ve test verilerinin karşılaştırılması	88
Şekil 6.23 LSTM regresyon modelinin dalga yüksekliği için 3 saatlik tahmin ve test verilerinin karşılaştırılması	89
Şekil 6.24 LSTM regresyon modelinin dalga periyodu için 3 saatlik tahmin ve test verilerinin karşılaştırılması	91
Şekil 6.25 RNN regresyon modelinin dalga yüksekliği için 12 saatlik tahmin ve test verilerinin karşılaştırılması	92
Şekil 6.26 RNN regresyon modelinin dalga periyodu için 12 saatlik tahmin ve test verilerinin karşılaştırılması	94
Şekil 6.27 SVM regresyon modelinin dalga yüksekliği için 72 saatlik tahmin ve test verilerinin karşılaştırılması	95
Şekil 6.28 SVM regresyon modelinin dalga periyodu için 72 saatlik tahmin ve test verilerinin karşılaştırılması	96
Şekil 6.29 XGB algoritmasının Ordu şamandırasında dalga boyu yüksekliği için tahmin ve test verilerinin karşılaştırılması	116
Şekil 6.30 XGB algoritmasının Ordu şamandırasında dalga periyodu için tahmin ve test verilerinin karşılaştırılması	118
Şekil 6.31 XGB algoritmasının Samsun şamandırasında dalga boyu yüksekliği için tahmin ve test verilerinin karşılaştırılması	119
Şekil 6.32 XGB algoritmasının Samsun şamandırasında dalga periyodu için tahmin ve test verilerinin karşılaştırılması	120
Şekil 6.33 Ordu şamandırasında XGB algoritmasının dalga gücü için tahmin ve test verilerinin karşılaştırılması	122
Şekil 6.34 Ordu şamandırasında ResNet algoritmasının dalga gücü için tahmin ve test verilerinin karşılaştırılması	122
Şekil 6.35 Samsun şamandırasında XGB algoritmasının dalga gücü için tahmin ve test verilerinin karşılaştırılması	123

Şekil 6.36 Samsun şamandırasında ResNet algoritmasının dalga gücü için tahmin ve test verilerinin karşılaştırılması.....	123
---	-----



TABLÖLER DİZİNİ

Sayfa

Tablo 3.1 Dalga enerjisi açısından zengin bazı bölgelerin sahip olduğu net dalga gücü (Teixeira-Duarte vd., 2022)	16
Tablo 3.2 Türkiye’de bölgelere göre dalga yoğunlukları (Yesilyurt vd., 2017)	17
Tablo 3.3 Çalışma noktalarında dalga enerjisi potansiyeli ve ortalama dalga enerjisi (Akpınar & Kömürcü, 2012)	18
Tablo 6.1 Ordu şamandırasının ölçüm parametrelerinin ortalama, standart sapma, minimum ve maksimum değerleri	61
Tablo 6.2 Samsun şamandırasının ölçüm parametrelerinin ortalama, standart sapma, minimum ve maksimum değerleri	62
Tablo 6.3 Ordu şamandırası ölçümlerinin Pearson korelasyon testi sonuçları	63
Tablo 6.4 Samsun şamandırası ölçümlerinin Pearson korelasyon testi sonuçları.....	64
Tablo 6.5 Dalga yüksekliği için saat aralıklarına göre ResNet regresyon modellerinin değerlendirme metrik değerleri.....	66
Tablo 6.6 Dalga periyodu için saat aralıklarına göre ResNet regresyon modellerinin değerlendirme metrik değerleri.....	67
Tablo 6.7 Dalga yüksekliği için saat aralıklarına göre ELM regresyon modellerinin değerlendirme metrik değerleri.....	69
Tablo 6.8 Dalga periyodu için saat aralıklarına göre ELM regresyon modellerinin değerlendirme metrik değerleri.....	70
Tablo 6.9 Dalga yüksekliği için saat aralıklarına göre Bayesian regresyon modellerinin değerlendirme metrik değerleri.....	71
Tablo 6.10 Dalga periyodu için saat aralıklarına göre Bayesian regresyon modellerinin değerlendirme metrik değerleri.....	73
Tablo 6.11 Dalga yüksekliği için saat aralıklarına göre LSTM regresyon modellerinin değerlendirme metrik değerleri.....	74
Tablo 6.12 Dalga periyodu için saat aralıklarına göre LSTM regresyon modellerinin değerlendirme metrik değerleri.....	75
Tablo 6.13 Dalga yüksekliği için saat aralıklarına göre RNN regresyon modellerinin değerlendirme metrik değerleri.....	76

Tablo 6.14 Dalga periyodu için saat aralıklarına göre RNN regresyon modellerinin değerlendirme metrik değerleri.....	78
Tablo 6.15 Dalga yüksekliği için saat aralıklarına göre SVM regresyon modellerinin değerlendirme metrik değerleri.....	79
Tablo 6.16 Dalga periyodu için saat aralıklarına göre SVM regresyon modellerinin değerlendirme metrik değerleri.....	80
Tablo 6.17 Dalga yüksekliği için saat aralıklarına göre ResNet regresyon modellerinin değerlendirme metrik değerleri.....	82
Tablo 6.18 Dalga periyodu için saat aralıklarına göre ResNet regresyon modellerinin değerlendirme metrik değerleri.....	83
Tablo 6.19 Dalga yüksekliği için saat aralıklarına göre ELM regresyon modellerinin değerlendirme metrik değerleri.....	84
Tablo 6.20 Dalga periyodu için saat aralıklarına göre ELM regresyon modellerinin değerlendirme metrik değerleri.....	86
Tablo 6.21 Dalga yüksekliği için saat aralıklarına göre Bayesian regresyon modellerinin değerlendirme metrik değerleri.....	87
Tablo 6.22 Dalga periyodu için saat aralıklarına göre Bayesian regresyon modellerinin değerlendirme metrik değerleri.....	89
Tablo 6.23 Dalga yüksekliği için saat aralıklarına göre LSTM regresyon modellerinin değerlendirme metrik değerleri.....	90
Tablo 6.24 Dalga periyodu için saat aralıklarına göre LSTM regresyon modellerinin değerlendirme metrik değerleri.....	92
Tablo 6.25 Dalga yüksekliği için saat aralıklarına göre RNN regresyon modellerinin değerlendirme metrik değerleri.....	93
Tablo 6.26 Dalga periyodu için saat aralıklarına göre RNN regresyon modellerinin değerlendirme metrik değerleri.....	95
Tablo 6.27 Dalga yüksekliği için saat aralıklarına göre SVM regresyon modellerinin değerlendirme metrik değerleri.....	96
Tablo 6.28 Dalga periyodu için saat aralıklarına göre SVM regresyon modellerinin değerlendirme metrik değerleri.....	97
Tablo 6.29 1 saatlik dalga boyu yüksekliği tahmin aralığı için temel regresyon modellerinin değerlendirme metrik değerleri	98
Tablo 6.30 3 saatlik dalga boyu yüksekliği tahmin aralığı için temel regresyon modellerinin değerlendirme metrik değerleri	99

Tablo 6.31 6 saatlik dalga boyu yüksekliđi tahmin aralıđı için temel regresyon modellerinin deđerlendirme metrik deđerleri	100
Tablo 6.32 12 saatlik dalga boyu yüksekliđi tahmin aralıđı için temel regresyon modellerinin deđerlendirme metrik deđerleri	101
Tablo 6.33 24 saatlik dalga boyu yüksekliđi tahmin aralıđı için temel regresyon modellerinin deđerlendirme metrik deđerleri	102
Tablo 6.34 72 saatlik dalga boyu yüksekliđi tahmin aralıđı için temel regresyon modellerinin deđerlendirme metrik deđerleri	103
Tablo 6.35 1 saatlik dalga periyodu tahmin aralıđı için temel regresyon modellerinin deđerlendirme metrik deđerleri.....	104
Tablo 6.36 3 saatlik dalga periyodu tahmin aralıđı için temel regresyon modellerinin deđerlendirme metrik deđerleri.....	104
Tablo 6.37 6 saatlik dalga periyodu tahmin aralıđı için temel regresyon modellerinin deđerlendirme metrik deđerleri.....	105
Tablo 6.38 12 saatlik dalga periyodu tahmin aralıđı için temel regresyon modellerinin deđerlendirme metrik deđerleri.....	106
Tablo 6.39 24 saatlik dalga periyodu tahmin aralıđı için temel regresyon modellerinin deđerlendirme metrik deđerleri.....	107
Tablo 6.40 72 saatlik dalga periyodu tahmin aralıđı için temel regresyon modellerinin deđerlendirme metrik deđerleri.....	107
Tablo 6.41 1 saatlik dalga boyu yüksekliđi tahmin aralıđı için temel regresyon modellerinin deđerlendirme metrik deđerleri	108
Tablo 6.42 3 saatlik dalga boyu yüksekliđi tahmin aralıđı için temel regresyon modellerinin deđerlendirme metrik deđerleri	109
Tablo 6.43 6 saatlik dalga boyu yüksekliđi tahmin aralıđı için temel regresyon modellerinin deđerlendirme metrik deđerleri	109
Tablo 6.44 12 saatlik dalga boyu yüksekliđi tahmin aralıđı için temel regresyon modellerinin deđerlendirme metrik deđerleri	110
Tablo 6.45 24 saatlik dalga boyu yüksekliđi tahmin aralıđı için temel regresyon modellerinin deđerlendirme metrik deđerleri	110
Tablo 6.46 72 saatlik dalga boyu yüksekliđi tahmin aralıđı için temel regresyon modellerinin deđerlendirme metrik deđerleri	111
Tablo 6.47 1 saatlik dalga periyodu tahmin aralıđı için temel regresyon modellerinin deđerlendirme metrik deđerleri.....	112

Tablo 6.48 3 saatlik dalga periyodu tahmin aralığı için temel regresyon modellerinin değerlendirme metrik değerleri.....	112
Tablo 6.49 6 saatlik dalga periyodu tahmin aralığı için temel regresyon modellerinin değerlendirme metrik değerleri.....	113
Tablo 6.50 12 saatlik dalga periyodu tahmin aralığı için temel regresyon modellerinin değerlendirme metrik değerleri.....	114
Tablo 6.51 24 saatlik dalga periyodu tahmin aralığı için temel regresyon modellerinin değerlendirme metrik değerleri.....	114
Tablo 6.52 72 saatlik dalga periyodu tahmin aralığı için temel regresyon modellerinin değerlendirme metrik değerleri.....	115
Tablo 6.53 XGB algoritmasının (meta-model) Ordu şamandırası dalga yüksekliği tahmini için saat aralıklarına ait değerlendirme metrik değerleri	116
Tablo 6.54 XGB algoritmasının (meta-model) Ordu şamandırası dalga yüksekliği tahmini için saat aralıklarına ait değerlendirme metrik değerleri	117
Tablo 6.55 XGB algoritmasının (meta-model) Samsun şamandırası dalga yüksekliği tahmini için saat aralıklarına ait değerlendirme metrik değerleri	119
Tablo 6.56 XGB algoritmasının (meta-model) Ordu şamandırası dalga yüksekliği tahmini için saat aralıklarına ait değerlendirme metrik değerleri	120
Tablo 7.1 Ordu şamandırası dalga yüksekliği tahmini için ResNet ve XGB algoritmalarının saat aralıklarına göre metrik değerleri	125
Tablo 7.2 Ordu şamandırası dalga periyodu için ResNet ve XGB algoritmalarının saat aralıklarına göre metrik değerleri	127
Tablo 7.3 Samsun şamandırası dalga yüksekliği tahmini için ResNet ve XGB algoritmalarının saat aralıklarına göre metrik değerleri	128
Tablo 7.4 Samsun şamandırası dalga periyodu için ResNet ve XGB algoritmalarının saat aralıklarına göre metrik değerleri	129
Tablo 7.5 Ordu ve Samsun şamandırasının dalga gücü tahmini için ResNet ve XGB algoritmalarının saat aralıklarına göre metrik değerleri	130

SİMGELER VE KISALTMALAR DİZİNİ

Simgeler

<i>P</i>	: Dalga gücü (kW/m)
<i>H</i>	: Dalga yüksekliği (m)
<i>T</i>	: Dalga periyodu (s)
<i>ρ</i>	: Su yoğunluğu (kg/m ³)
<i>g</i>	: Yerçekimi ivmesi (m/s ²)
<i>C_g</i>	: Grup hızı (m/s)
<i>E</i>	: Dalga enerjisi yoğunluğu (J/m ²)

Kısaltmalar

R²	: Korelasyon katsayısı
MAE	: Ortalama mutlak hata
RMSE	: kök ortalama kare hatası
MSE	: ortalama hata karesi
LSTM	: Uzun kısa süreli hafıza
RNN	: Tekrarlayan sinir ağı
ResNet	: Artık sinir ağı
SVM	: Destek vektör makinesi
ELM	: Aşırı öğrenme makinesi
XGB	: Ekstrem gradyan artırma
YSA	: Yapay Sinir Ağları
DED	: Dalga Enerji Dönüştürücüleri
GBM	: Eğilim Artırma Makinesine

1. GİRİŞ

Gündelik yaşamda, ısınma, aydınlatma, ulaşım, iletişim ve sanayi üretimi gibi birçok alanda enerjiye olan ihtiyaç her geçen gün artmaktadır. Bu artan talep, enerji kaynaklarının verimli bir şekilde kullanılmasını ve sürdürülebilir enerji çözümlerinin geliştirilmesini zorunlu kılmaktadır. Enerji kaynakları, genellikle yenilenebilir ve yenilenemez olmak üzere iki ana kategoriye ayrılmaktadır. Yenilenebilir enerji kaynakları, doğada kendiliğinden yenilenen ve tükenmeyen kaynaklar olup, çevreye minimum zarar vererek sürdürülebilir enerji üretimi sağlar. Bu kaynaklar arasında güneş, rüzgar, hidroelektrik, biyokütle ve dalga enerjisi gibi çevre dostu seçenekler yer almaktadır. Yenilenebilir enerji kaynaklarının artan önemi, fosil yakıtların çevreye verdikleri zararlar ve sınırlı olmaları nedeniyle giderek daha fazla hissedilmektedir.

Dalga enerjisi, okyanuslarda ve denizlerdeki dalgaların hareketinden elde edilen bir enerji türüdür. Dünya yüzeyinin yaklaşık %70'inin okyanuslarla kaplı olduğu düşünüldüğünde, dalga enerjisinin potansiyeli oldukça yüksektir. Okyanusların sahip olduğu enerji potansiyeli, dalga enerjisinin önemli bir yenilenebilir enerji kaynağı olarak kullanılmasını mümkün kılmaktadır. Dalga enerjisinin çevresel etkileri, diğer enerji üretim yöntemlerine göre çok daha düşüktür. Bu, dalga enerjisinin çevre dostu bir seçenek olarak öne çıkarmaktadır. Bununla birlikte, dalga enerjisinin ticari ölçekte kullanılabilirliği henüz gelişme aşamasındadır. Dalga enerjisi sistemlerinin verimli bir şekilde çalışabilmesi için, dalgaların doğal yapısının düzensiz karakteristiği, dalga enerji dönüştürücüleri ve bu sistemlerin karmaşık yapısı gibi bazı zorluklar aşılmalıdır. Dalga enerjisi üretimi, dalgaların enerjilerini emebilecek çeşitli sistemler kullanılarak gerçekleştirilir. Bu sistemler arasında salınlı su sütunları, salınlı gövde dönüştürücüleri ve üst üste binen dönüştürücüler gibi teknolojiler yer almaktadır. Bu sistemlerin kurulumu, özellikle doğrudan sürüştü dalga enerji sistemlerinde, güç elektroniği ara elemanları, enerji depolama üniteleri ve karma enerji sistemleri gibi ek bileşenler gerektirmektedir.

Dalga enerjisinin düşük verimliliği ve düzensiz enerji üretim karakteristiği, enerji üretiminde karşılaşılan en büyük zorluklardan biridir. Bu nedenle, dalga enerjisi sistemlerinin etkinliğini artırmak için çeşitli yöntemler geliştirilmiştir. Bu yöntemlerden biri, dalga enerjisinin tahmin edilmesidir. Dalga enerjisinin tahmini, sistemdeki enerjinin düzenlenmesi ve verimli bir şekilde kullanılabilmesi için kritik bir rol oynamaktadır. Dalga enerjisinin düzensiz üretim karakteristiği, yapay zekâ ve makine öğrenmesi

algoritmaları ile tahmin edilerek yönetilebilir. Bu tür tahminler, özellikle okyanuslara yerleştirilen şamandıralar aracılığıyla ölçülen parametreler (basınç, deniz suyu sıcaklığı, rüzgâr hızı vb.) kullanılarak yapılmaktadır. Bu parametreler, dalga yüksekliği ve periyodunun tahmin edilmesinde önemli bir veri kaynağı oluşturmaktadır. Son yıllarda, derin öğrenme yöntemleri ve makine öğrenmesi algoritmaları, dalga enerjisi tahmininde kullanılmak üzere geliştirilmiştir. Bu algoritmalar, dalga yüksekliği ve periyodunu tahmin ederek, dalga enerjisinin düzensiz karakteristiğini düzenlemeye yardımcı olmaktadır. Dalga yüksekliği ve periyodu tahminleri, hem kısa vadeli enerji üretimi düzenlemeleri hem de uzun vadeli enerji üretim potansiyelinin belirlenmesi açısından büyük bir önem taşımaktadır.


Bu tezde, dalga enerjisi tahmini için makine öğrenmesi tabanlı bir hibrit model geliştirilmiştir. Çalışma kapsamında, Karadeniz'deki Samsun ve Ordu illerinin açıklarında yer alan deniz şamandıralarına ait 2023 yılına ait 1 yıllık veri seti kullanılmıştır. Bu veri setinde, dalga yüksekliği, dalga periyodu, rüzgar hızı, deniz suyu sıcaklığı gibi çeşitli parametreler yer almaktadır. Dalga gücünün tahmin edilmesi için, dalga boyunun karesi ve dalga periyodu ile doğru orantılı olan dalga gücü hesaplanmıştır. Çalışma, dalga enerjisi tahmininde kullanılan makine öğrenmesi algoritmalarının performansını incelemeyi amaçlamaktadır. Bu amaçla, LSTM (Long Short-Term Memory), ELM (Extreme Learning Machine), SVM (Support Vector Machine), ResNet (Residual Networks), Bayesian ve RNN (Recurrent Neural Networks) gibi temel regresyon modelleri geliştirilmiştir. Ardından, bu modellerin performansını artırmak amacıyla XGB (Extreme Gradient Boosting) algoritması ile bir yığınlama (stacking) yaklaşımı uygulanmıştır. Yığınlama yaklaşımı, farklı modellerin güçlü yönlerini birleştirerek zayıf yönlerini minimize etmeyi hedeflemektedir.

Bu tez çalışması, dalga enerjisi tahmininde makine öğrenmesi algoritmalarının etkinliğini test etmekte ve bu alanda yeni bir yaklaşım sunmaktadır. Dalga enerjisinin daha verimli ve sürdürülebilir bir şekilde kullanılabilmesi için yapılan bu çalışma, gelecekteki enerji dönüşüm sistemlerinin planlanmasında önemli bir katkı sağlamaktadır. Ayrıca, dalga enerjisinin ticari ölçekte kullanılabilirliğini artırmak ve bu alandaki teknolojilerin gelişimine katkı sağlamak adına yeni bir çerçeve sunmaktadır.

2. ENERJİ


Enerji, modern yaşamın sürdürülebilirliği için hayati bir kaynaktır. Enerji kaynakları kullanım çeşitlerine ve dönüştürülebilme kapasitelerine bağlı olarak farklı şekillerde sınıflandırılmaktadır. Kullanım çeşitlerine göre enerji kaynakları, *yenilenemeyen* (tükenebilir) ve *yenilenebilir* enerji (tükenmez) kaynakları olarak ikiye ayrılmaktadır. Yenilenebilir enerji kaynakları, kullanıldıklarında tükenmeyen, doğada kendini sürekli yenileyebilen enerji kaynaklarıdır. Bu kaynaklar, çevre dostu olmaları ve sürdürülebilir enerji üretimi sağlamaları nedeniyle günümüzde giderek daha fazla önem kazanmaktadır. Güneş, rüzgâr, biyokütle, hidrolik, jeotermal, dalga ve hidrojen enerjisi yenilenebilir enerji kaynakları arasında yer alır. Yenilenemeyen enerji kaynakları, enerji sağlama sürecinde yapılarında kimyasal değişimler meydana geldiği için geri dönüşümü mümkün olmayan enerji kaynaklarıdır. Yenilenemeyen enerji kaynakları iki ana gruba ayrılır. Bunlar, doğal gaz, petrol ve kömür gibi fosil esaslı enerji kaynakları ve uranyum ve toryum gibi nükleer enerji üretiminde kullanılan çekirdek kaynaklı enerji kaynaklarıdır. Enerji kaynaklarının bu genel sınıflandırması, farklı enerji türlerinin avantajlarını ve dezavantajlarını anlamak için önemli bir çerçeve sunmaktadır (Koç & Şenel, 2013).

Enerji kaynakları, dönüştürülme kapasitelerine göre birincil ve ikincil enerji kaynakları olarak da sınıflandırılmaktadır: Birincil enerji kaynakları, doğrudan kullanıma uygun olan ve başka bir enerji türüne dönüştürülmeden kullanılabilen kaynaklardır. Doğal gaz, petrol, kömür, nükleer enerji, güneş, rüzgar ve dalga enerjisi birincil enerji kaynaklarına örnek olarak verilebilir. İkincil enerji kaynakları, doğrudan kullanılamayan, birincil enerji kaynaklarının dönüşümü sonucunda elde edilen enerji türleridir. Elektrik, dizel, benzin, sıvılaştırılmış petrol gazı (LPG), hava gazı ve kok kömürü gibi enerji türleri ikincil enerji kaynakları arasında yer alır (Panwar vd., 2011). Bu ayrım, enerji üretim ve tüketim süreçlerinin daha iyi analiz edilmesine ve enerji sistemlerinin verimliliğinin artırılmasına olanak tanır. Enerji kaynaklarının sınıflandırılması, Şekil 2.1’de görsel olarak sunulmaktadır.



Şekil 2.1 Enerji kaynaklarının sınıflandırılması


Enerji kaynaklarının kullanımı, ülkelerin ekonomik ve çevresel hedeflerine bağlı olarak değişiklik göstermektedir. BP verilerine göre hazırlanan grafikler, Türkiye ve dünya genelinde enerji kaynaklarının kullanım oranlarını karşılaştırmaktadır (Şekil 2.2). 2018 verilerine göre Türkiye’de enerji kullanımı, hidroelektrik ve diğer yenilenebilir enerji kaynaklarının toplam enerji kaynakları içindeki payı %14’tür. Bu oran, Türkiye’nin yenilenebilir enerjiye verdiği önemin artmakta olduğunu göstermektedir. Ancak, fosil yakıtların yüksek oranlarda kullanımı, CO₂ emisyonlarını artırmakta ve enerji arzında dışa bağımlılığa yol açmaktadır. Dünyada enerji kullanımı, yenilenebilir enerji kaynaklarının kullanım oranı dünya genelinde artış göstermektedir. Türkiye’nin hidroelektrik ve yenilenebilir enerji kaynakları açısından dünya ile benzer bir orana sahip olduğu görülmektedir. Şekil 2.2’de Türkiye ve dünya genelinde enerji kaynaklarının kullanım oranları detaylı olarak sunulmaktadır. Bu karşılaştırma, Türkiye’nin enerji kaynaklarını çeşitlendirme ve yenilenebilir enerjiye geçiş sürecini hızlandırma gerekliliğini açıkça ortaya koymaktadır.



Şekil 2.2 Enerji (a) Türkiye’de enerji kaynaklarının kullanım oranları; (b) Dünya’da enerji kaynaklarının kullanım oranları (Koç ve Şenel, 2013)

2.1 Yenilebilir Enerji Kaynakları

Yenilenebilir enerji kaynakları, doğada belli bir süre içinde kendini yenileyebilen, tükenmeyen ve temiz enerji kaynaklarıdır. Bu kaynaklar, tüketim hızlarından daha hızlı bir şekilde yenilenebilir oldukları için sürdürülebilir enerji üretimi sağlar. Yenilenebilir enerji kaynakları, erişilebilirlik, kullanılabilirlik ve çevresel uyum açısından birçok avantaj sunmaktadır. Yenilenebilir enerji kaynaklarının en önemli özelliklerinden biri, enerjide dışa bağımlılığı azaltarak enerji güvenliğini artırmasıdır. Aynı zamanda, karbondioksit salınımını önemli ölçüde azaltarak çevrenin korunmasına katkı sağlar. Bu kaynakların yerli olması, ekonomik bağımsızlık ve istihdam artışı açısından da büyük bir avantaj sunmaktadır. Yenilenebilir enerji projeleri, kamuoyundan yaygın destek görmekte ve çevresel sürdürülebilirlik hedeflerine ulaşmada kritik bir rol oynamaktadır (Deshmukh vd., 2023). Uluslararası Enerji Ajansı (IEA), yenilenebilir enerji kaynaklarını, karbondioksit emisyonlarını azaltarak daha sürdürülebilir bir enerji sistemine geçişin temel unsuru olarak tanımlamaktadır. Bu bağlamda, güneş, rüzgar, hidrolik, jeotermal, biyokütle, dalga ve hidrojen enerjisi, yenilenebilir enerji kaynakları arasında yer almaktadır. Yenilenebilir enerji kaynakları hem çevresel hem de ekonomik açıdan büyük bir potansiyele sahiptir. Bu kaynaklar, enerji üretim süreçlerinde çevreye zarar vermemeleri ve sürekli bir enerji kaynağı sunmaları nedeniyle giderek daha fazla tercih edilmektedir. Şekil 2.3’te yenilenebilir enerji türleri ve bu enerji türlerinin elde edilmesi için gereken olgular görsel olarak sunulmaktadır.




Şekil 2.3 Yenilebilir enerji türleri ve kaynakları

2.1.1 Güneş enerjisi

Güneş enerjisi, güneşin içindeki hidrojen atomlarının birleşerek helyuma dönüşmesi sırasında açığa çıkan enerjidir. Bu enerji, dünyaya iletilen en güçlü ve sürdürülebilir enerji kaynaklarından biridir. Dünyaya ulaşan güneş enerjisi miktarı, insanlığın bir yılda kullandığı toplam enerji miktarının yaklaşık 20 bin katına eşittir. Bu muazzam potansiyel, güneş enerjisini yenilenebilir enerji kaynakları arasında ön plana çıkarmaktadır. Güneş enerjisi teknolojileri, fotovoltaik güneş teknolojisi ve termal güneş teknolojisi olmak üzere iki temel sınıfa ayrılmaktadır (ETKB, 2020). Fotovoltaik sistemler, güneş ışığını doğrudan elektrik enerjisine dönüştürürken; termal sistemler, güneş enerjisini ısı enerjisine dönüştürerek çeşitli uygulamalarda kullanılmasını sağlar. Bu teknolojiler, bol ve temiz enerji üretimi sağlamaları, çevre dostu olmaları, finansal uygulanabilirlikleri ve enerji bağımlılığını azaltma potansiyelleri nedeniyle giderek yaygınlaşmaktadır. Ayrıca, güneş enerjisi projeleri istihdam yaratma özelliği ile ekonomik büyümeye de katkı sağlamaktadır.

Türkiye, jeopolitik konumu itibarıyla güneş enerjisi potansiyeli bakımından avantajlı ülkeler arasında yer almaktadır. Özellikle Güneydoğu Anadolu Bölgesi ve Akdeniz kıyılarında güneş ışığına erişim süresi oldukça yüksektir. Bu bölgelerde yıllık güneşlenme süresi ve güneş enerjisi yoğunluğu, güneş enerjisi sistemlerinin kurulumu için elverişli bir zemin oluşturmaktadır. Güneş enerjisi, Türkiye'nin yenilenebilir enerji üretimindeki önemli bir kaynağı haline gelmiş ve bu alanda son yıllarda hızlı bir gelişim kaydedilmiştir. Türkiye'de kurulu güneş enerjisi sistemlerinin yıllara göre kurulu güç değerleri, Şekil 2.4'te görsel olarak sunulmaktadır.



Şekil 2.4 Türkiye’de kurulu güneş enerji gücü (Enerji ve Tabi Kaynaklar Bakanlığı, 2022)


2.1.2 Rüzgar enerjisi

Rüzgar enerjisi, güneşin yeryüzünü ve atmosferi ısıtması sonucu oluşan sıcaklık ve basınç farklarından kaynaklanan hava akımlarından elde edilen bir enerji türüdür. Güneşin yeryüzüne gönderdiği toplam enerjinin yalnızca %1-2'si rüzgar enerjisine dönüşmektedir (ETKB, 2020). Rüzgar, atmosfer ile dünya yüzeyi arasında hava kütlelerinin yer değiştirmesi ile oluşur ve bu hareket, enerji üretimi için kullanılabilir hale getirilebilir.

Rüzgar enerjisi, bol, temiz ve çevre dostu bir enerji kaynağıdır. Erişilebilirliği yüksek olan bu kaynak, finansal olarak uygulanabilir projelere olanak tanırken, aynı zamanda istihdam yaratma ve enerji bağımlılığını azaltma gibi önemli avantajlar sunar. Güneş enerjisi kadar değerli bir yenilenebilir enerji kaynağı olan rüzgar enerjisi, arz güvenliğini artırarak sürdürülebilir enerji politikalarının temel bileşenlerinden biri haline gelmiştir.

Türkiye, rüzgar enerjisi potansiyeli açısından oldukça avantajlı bir konuma sahiptir. Özellikle Ege, Marmara ve Akdeniz bölgelerinde meydana gelen güçlü rüzgarlar, yenilenebilir enerji üretimi için önemli bir kaynak oluşturmaktadır. Bu bölgelerdeki rüzgar hızlarının ve sürekliliğinin yüksek olması, enerji üretimi için rüzgar türbinlerinin verimli bir şekilde kullanılmasını mümkün kılmaktadır. Rüzgar enerjisi, Türkiye'nin yenilenebilir enerji portföyünün önemli bir parçası haline gelmiş ve bu alanda büyük yatırımlar yapılmıştır. Son yıllarda Türkiye’de kurulu rüzgar enerji sistemlerinin

kapasitesi hızla artmıştır. Bu artış hem enerji üretiminde çeşitliliği sağlamakta hem de karbon salınımını azaltarak çevre korumasına katkıda bulunmaktadır. Türkiye’de yıllara göre kurulu rüzgar enerji sistemlerinin toplam güç değerleri, Şekil 2.5’te görsel olarak sunulmaktadır.



Şekil 2.5 Türkiye’de kurulu rüzgar enerji sistemlerinin yıllara göre toplam gücü (Enerji ve Tabi Kaynaklar Bakanlığı, 2022)


2.1.3 Jeotermal enerji

Jeotermal enerji, dünyanın merkezindeki ısının sıcak bölgeleri takip ederek yeryüzüne doğru yayılmasıyla oluşan bir enerji türüdür (ETKB, 2020). Bu enerji, yer kabuğunun derinliklerinde bulunan ısının, yenilenebilir ve çevre dostu bir kaynak olarak yeryüzüne taşınmasıyla elde edilir. Jeotermal enerjinin temel kaynağı, dünyanın iç kısmında meydana gelen doğal radyoaktif bozunma süreçleri ve yer kabuğundaki sıcaklık farklarıdır. Sıcak su, buhar ve kayalar gibi yeraltı kaynakları, jeotermal enerjinin başlıca bileşenleridir.

Jeotermal enerji, yenilenebilir enerji kaynakları arasında önemli bir yere sahiptir. Güneş ve rüzgar enerjisinin avantajlarının yanı sıra hava koşullarından etkilenmemesi, bu enerji türünü daha da cazip hale getirmektedir (H. Kulasekara & V. Seynulaabdeen, 2019).

Türkiye, jeotermal enerji kaynakları bakımından dünya genelinde önemli bir konuma sahiptir. Özellikle Ege Bölgesi, İç Anadolu Bölgesi ve Doğu Anadolu Bölgesi, yüksek miktarda jeotermal kaynak potansiyeline sahiptir. Türkiye’de jeotermal enerji, elektrik

üretimi, ısıtma ve seracılık gibi çeşitli alanlarda kullanılmaktadır. Termal santraller aracılığıyla elektrik üretimi yapılabildiği gibi, jeotermal enerji doğrudan ısıtma amacıyla da kullanılabilir. Son yıllarda, Türkiye’de kurulu jeotermal enerji sistemlerinin kapasitesi hızla artmıştır. Bu artış hem enerji üretiminde çeşitliliği sağlamış hem de karbon salınımını azaltarak çevre korumasına katkıda bulunmuştur. Türkiye’deki yıllara göre kurulu jeotermal enerji sistemlerinin toplam güç değerleri, Şekil 2.6’da görsel olarak sunulmaktadır.



Şekil 2.6 Türkiye’de jeotermal enerji sistemlerinin toplam kurulu gücünün yıllara göre değeri (Enerji ve Tabi Kaynaklar Bakanlığı, 2022)

2.1.4 Hidroelektrik enerji


Hidroelektrik enerji, suyun sahip olduğu potansiyel enerjinin mekanik enerjiye ve ardından elektrik enerjisine dönüştürülmesiyle elde edilen bir enerji türüdür. Hidroelektrik santrallerde (HES), suyun akışından elde edilen enerji, türbinlerde mekanik enerjiye dönüştürülür ve bu mekanik enerji jeneratörler aracılığıyla elektrik enerjisine çevrilir. Üretilen elektrik enerjisi, suyun miktarı, debisi ve yüksekliği gibi parametrelere bağlı olarak değişiklik göstermektedir. Hidroelektrik enerji, suyun sahip olduğu potansiyelin etkin bir şekilde kullanılmasıyla elde edilen temiz ve çevre dostu bir enerji kaynağıdır.

Hidroelektrik santraller genellikle engebeli ve dağlık arazilere kurulur. Bunun temel nedeni, suyun yüksekten akmasıyla daha fazla potansiyel enerji elde edilmesidir.

Hidroelektrik enerji, güneş ve rüzgar enerjisi gibi yenilenebilir enerji kaynakları arasında önemli bir yere sahiptir. Çevre dostu olması, teknik ömrünün uzunluğu, yerli bir kaynak olması, enerji bağımlılığını azaltması, arz güvenliğini artırması ve istihdam yaratıcı özelliği, hidroelektrik enerjiyi sürdürülebilir enerji politikalarının vazgeçilmez bir unsuru haline getirmektedir.

Türkiye, hidroelektrik enerji potansiyeli açısından dünya genelinde avantajlı ülkelerden biridir. Coğrafi yapısı, dağlık alanları ve zengin akarsu kaynakları, hidroelektrik enerji üretimi için elverişli bir ortam sunmaktadır. Türkiye'de birçok baraj ve hidroelektrik santrali bulunmaktadır. Bu santraller, akarsular üzerine inşa edilen barajlar aracılığıyla suyu depolar ve potansiyel enerjiyi elektrik enerjisine dönüştürür. Türkiye'nin elektrik üretiminin önemli bir kısmı hidroelektrik santrallerden sağlanmaktadır.

Son yıllarda, Türkiye'de hidroelektrik enerji sistemlerinin kurulu gücü hızla artmıştır. Bu artış, ülkenin enerji üretiminde çeşitlilik sağlamış ve fosil yakıt kullanımını azaltarak çevre korumasına katkıda bulunmuştur. Türkiye'de yıllara göre hidroelektrik enerji sistemlerinin toplam kurulu güç değerleri, Şekil 2.7'de görsel olarak sunulmaktadır.



Şekil 2.7 Türkiye'de hidroelektrik enerji sistemlerinin toplam kurulu gücünün yıllara göre değeri (Enerji ve Tabii Kaynaklar Bakanlığı, 2022)

2.1.5 Biyokütle enerji

Biyokütle, fotosentez yoluyla güneş enerjisini depolayan bitkisel ve organik organizmalardan elde edilen bir enerji kaynağıdır. Fotosentez gerçekleştiren bitkiler ve diğer canlı organizmaların ürettikleri enerji, biyokütle enerjisi olarak tanımlanmaktadır (ETKB, 2020). Biyokütle enerjisi, organik atıklar, bitki ve hayvan atıkları, orman ürünleri, kentsel ve endüstriyel atıklar gibi çeşitli biyolojik kaynaklardan elde edilmektedir. Bu kaynaklar, biyodizel, biyoetanol ve biyogaz gibi üç önemli yakıt türünün üretiminde kullanılmaktadır.


Biyokütle enerjisi, canlı organizmalardan elde edilen kimyasal ve/veya fiziksel işlemler sonucunda üretilmektedir. Diğer yenilenebilir enerji kaynaklarına kıyasla (örneğin rüzgar ve güneş enerjisi), biyokütle enerjisinin en büyük avantajı, üretimin meteorolojik koşullara bağımlı olmamasıdır. Biyokütle malzemesi mevcut olduğu sürece enerji üretimi kesintisiz olarak devam edebilir. Ayrıca, biyokütle oluşumu sırasında atmosfere CO_2 alınır ve enerji üretimi sırasında bu CO_2 tekrar atmosfere salındığından, biyokütle enerjisi karbon nötr bir enerji kaynağı olarak kabul edilmektedir. Bu durum, biyokütle enerjisini çevre dostu bir seçenek haline getirmektedir.

Türkiye, biyokütle enerjisi üretimi için geniş bir kaynak yelpazesine sahiptir. Bu kaynaklar arasında tarımsal atıklar (örneğin saman artıkları, mısır sapı, hayvan gübresi), orman atıkları, endüstriyel atıklar ve kentsel biyolojik atıklar bulunmaktadır. Türkiye’de biyokütle enerjisi genellikle iki ana yöntemle üretilmektedir:

Biyogaz tesisleri: Organik atıkların fermantasyonu yoluyla biyogaz üretimi yapılmaktadır. Bu süreç, özellikle tarımsal ve hayvansal atıkların değerlendirilmesinde önemli bir rol oynar.

Biyokütle yakma tesisleri: Biyokütle malzemesi doğrudan yakılarak ısı veya elektrik enerjisi üretilmektedir. Bu yöntem, özellikle orman ve endüstriyel atıkların değerlendirilmesinde kullanılır.

Son yıllarda Türkiye’de biyokütle enerji sistemlerinin kurulu gücü hızla artmıştır. Atık yönetimi, tarım ve ormancılık sektörlerinden elde edilen biyolojik atıkların enerji üretiminde kullanılması, Türkiye’nin yenilenebilir enerji hedeflerine ulaşmasına katkıda bulunmaktadır. Türkiye’de biyokütle enerji sistemlerinin yıllara göre kurulu güç değerleri, Şekil 2.8’de görsel olarak sunulmaktadır.



Şekil 2.8 Türkiye’de biyokütle enerji sistemlerinin toplam kurulu gücünün yıllara göre değeri (Enerji ve Tabi Kaynaklar Bakanlığı, 2022)

2.1.6 Dalga enerjisi

Dalga enerjisi, okyanus, deniz veya göllerdeki dalgalardan elde edilen enerji türüdür. Bu enerji genellikle dalga hareketinden, denizdeki gelgitlerden veya rüzgarın su yüzeyine etkisiyle oluşan dalgacıklardan kaynaklanır. Dalga enerjisi, suyun hareket enerjisini kullanarak elektrik enerjisi üretmek için çeşitli teknolojiler kullanır. Çevresel etkileri genellikle diğer enerji kaynaklarına göre daha azdır. Bununla birlikte, dalga enerjisinin ticari ölçekte kullanılabilirliği hala geliştirme aşamasındadır ve maliyet etkinliği ve çevresel etkiler gibi birçok faktörü dikkate almak gerekir.

2.1.7 Hidrojen enerjisi

Hidrojen, doğada tek başına element formunda bulunmasa da farklı elementlerle birleşerek moleküler yapılar oluşturur. Su, hidrojenin doğadaki en yaygın örneklerinden biridir. Ancak, hidrojenin enerji kaynağı olarak kullanılabilmesi için bazı işlemlerden geçirilmesi ve dönüştürülmesi gerekmektedir. Hidrojen, yenilenebilir enerji kaynakları arasında depolanabilir ve verimli bir enerji taşıyıcısı olarak dikkat çekmektedir. Enerji ve Tabii Kaynaklar Bakanlığı hidrojenin enerji olarak kullanılmasının en önemli avantajlarından birinin, petrol yakıtlarına göre yaklaşık %33 daha verimli olması ve kolayca depolanabilmesi olduğunu belirtmektedir (ETKB, 2020). Ayrıca, su moleküllerinden üretilmesi sayesinde bol miktarda bulunabilen bir enerji kaynağıdır.

Hidrojen enerjisi, yenilenebilir enerji sistemleri ile entegre çalışabilmesi ve karbon salınımını sıfıra indirme potansiyeli ile çevre dostu bir alternatif sunmaktadır. Yenilenebilir enerji kaynaklarının elektrik üretimindeki düzensizliği, hidrojenin depolama özelliği ile dengelenebilir. Bu özellik, hidrojenin hem enerji güvenliği hem de sürdürülebilirlik açısından stratejik bir kaynak olmasını sağlamaktadır.

Artan enerji talebi, yenilenebilir enerji kaynaklarının önemini her geçen gün artırmaktadır. Yenilenemeyen enerji kaynaklarının tükenmesi, çevre kirliliği ve sürdürülebilirlik ihtiyacı, yenilenebilir enerji kaynaklarına geçişi zorunlu hale getirmiştir (Akyüz & Elcıl, 2023). Hidrojen, bu geçişte kilit bir rol oynayabilecek enerji taşıyıcılarından biridir. Özellikle güneş ve rüzgar enerjisinden elde edilen elektriğin, elektroliz yöntemiyle hidrojen üretiminde kullanılması, yenilenebilir enerji kaynaklarının etkinliğini artırmaktadır.

Türkiye, enerji talebindeki artış ve yenilenebilir enerjiye olan bağımlılığını azaltma ihtiyacı nedeniyle hidrojen enerjisine yönelik yatırımları artırmaktadır. Ülkenin mevcut enerji yapısı büyük ölçüde yabancı kaynaklara bağımlıdır ve yenilenebilir enerji kaynaklarına geçiş bir zorunluluk haline gelmiştir (Dilaveroğlu, 2023). Türkiye'nin hidrojen enerjisi potansiyelinin değerlendirilmesi, enerji arz güvenliğini sağlamada ve karbon emisyonlarını azaltmada önemli bir adım olacaktır.

Hidrojen enerjisi, yalnızca enerji üretiminde değil, aynı zamanda ulaşım, sanayi ve ısıtma gibi farklı sektörlerde de kullanılabilecek çok yönlü bir enerji kaynağıdır. Türkiye'nin bu alanda yapacağı yatırımlar hem enerji güvenliği hem de ekonomik sürdürülebilirlik açısından büyük bir katkı sağlayacaktır.

3. DALGA ENERJİSİ

Yenilenemez enerji kaynaklarından yenilenebilir enerji sistemlerine geçiş, küresel ısınma, çevre kirliliği ve doğal kaynakların tükenmesi gibi dünya çapında karşılaşılan sorunların çözümünde kritik bir adımdır (Edenhofer vd., 2011). Bu bağlamda, dalga enerjisi, çevresel etkileri minimum düzeyde olan ve potansiyeli oldukça yüksek bir yenilenebilir enerji kaynağı olarak dikkat çekmektedir. Dalga enerjisi teknolojisinin temel işlevi, rüzgar etkisiyle oluşan okyanus dalgalarının mekanik enerjisini elektrik enerjisine dönüştürmektir. Dalga enerjisi, güneş ve rüzgar enerjisine kıyasla şebekeye daha öngörülebilir bir şekilde elektrik sağlayabilme avantajına sahiptir (Reikard vd., 2015). Ayrıca, su ürünleri yetiştiriciliği, okyanus araştırmaları ve açık deniz operasyonlarına güç sağlama gibi şebekeden bağımsız uygulamalar için de ideal bir enerji kaynağıdır.

Dalga enerjisi, dünya yüzeyinin yaklaşık %70'ini kaplayan okyanuslardan gelen enerji potansiyelini kullanır. Bu geniş enerji kaynağı, hidrolik ve biyokütle enerjilerinden daha fazla, ancak rüzgar enerjisinden biraz daha düşük bir enerji kapasitesine sahiptir (Özdamar, 2000; Özkop, 2012). Dalga enerjisinin çevresel etkileri ise oldukça sınırlıdır ve uygun araştırma ve geliştirme çalışmalarıyla daha da azaltılabilir (Langhamer vd., 2010). Bununla birlikte, dalga enerjisinin ticari ölçekte kullanımı hala geliştirme aşamasındadır. Teknolojik ilerlemeler ve maliyetlerin düşürülmesi, bu kaynağın daha yaygın bir şekilde kullanılmasını sağlayacaktır.

Dalga enerjisi sistemleri, farklı yöntemler kullanarak dalga hareketlerini elektrik enerjisine dönüştürür. Bu sistemlerden bazıları:

Salınlımlı su sütunları: Dalga hareketiyle sıkışan hava ceplerinin türbinleri çalıştırdığı sistemler.

Salınlımlı gövde dönüştürücüleri: İki cihaz gövdesi arasındaki bağıl hareketten enerji elde eden cihazlar.

Üst üste binen dönüştürücüler: Dalga hareketiyle suyu yüksek bir seviyeye taşıyan ve bu potansiyel enerjiyi elektrik enerjisine dönüştüren sistemlerdir.

Bu sistemler, deniz tabanına sabitlenebileceği gibi, yüzer platformlar şeklinde de tasarlanabilir. Sistemlerin tasarımı, dalga enerjisini absorbe etme yöntemlerine ve dönüştürdükleri dalga hareketi türüne göre farklılık gösterir. Dalga enerjisi

dönüştürücüleri (DED), dalga hareketinin kabarma, dalgalanma veya yerçekimi potansiyeli gibi türlerini kullanarak enerji üretir.

Günümüzde, dalga enerjisi dönüştürücüleri yapılarına göre 4 ile 8 farklı kategoriye ayrılmaktadır ve her kategoride çok sayıda cihaz tasarımı bulunmaktadır (Babarit, 2015). Örneğin, salınlı gövde cihazları, dalgalarla tetiklenen bağıl hareketten faydalanırken, salınlı su sütunu cihazları su sütununun hareketiyle indüklenen hava akışını kullanır. Şebeke ölçeğinde enerji üretimi için cihaz dizileri oluşturulması planlanmaktadır. Ancak bu cihazların tasarımı, kurulum maliyetleri ve çevresel etkileri gibi faktörler nedeniyle çeşitli zorluklar içermektedir (Ruehl & Bull, 2012).

Dalga enerjisi teknolojisi, birçok farklı bilimsel ve mühendislik alanında araştırma ve geliştirme çalışmalarını gerektirir. Bu alanlar arasında hidrodinamik, malzeme bilimi, kontrol sistemleri, demirleme teknolojileri, okyanusta kurulum ve enerji taşınması gibi konular yer almaktadır. Bu teknolojilerin henüz erken bir gelişim aşamasında olması, tasarım sürecini karmaşık hale getirmektedir. Dalga enerjisi dönüşüm sistemlerinin tasarımı ve kurulumu, doğal şartların karmaşıklığı ve çok değişkenli yapılar nedeniyle zorlu bir süreçtir.

Dalga enerjisi sistemlerinin verimli bir şekilde çalışabilmesi için, kurulacağı bölgede uzun süreli ölçümlerin yapılması gerekmektedir. Dalga periyodu, dalga yüksekliği, su sıcaklığı gibi parametrelerin doğru bir şekilde ölçülmesi, enerji üretimi açısından kritik öneme sahiptir. Teorik hesaplamalarda, dalga enerjisinden alınabilecek maksimum güç, dalga frekansı ile sistemin doğal frekansının eşleştiği rezonans durumuna dayanır. Ancak doğal koşullarda bu rezonans her zaman gerçekleşmez. Bu nedenle, tahmini güç genellikle maksimum gücün bir katsayısı olarak hesaplanır.

Dalga enerjisi, yenilenebilir enerji kaynakları arasında geniş bir potansiyele sahiptir. Okyanusların dünya yüzeyindeki büyük payı ve bu alanların enerji üretimi için kullanılabilirliği, dalga enerjisini geleceğin enerji sistemlerinde önemli bir yere taşımaktadır. Elektrik üretimi için kullanılan dalga enerjisi sistemleri, karbon salınımını azaltarak çevresel sürdürülebilirliğe katkıda bulunur. Ayrıca, kıyı bölgelerinde yaşayan dünya nüfusunun yaklaşık %50'sine enerji sağlama potansiyeli ile dalga enerjisi, enerji güvenliğini artırmak için stratejik bir çözüm sunmaktadır.

Sonuç olarak, dalga enerjisi, gelecekte enerji arzında çeşitlilik sağlamak ve fosil yakıtlara olan bağımlılığı azaltmak için önemli bir yenilenebilir enerji kaynağıdır. Teknolojik

gelişmeler, maliyetlerin düşürülmesi ve uluslararası iş birlikleri, dalga enerjisi sistemlerinin ticari ölçekte uygulanabilirliğini artıracaktır.

3.1 Dünya’da Dalga Enerjisi

Dalga enerjisi, dünya genelinde büyük bir yenilenebilir enerji potansiyeline sahiptir. Okyanusların geniş alanları ve sürekli dalga hareketleri, bu kaynağın etkin bir şekilde kullanılabilmesi için uygun bir ortam sunmaktadır. Dünya üzerinde dalga enerjisi açısından en zengin bölgeler, genellikle Kuzey ve Güney yarım kürelerin 40°-60° enlemleri arasında yer alan alanlardır. Ancak, en yüksek yıllık ortalama dalga enerjisi potansiyeline sahip bölge, Güney yarım küredeki 40°-60° enlemleri arasındadır (López vd., 2013). Bu bölgelerdeki yüksek dalga enerjisi potansiyeli, okyanusların rüzgarla sürekli etkileşimi ve bu bölgelerdeki deniz koşullarının stabilitesi ile ilişkilidir.

Dalga enerjisi açısından zengin bazı bölgelerin sahip olduğu net dalga gücü, 5 kW/m’den küçük olan alanlar ve buzullarla kaplı bölgeler hariç tutulduğunda, Tablo 3.1’de özetlenmiştir verilmektedir (Mork vd., 2010).

Bazı ülkelere ait dalga güçleri; İrlanda 21GW, Portekiz 10GW, Danimarka 3,4 GW, İsveç 1GW, İngiltere 120 GW ve Akdeniz tarafında Fransa, İtalya, İspanya ve Yunanistan’ın toplam dalga gücü 30 GW olarak hesaplanmaktadır (Vicinanza vd., 2013). Bu değerler, dalga enerjisinin belirli bölgelerdeki yüksek potansiyelini ve bu kaynağın yenilenebilir enerji sistemlerine entegre edilmesi için sahip olduğu fırsatları göstermektedir.

Tablo 3.1 Dalga enerjisi açısından zengin bazı bölgelerin sahip olduğu net dalga gücü (Teixeira-Duarte vd., 2022)

Bölge	Pnet (GW)
Avustralya ve Yeni Zelanda	574
Güney Amerika’nın batısı	324
Avrupa’nın kuzeyi ve batısı	286
Asya’nın güney doğusu ve Malezya	283
Kuzey Amerika’nın batısı	207
Güney Amerika’nın doğusu	202

3.2 Türkiye’de Dalga Enerjisi

Türkiye, okyanuslara kıyısı olmamasına ve batı sahil şeridinin sınırlı olmasına rağmen, sahip olduğu denizler ve rüzgar rejimleri sayesinde önemli bir dalga enerjisi potansiyeline sahiptir. Özellikle Karadeniz havzası, dalga yükseklikleri açısından okyanus sahalarına

benzer enerjik bir rejime sahiptir. Bu durum, güçlü rüzgar modellerinin etkisiyle dalga enerjisi açısından gelişim için iyi bir potansiyel sunmaktadır (E. Rusu, 2009).

Türkiye'nin denizlerden elde edebileceği yenilenebilir enerji türleri arasında dalga enerjisi, deniz sıcaklık gradyanı enerjisi ve deniz akıntı enerjisi yer almaktadır. Ancak, Akdeniz, Ege, Marmara ve Karadeniz'de okyanuslardaki gibi gelgit olayları olmadığı için gelgit enerjisi kullanımı mümkün değildir. Ayrıca, İstanbul ve Çanakkale Boğazlarındaki kuvvetli deniz akıntıları, bu bölgelerdeki yoğun deniz trafiği nedeniyle enerji üretimi açısından sınırlı bir potansiyele sahiptir.

Buna karşın, Türkiye'nin dalga enerjisi potansiyeli oldukça yüksektir. Dalga enerjisi yalnızca kıyı bölgeleri ile sınırlı kalmayıp, deniz açıklarında da uygun modellerle elektrik enerjisine dönüştürülebilmektedir. Türkiye'nin toplam kıyı uzunluğu Marmara Denizi hariç yaklaşık 8.200 km olup, bu durum Türkiye'yi dalga enerjisi potansiyeli açısından önemli bir konuma taşımaktadır.

Karadeniz'in Türkiye'yi çevreleyen diğer denizlere kıyasla daha dalgalı olduğu düşünülse de Ege ve Akdeniz bölgeleri de yüksek dalga potansiyeline sahiptir. Özellikle İzmir ve Antalya arasındaki güneybatı sahil şeridi, Dalaman'dan doğuda Finike'ye kadar uzanan bölge, rüzgar rejimi ve dalga potansiyeli açısından öne çıkmaktadır (Özhan & Abdalla, 2002; Sağlam vd., 2010). Türkiye'nin bölgesel dalga yoğunlukları Tablo 3.2'de sunulmaktadır.

Tablo 3.2 Türkiye'de bölgelere göre dalga yoğunlukları (Yesilyurt vd., 2017)

Bölge	Dalga Yoğunluğu
İzmir - Antalya	3,91 – 12,05 kWh/m
Ege Denizi	2,86 – 8,75 kWh/m
Akdeniz	2,59 – 8,26 kWh/m
Karadeniz	1,96 – 4,22 kWh/m
Marmara	0,31 – 0,69 kWh/m

Karadeniz özelinde yapılan çalışmalar, bu bölgedeki dalga enerjisi potansiyelini daha detaylı bir şekilde ortaya koymaktadır. Akpınar & Kömürcü, (2012) üçüncü nesil dalga modeli SWAN yaklaşımı kullanarak Karadeniz'in güneydoğu kıyısında toplam 7 çalışma noktasında dalga enerjisi potansiyelini incelemiştir. Bu çalışma, Hopa, Rize, Trabzon, Giresun, Ordu, Samsun ve Sinop bölgelerinin açık deniz lokasyonlarını kapsamaktadır. İlgili bölgelerdeki dalga enerji potansiyelleri ve ortalama dalga gücü değerleri Tablo 3.3'te detaylı olarak gösterilmiştir.

Tablo 3.3 Çalışma noktalarında dalga enerjisi potansiyeli ve ortalama dalga enerjisi
(Akpınar & Kömürcü, 2012)

Çalışma Noktası	(Hs) mean ±std (m)	(Hs) maks. (m)	Jmean (kW/m)	Jmaks (kW/m)	Yıllık Dalga Enerjisi (MWh/m)
Sinop	0,533 ±0,442	4,566	1,123	83,664	9,841
Samsun	0,399±0,316	4,295	0,524	73,333	4,592
Ordu	0,403±0,365	4,614	0,702	93,412	6,153
Giresun	0,384±0,348	4,619	0,629	97,638	5,518
Trabzon	0,414±0,372	4,186	0,689	72,031	6,036
Rize	0,383±0,358	4,249	0,646	77,755	5,665
Hopa	0,361±0,347	3,886	0,597	64,907	5,231

Dalga enerjisi potansiyeli değerlendirilirken üç temel kavram ön plana çıkmaktadır. Bunlar:

- Doğal Potansiyel: Doğada mevcut olan toplam enerji miktarını ifade eder.
- Teknik Potansiyel: Sahip olunan teknik bilgi ve altyapı ile doğal potansiyelden elde edilebilecek enerji miktarıdır.
- Ekonomik Potansiyel: Teknik potansiyelin, diğer enerji kaynakları ile kıyaslandığında ekonomik açıdan ne kadar verimli olduğunu belirler (Uygur vd., 2006).

Dalga enerjisi projelerinde ekonomik potansiyel, yatırımların fizibilitesi açısından en önemli kriterlerden biridir. Teknik potansiyelin yüksek olması, doğal enerji kaynaklarının kullanımını artırabilir; ancak ekonomik fizibilite sağlanamazsa bu potansiyelin kullanımı sınırlı kalacaktır.

Denizdeki dalgaların periyodu genellikle 3 ila 5 saniye arasında değişmektedir. Bu kısa zaman aralığında dalga enerjisinin verimli bir şekilde elektrik enerjisine dönüştürülebilmesi için uygun dalga enerjisi dönüştürücülerinin seçimi kritik bir öneme sahiptir. Enerji dönüşüm sistemlerinde, dalgaların periyodu, suyun kaldırma kuvveti ve yerçekimi gibi faktörler dikkate alınmalıdır. Aksi halde, faydalı enerji kaybı kaçınılmaz olacaktır.

Dalga enerjisinden elektrik üretimi için kullanılan türbinlerin nominal çalışma gücünün belirlenmesinde, ilgili lokasyondaki ortalama dalga gücü potansiyeli birincil rol oynar. Türbin seçimi, dalga enerjisi üretim maliyetini doğrudan etkiler:

- Nominal gücün ortalama dalga gücünden yüksek olması: Türbin maliyetlerini artırarak elektrik üretiminin birim maliyetini yükseltir.
- Nominal gücün ortalama dalga gücünden düşük olması: Dalga enerjisinden elde edilebilecek toplam enerji miktarını azaltır.

Bu nedenle, dalga türbinlerinin seçimi ve tasarımı, lokasyondaki dalga enerjisi potansiyelinin doğru bir şekilde analiz edilmesine dayalı olarak yapılmalıdır. Uzun süreli dalga ölçümleri (dalga periyodu, dalga yüksekliği, su sıcaklığı vb.) ve bu verilerin doğru değerlendirilmesi, dalga enerjisi sistemlerinin verimli bir şekilde çalışmasını sağlamak için kritik bir adımdır.

Sonuç olarak, Türkiye'nin sahip olduğu geniş kıyı şeridi ve deniz potansiyeli, dalga enerjisinin gelecekteki enerji politikalarında önemli bir yer tutabileceğini göstermektedir. Karadeniz, Ege ve Akdeniz bölgeleri, dalga enerjisi projelerinin uygulanabileceği stratejik alanlar olarak öne çıkmaktadır. Bu potansiyelin etkin bir şekilde değerlendirilmesi, enerji arz güvenliğini artıracak, dışa bağımlılığı azaltacak ve sürdürülebilir enerji hedeflerine katkıda bulunacaktır.

3.3 Dalga Enerjisinin Avantajları ve Dezavantajları

Dalga enerjisinin ve dalga dönüşüm sistemlerinin sosyal, ekonomik, çevresel vb. yönden birçok avantajı vardır.

- Dalga enerjisi temiz, doğal dengeyi koruyan, solunabilir temiz havayı sağlayan ve devamlı yinelenen doğal enerji kaynağıdır.
- Dalga hareketinin yinelenmesi (2-8s periyotlu), akarsular gibi yılda bir veya iki kez yinelenen kaynaklara göre uygulanacak enerji dönüşüm sistemleriyle daha uzun süreli enerji elde edilmesini sağlamaktadır.
- Her dalga yüksekliğinden istenilen enerjinin alınabilmesi önemli bir avantajdır.
- Enerji dönüşüm sistemleri denize bıraktığı fiziksel, kimyasal ve organik kirlenici etkisi olmaması nedeniyle çevre dostudurlar.
- Uygun dönüşüm sistemleri geliştirildiğinde büyük güce sahip dalgalardan önemli miktarlarda enerji elde edilebilmektedir.

- Adalar ve platformlar gibi açık deniz yapılarının elektrik ihtiyaçlarının kıyı bölgelerinden temin edilmesi güçlükleri karşısında bu yapılara yakın olarak tesis edilecek dalga enerjisi dönüşüm sistemleri ile enerji temini sağlanabilmektedir.
- Kıyıya yakın bölgelerde konuşlandırılan dönüşüm sistemleri daha yüksek verimle ve daha düşük maliyetle enerji üretebilmektedir.
- Birçok dalga enerji dönüşüm sistemi bu çalışmada seçilen sistem gibi enerji dönüşüm sistemi görevinin haricinde dalgakıran görevi üstlenerek dalga yüksekliklerinin azaltılmasında önemli rol oynar. Bunun sonucunda kıyı ve deniz yapılarının korunması imkanı sağlarlar.
- Dalgakıran özelliğiyle balık çiftlikleri, su altı balıkçılığı ve dalış gibi su altı sporları için uygun ortamlar yaratırlar.

Gerek dalgaların ve gerekse bu dalgalardan elde edilecek enerjinin üretiminde dezavantajlara sahiptir.

- Sistemlerin en verimli şekilde tasarlanabilmeleri ve dalga potansiyelinin belirlenebilmesi için dalga yüksekliği ve periyotlarına ve bunların yıllık ve daha uzun dönem istatistikî değerlerine ihtiyaç duyulmaktadır ve yüksek maliyet gerektiren çalışmalar yapılması gerekir.
- Dalga enerjisi dönüşüm sistemleri tasarlanırken konuşlandırılacakları yörenin rüzgâr ve dalga iklimine göre en verimli şekilde hesap yapılması gerekir.
- Dalga enerjisi dönüşüm sistemlerinde kullanılan türbinler, jeneratörler ve bağlantı elemanları açık deniz şartlarından (fırtına, büyük dalgalar) ve deniz suyunun kimyasal (korozyon, plankton vb.) etkilerinden olumsuz olarak etkilenirler. Bu yüzden deniz suyunun koroziyon etkilerine karşı sistemlerin özel olarak tasarlanarak korunmaları gerekir.
- Enerji dönüşüm sisteminden elde edilen enerjinin iletilmesi için ihtiyaç duyulacak enerji nakil hatlarının tesis edilmesi ve daha sonraki bakım maliyetleri yüksek olmaktadır.
- Açık denizden karaya döşenen enerji nakil hatlarının kayıpları çok fazla olmaktadır. Açık denizde üretilen enerjinin en verimli piller olan lityum-iyon pilleri ile depolanarak karaya nakli ise lityum-iyon pillerinin ilk yatırım maliyetleri, nakil bedelleri ve sınırlı pil ömrü nedeniyle ekonomik olamamaktadır.

- Dalgalardaki enerjinin elektrik enerjisine dönüşümünü için kullanılacak dalga türbinlerinin nominal güçlerinin belirlenmesinde, mevcut ortalama dalga güç potansiyeli birinci derecede rol oynamaktadır. Elektrik enerjisi üretiminde, mevcut ortalama dalga gücünden daha büyük nominal güce sahip dalga türbinlerinin kullanılması, türbin gücünün büyük bir kısmının atıl kalması sonucunu doğurmaktadır. Bunun sonucunda da birim dalga elektriğinin maliyeti artmaktadır.
- Bu sistemler hidrodinamik çevre üzerinde etkileri olacağından yer seçiminde dikkatli olunması gündeme gelmektedir.
- Kıyı şeridi ve kıyıya yakın bölgelerde sistemlerde kullanılan Wells türbinlerinden kaynaklanan gürültü kirliliği gündeme gelebilir, bu yüzden yapıların ses geçirmez özellikte tesis edilmesi ihtiyacı doğar.
- Deniz trafiğinde tehlike yaratabileceklerinden, uygun, görsel ve radar uyarı sistemleri konulması ihtiyacı doğar.
- Kıyı ve yakın kıyı bölgelerinde estetik açıdan olumsuzluk oluşturabilir.

3.4 Dalga Enerjisinin Hesabı

Dalga Enerjisi literatürde çeşitli tanımlar altında ifade edilebilmektedir. En basit hali ile enerji akısı fizikteki kavramlar cinsinden aşağıdaki gibi tanımlanabilir:

$$Enerji Akısı = \Phi = \frac{Güç}{Alan} = \frac{Enerji}{Alan.Zaman} \quad (3.1)$$

Olup enerji ise;

$$E = \frac{1}{8} \rho g H^2 \quad (3.2)$$

olarak tanımlanmaktadır (H : dalga yüksekliği, ρ : deniz suyunun özgül kütlesi, g : yerçekimi ivmesi). Sinüzoidal olmayan dalga durumunda ise dalga enerji spektrumundan bulunan anlamlı dalga yüksekliği kullanılmaktadır. Denklemin C_g dalga yayılma hızı ile çarpılması ile de birim boya karşı gelen güç bulunmuş olur.

$$P = \frac{1}{8} \rho g H^2 C_g \quad (3.3)$$

Açık deniz koşullarında dalga yayılma hızı ve dalga boyu aşağıdaki şekilde yazılabilmektedir:

$$C_g = \frac{c}{2}, \quad C = \frac{L}{T}, \quad L = \frac{gT^2}{2\pi} \quad (3.4)$$

Güç denklemi yeniden düzenlenecek olursa;

$$J(W/m) = \frac{1}{64} \rho g^2 H^2 T \quad (3.5)$$

burada $k = \frac{1}{64} \rho g^2$ olarak alınır;

$$J(W/m) = k H^2 T \quad (3.6)$$

ifadesi elde edilir. Elde edilen denklem göz önüne alındığı zaman dalga gücünün doğrudan dalga yüksekliğinin karesi ile doğru orantılı olduğu görülmektedir.

Sinüzoidal dalgalar için k katsayısı 976 W/s.m^3 olarak hesaplanmaktadır. Gerçek deniz koşullarındaki sinüzoidal olmayan dalga halinde, bu katsayı için literatürde farklı değerler verilmekle birlikte, genel olarak 300 ile 500 W/s.m^3 arasında olacağı belirtilmektedir. Literatürde yer alan bazı çalışmalarda Karadeniz için k değeri 486 W/s.m^3 olarak hesaplanmıştır (Akpınar & Kömürcü, 2012). Çalışmanın devamında dalga yüksekliği ve periyodu kullanılarak hesaplanan dalga gücü değerleri $k = 486 \text{ W/s.m}^3$ olarak hesaplanmıştır. Elde edilen güç denkleminde dalga gücünün dalga boyu yüksekliğinin karesi ile doğru orantılı olarak değişim gösterdiği gözlenmektedir. Dalga enerjisinden elektrik üretim aşamasında üretilecek elektrik enerjisinin de dolaylı olarak dalga boyu yüksekliği ile orantılı olacağı düşünülmektedir. Üretilecek elektrik enerjisi ile dalga boyu yüksekliği arasındaki korelasyon her alanda aynı şekilde gözlenir denilmesi hata olacaktır. Bunun için küçük boyutlu fizibilite çalışmaları ile ilgili bölgede üretilecek elektrik enerjisi ile dalga boyu yüksekliği arasındaki ilişki incelenmelidir. İlişki analizinin ardından belirli periyotlarla dalga enerjisi dönüşüm sistemine gelecek dalga boyu yüksekliklerinin tahmin edilmesi sayesinde, çokça değişkenlik gösterebilen dalga enerjisinden elektrik üretilerek depolama ihtiyacı duyulmadan şebekelere verilmesine olanak sağlayacağı düşünülmektedir.

3.5 Dalga Enerji Sistemlerinde Derin Öğrenme Algoritmalarının Kullanımı

Dalga enerjisi, doğrusal olmayan ve birçok parametreye bağlı olarak değişkenlik gösteren karmaşık bir enerji kaynağıdır. Dalga enerjisinden elde edilecek elektrik enerjisinin doğru bir şekilde tahmin edilmesi, enerji tedarik sisteminin güvenilirliği açısından büyük bir önem taşımaktadır. Bu bağlamda, yapay zeka tabanlı tahmin modelleri, geleneksel

istatistiksel analizler ve fiziksel modellere kıyasla daha yaygın bir şekilde uygulanmakta ve üstün performans göstermektedir.

Destek vektör makineleri, geri yayılım algoritmaları, bulanık mantık yöntemleri ve yapay sinir ağları (YSA) gibi yapay zeka tabanlı modeller, enerji tahmini başta olmak üzere birçok farklı alanda kullanılmaktadır. Bu yöntemlerin geliştirilmesiyle birlikte, doğrusal olmayan problemlerin çözümünde esneklik sağlayan derin sinir ağları (deep neural networks) ortaya çıkmıştır. Derin öğrenme modelleri, büyük veri kümelerini işleyebilme kapasiteleri sayesinde, karmaşık ve çok değişkenli problemlerin çözümünde başarılı sonuçlar elde etmektedir.

Dalga enerjisi tahmini için kullanılan yapay zeka modelleri, iki ana gruba ayrılabilir. Bunlar, hibrit olmayan modeller ve hibrit modellerdir.

Hibrit olmayan modeller tek bir algoritma kullanarak tahmin yaparken, hibrit modeller birden fazla algoritmanın güçlü yönlerini birleştirerek daha yüksek performans sağlamayı amaçlar (Aly, 2020; Hong & Rioflorido, 2019; Yang & Chen, 2019).

Son yıllarda derin öğrenme teknikleri dalga enerjisi tahmininde yoğun bir şekilde kullanılmaktadır. Bu modellerin başlıcaları şunlardır:

Konvolüsyonel Sinir Ağları (CNN): Görsel veri analizi için geliştirilmiş olsa da, dalga verilerindeki mekansal özellikleri analiz etmekte başarılıdır (Chen vd., 2021).

Tekrarlayan Sinir Ağları (RNN): Zaman serisi verilerinde sıklıkla kullanılır ve dalga enerjisi tahmininde etkili sonuçlar verir (Y.-L. Hu & Chen, 2018).

Uzun Kısa Süreli Hafıza (LSTM): Zaman serisi verilerindeki uzun vadeli bağımlılıkları öğrenme yeteneği sayesinde dalga enerjisi tahmininde yaygın olarak kullanılmaktadır (Y.-L. Hu & Chen, 2018).

Derin Kısa Ağlar (Deep Short Networks): Karmaşık verilerin daha kısa ve hızlı bir şekilde işlenmesini sağlar (Zhao vd., 2019).

Yığılmış Otomatik Kodlayıcılar (Stacked Autoencoders): Verilerin boyutunu azaltarak özellik çıkarımında kullanılır (Y. Wang vd., 2021).

Kapılı Tekrarlayan Akım Ağları (GRU): LSTM'ye benzer bir yapıya sahip olup, hesaplama açısından daha verimlidir (Ding vd., 2019).

Derin Hibrit Modeller: Birden fazla derin öğrenme tekniğini bir araya getirerek doğruluk oranını artırır (J. Wang vd., 2021).

Literatürde yapılan çalışmalar, derin öğrenme tabanlı modellerin, istatistiksel ve fiziksel modellere kıyasla daha iyi performans gösterdiğini ortaya koymaktadır (J. Wang vd., 2021). Bu modeller, dalga enerjisi tahmininde doğruluk oranını artırarak enerji tedarik sistemlerinin daha güvenilir hale gelmesini sağlar.

Dalga enerjisi tahmininde yapay zeka tabanlı modellerin kullanımı, enerji tedarik sisteminde denge sağlama açısından büyük bir avantaj sunmaktadır. Özellikle rüzgar ve dalga enerjisi gibi düzensiz enerji kaynaklarının tahmininde yapay zeka teknikleri, bu kaynakları diğer yenilenebilir enerji kaynaklarına göre daha avantajlı hale getirebilir. Dalga gücü tahmini, genellikle şu verilere dayalı olarak gerçekleştirilir:

Hindcast Verileri: Geçmiş rüzgar ve dalga gücü verilerinin analizi.

Hasat Cihazlarının Güç Eğrileri: Dalga türbinlerinin performansını belirlemek için kullanılır.


Doğrudan İlgili Değişkenler: Rüzgar hızı, dalga yüksekliği ve dalga periyodu gibi değişkenler kullanılarak tahmin yapılır.

Bu yöntemler, dalga enerjisi dönüşüm sistemlerinin tasarımında ve türbin seçiminde kritik rol oynar. Dalga enerjisi tahmininde doğruluk oranının artırılması, enerji üretim maliyetlerini düşürerek ekonomik fizibiliteyi iyileştirir.

Derin öğrenme modellerinin kullanım alanları yalnızca enerji tahmini ile sınırlı kalmamaktadır. Artan işlemsel kapasiteler sayesinde bu modeller, endüstri (kalite kontrol ve süreç optimizasyonunda), sağlık (hastalık tespiti ve teşhis sistemlerinde), çevre bilimleri (hava ve su kalitesi tahminlerinde) ve enerji sistemleri (dalga ve rüzgar enerjisi tahmini ve enerji dönüşüm optimizasyonunda) alanlarında kullanılmaktadır.

Bu alanlardaki başarı, büyük veri ve yapay zeka tekniklerinin entegrasyonu sayesinde mümkün olmaktadır (Cuadra vd., 2016). Dalga enerjisi dönüşüm sistemlerinin optimizasyonu için yapay zeka algoritmalarını sınıflandıran çalışmalar, literatürde geniş bir yer tutmaktadır (Duarte vd., 2022). Dalga enerjisi tahmini için kullanılabilecek algoritmaların sınıflandırılması Şekil 3.1’de şematik olarak sunulmaktadır. Bu sınıflandırma, farklı yapay zeka tekniklerinin dalga enerjisi tahmininde nasıl kullanılabileceğini ve hangi yöntemlerin daha etkili sonuçlar verdiğini göstermektedir.

Sonuç olarak, derin öğrenme algoritmalarının dalga enerjisi sistemlerine entegrasyonu, enerji üretiminde verimliliği artırmakta ve maliyetleri düşürmektedir. Bu teknolojiler, gelecekte dalga enerjisinin daha yaygın bir şekilde kullanılmasını sağlayarak sürdürülebilir enerji hedeflerine katkıda bulunacaktır.



Şekil 3.1 Yaygın olarak uygulanan doğrudan ve dolaylı yapay zeka tabanlı algoritmalarının sınıflandırılması (Clemente vd., 2023)

Dolaylı ve doğrudan algoritmalar arasında önemli bir ayrım yapılmaktadır. Dolaylı algoritmalar, daha çok dalga yayılımı, cisim hareket tahmini ve boşluk doldurma gibi problemlerin çözümüne odaklanırken (Nam vd., 2020), doğrudan algoritmalar ise dalga enerjisi dönüştürücüleri tasarımı, parametre optimizasyonu ve performansın maksimize edilmesi gibi daha doğrudan optimizasyon problemlerini çözme eğilimindedir. Dolaylı algoritmalar genel olarak regresyon ve sınıflandırma işlemlerini gerçekleştirmek için örüntü tanıma üzerine geliştirilmiştir. Yapay Sinir Ağları, Destek Vektör Makineleri ve Rastgele Ormanlar dolaylı algoritmalara örnek yöntemler olarak verilebilir. Doğrudan algoritmalar, bir amaç fonksiyonunu minimize/maksimize etmek için, probleme ait evrensel küme içerisinde optimizasyon işlemi gerçekleştirilmesinde dikkate alınmaktadır (Ambach & Schmid, 2017). Optimizasyon işlemi sayesinde problem çözümünde global optimum çözüme mevcut yerel minimum/maksimum noktalar üzerinden erişebilmektedir. Bu sayede diğer tekniklerden farklı olarak kaybolan gradyan problemi ortadan kaldırılmaktadır.

Özetle, dolaylı ve doğrudan algoritmalar, dalga enerjisi sistemlerinin geliştirilmesi ve optimizasyonunda kritik bir rol oynamaktadır. Yapay zeka tabanlı derin öğrenme

modellerinin optimizasyon algoritmaları ile entegre edilmesi, dalga enerjisinden elde edilen verimliliği artırarak enerji maliyetlerini düşürmekte ve sistem performansını iyileştirmektedir. Gelecekte, bu tekniklerin daha yaygın kullanımı, dalga enerjisinin sürdürülebilir enerji sistemleri içindeki payını önemli ölçüde artıracaktır.



4. LİTERATÜR TARAMASI

Berbić vd., (2017), Avustralya'daki iki lokasyon için neredeyse gerçek zamanlı olarak belirgin dalga yüksekliği tahmini için YSA ve SVM uygulamıştır. Algoritmaların tahmin performansları 0,5 ila 5,5 saat aralığındaki farklı zaman periyotları için test edilerek değerlendirilmiştir. Çalışma, daha az sayıda girdi özneliğinin kullanılmasının daha doğru tahminlerle sonuçlandığını bulmuştur. Hem YSA'ların hem de SVM'lerin faydalı olabileceğini, YSA'ların daha kısa tahmin dönemleri için, SVM'lerin ise daha uzun dönemler için uygun olduğunu öne sürmektedirler.

Mahmoodi vd., (2017), okyanus şamandıralarından alınan meteorolojik veriler (rüzgar hızı, hava ve deniz sıcaklığı) kullanılarak dalga enerjisi akısını tahmin etmek için üç farklı veri madenciliği yöntemleri ileri beslemeli sinir ağı (FFNN), kademeli ileri sinir ağı (CFNN) ve gen ifade programlama (GEP) arasında karşılaştırma yapılmıştır. Algoritmaların tahmin performansları değerlendirme kriterleri (kök ortalama kare hatası (RMSE) ve regresyon katsayısı (R^2)) kullanılmıştır. FFNN yönteminin doğruluk açısından diğer yöntemlere göre daha iyi performans gösterdiği bulunmuştur. Çalışmada ayrıca dalga enerjisi akısı ile meteorolojik veriler arasında iyi bir korelasyon olduğu gözlenmiştir. Genel olarak dalga verileri olmayan bölgelerde dalga enerjisi akısının meteorolojik verileri üzerinden tahmin edilmesinin mümkün olduğu ortaya konulmuştur.

Sadeghifar vd., (2017), çeşitli zaman aralıklarında dalga yüksekliğini tahmin etmek için doğrusal olmayan artık sinir ağları kullanmıştır. Farklı eğitim fonksiyonlarına sahip RNN modelleri, 3 saatlik periyot için tahminlerinde 0,96 ve 12 saatlik periyot için tahminlerinde 0,87 olmak üzere korelasyon katsayıları hesaplanmıştır. Modelin daha yüksek dalgaları tahmin etmede daha doğru olduğu gözlenmiş ve çeşitli kıyı mühendisliği uygulamalarında yararlı olduğunu ortaya koymuşlardır.

Choi vd., (2020), yapay sinir ağları kullanılarak ham okyanus görüntülerinden dalga boyu yüksekliğini gerçek zamanlı tahmini için bir yöntem önermişlerdir. Okyanus görüntüsünün işlenmesinde dört farklı konvolüsyonel sinir ağı (CNN) modeli incelenmiş ve performansı artırmak için çeşitli özellik çıkarıcılarla transfer öğrenme uygulanmıştır. Sıralı okyanus görüntülerinden gerçek değerli dalga boyu yüksekliğini tahmin etmek için çift yönlü ConvLSTM tabanlı bir regresyon modeli de önerilmiştir. Önerilen yöntemin MSE değeri 0,0177 olarak hesaplanmış ve MAE ile MAPE değerleri bakımından da olumlu performans gösterdiği ortaya konulmuştur.

Pirhooshyaran & Snyder, (2019), dünyanın dört bir yanındaki Ulusal Okyanus ve Atmosfer İdaresi şamandıralarından alınan gerçek verilere dayanarak okyanus dalgası özelliklerinin yeniden yapılandırılması, özellik seçimi ve çok değişkenli, çok aşamalı tahmini için özellikle diziden diziye YSA ve LSTM gibi RNN kullanmaya odaklanmıştır. Tanıtılan ağlar üzerinde çeşitli optimizasyon algoritmalarının performansı test edilmiştir. Önerilen ağların dalga özelliklerinin yeniden yapılandırılmasında ve çok değişkenli tahminlerde mevcut tekniklerden daha iyi performans gösterdiği görülmüştür. Ayrıca, elastik ağ kavramı özellik seçimi için ağlara dahil edilmiş ve daha derin tekrarlayan yapıların bu amaç için tek katmanlı olanlardan daha etkili olduğu bulunmuştur.

Wei & Chang, (2021), Tayvan'daki Keelung ve Kaohsiung limanlarının kıyı sularında bulunan çalışma alanını seçerken, şamandıra ve radar görüntüleri veri kümeleri 2013-2019 yılları arasında tayfun verileri için toplanmıştır. Veri seti tipik olarak zaman serisine duyarlıydı. Dalga yüksekliği, rüzgar hızı, deniz seviyesindeki hava basıncı, yüzey sıcaklığı, yüzey rüzgar hızı/yönü ve anlık maksimum yüzey rüzgar hızı/yönü, geçitli tekrarlayan birim sinir ağı ve CNN özellik ve zaman serisi çıkarma girdisi için veri kümesi grubu ve öznetelik grubu olarak kullanılmış ve iki rüzgar hızı tahmin modeli ve rüzgar sonuçlarına dayalı genişletilmiş dört dalga yüksekliği tahmin modeli tasarlamışlardır.

Bento vd., (2021), Pasifik ve Atlantik kıyıları ile Meksika Körfezi'nde ABD Ulusal Veri Merkezi'nden (NDBC) dört farklı ayda 11 sahadan ve Kanada Entegre Bilim Veri Yönetimi'nden (ISDM) iki sahadan şamandıra verileri toplayarak derin yapar sinir ağı (Lipton vd., 2015) temelinde sırasıyla dalga yüksekliği ve dalga periyodu tahmini yoluyla dalga enerjisi akışını doğrudan ve dolaylı olarak tahmin etmiştir. Dalga veri seti, tahmin edilen değerler ile ham değişkenler arasındaki korelasyonları ortaya çıkarmak için hem zamansal hem de uzamsal özelliklere sahiptir.

Mousavi vd., (2021) dalga gücünü tahmin etmek için LSTM tabanlı bir modelin performansını değerlendirmişlerdir. Veri kümesi, LTSM yapısına dayalı dalga gücünü ve dalga yüksekliği ile ilişkisini araştırmak için akış-3D simülasyonu gerçekleştirmişlerdir. Dalga yüksekliği ile dalga gücünün arasında korelasyon olduğunu ve elektrik üretim kapasitesinin de iki parametreye bağlı olduğunu göstermişlerdir.

Yao & Wu, (2022), çalışmalarında dalga yüksekliği tahmini için LSTM sinir ağına dayalı bir tahmin modeli oluşturmuşlardır. Şamandıra verilerinden alınan rüzgar hızı değerleri

ile dalga yüksekliđi arasındaki korelasyonu arařtırmıřlardır. LSTM modelinin dođruluđunu deđerlendirmek için farklı zaman aralıklarında ($t=0,5s, 1s, 3s, 6s$ ve $12s$) farklı tahmin modelleri oluřturmuřtur. Modellerin tahmin sonularına bakıldıđında tahmin yapılan zaman aralıđı arttıça tahmin hata deđerinin hızla arttıđı gözlenmiřtir. Çoklu alt adım dalga yüksekliđi tahmin verileri, son tahmin zamanındaki dođruluđu arttırmak için bilinen veriler olarak kullanılmıřtır. alıřmada yapılan simlasyon sonularında, 6 saatlik tahmin hatasının tek adımlı modele kıyasla %45,83 ve 12 saatlik tahmin hatasının %52,83 oranında azaldıđını göstermiřlerdir.

Patanè vd., (2024), bir bölgedeki rüzgar alanı hakkında mekânsal ve zamansal bilgileri kullanarak dalga yüksekliđi tahmini için derin öğrenme mimarisi kullanmıřlardır. Önerilen yöntemde Sicilya kıyılarına yakın bir yere kurulan İtalyan Deniz İzleme Ađı řamandırasından alınan dalga yüksekliđi verileri ve Copernicus İklim Deđerikliđi Servisi ERA5 analizinden alınan rüzgar alanı verileri kullanılarak bir fizibilite alıřması yapılmıřtır. alıřma sonucunda, mekansal özellik ıkarımı için konvolsyonel katmanlardan ve ilgili dinamikleri modellemek için řamandıra evresini dikkate alan kısa süreli bellek katmanlarından oluřan çok bloklu bir hibrit derin sinir ađının kullanımının literatürde kullanılan diđer ampirik, sayısal, makine öğrenimi ve derin öğrenme yöntemlerinden daha iyi performans gösterdiđini ortaya koymuřlardır.

Tarwidi vd., (2023), alıřmalarında dalga yüksekliđini tahmin etmek için aşırı gradyan artırma (XGB) tabanlı bir makine öğrenimi yöntemi kullanılmıřtır. XGB yönteminin performans metrikleri üç farklı makine öğrenimi modeli (çoklu dođrusal regresyon (MLR), destek vektör makinesi (SVM) ve rastgele orman (RF)) ile karřılařtırılmıřtır. Modelin performans metriklerinde, XGB algoritmasının 0,98675 korelasyon katsayısı (R^2), %6,635 ortalama mutlak yüzde hatası (MAPE) ve 0,03902 kök ortalama kare hatası (RMSE) deđerleri elde edilmiřtir. Sonu olarak dalga yüksekliđi tahmin etmede XGB algoritmasının diđer makine öğrenimi yaklařımlarından daha iyi performans gösterdiđini ortaya koymuřlardır.

F. Anggraeni vd., (2021), alıřmalarında dalga yüksekliđini dođru bir řekilde tahmin etmek için XGB ve AdaBoost yöntemleri bir arada kullanılarak hibrit bir sistem önerilmiřtir. Eğitim verisi olarak 4,5 yıllık ve test verisi olarak altı aylık olmak üzere beř yıllık veri kullanılmıřtır. Test verilerini 7 gün, 14 gün, 30 gün, 45 gün ve 60 gün sonrasını tahmin etmek için kullanılmıřtır. En yüksek dođruluđu elde etmek için XGB ve AdaBoost kullanarak tahmin sonularını karřılařtırmıřlardır. Hibrit modelin performansını optimize

etmek için her iki y nteme de hiper parametre ayarı ger ekleřtirilmiřtir. Her iki model i in de en iyi parametre deęeri kombinasyonunu bulmak i in hiper parametre ayarlama i in GridSearch algoritmasını kullanılmıřtır. Tahmin sonu larının en y ksek doęruluęu RMSE i in 0,064 ve korelasyon deęeri (R^2) i in 0,987 olarak hesaplanmıřlardır.

Afzal vd., (2023),  alıřmalarında genelleřtirilmiř ařırı deęer (General Extreme Value, GEV) teorisi ve makine  ęrenimi teknięini kullanarak dalga y kseklięini tahmini yapmıřlardır. Dalga karakteristiklerini i eren 60 yıllık r zgar hızı, r zgar y n  ve deniz sıcaklıęı verileri Avrupa Orta Menzilli Hava Tahminleri Merkezi'nden (ECMWF) elde etmiřlerdir. Doęrusal regresyon (LR), yapay sinir aęları ve destek vekt r makineleri gibi makine  ęrenmesi algoritmaları korelasyon deęeri (R^2) performansı a ısından deęerlendirilmiřtir. Model karřılařtırma sonu larında, SVM modelinin LR ve YSA modellerinden %99,80 doęrulukla daha iyi performans g sterdięini ortaya koymuřlardır. Geliřtirilen model, kıyı yapılarının tasarımı i in hem  nemli dalga y kseklięini hem de ařırı dalgaları tahmin edebilme potansiyeli ortaya konulmuřtur.

X. Guan, (2020),  alıřmasında kısa vadeli dalga y kseklięi tahmininin doęruluęunu artırmak i in, m kemm l  zellik  ıkarma kabiliyetine sahip oldukları ve zaman serisi verilerini iřlemede  ok iyi oldukları i in konvol syonel sinir aęı (CNN) ve uzun kısa vadeli bellek aęına dayalı bir tahmin modeli  nermiřlerdir. Dalga y kseklięi dizilerinin zamanlama baęımlılıęını tanımlamak i in spektral  zellik bilgisi, dalga y kseklięi tahmin sonu larını hesaplamak  zere LSTM aęının giriř bilgisi olarak kullanmıřlardır. Modelin doęruluęunu teyit etmek i in Avustralya'dan  l  len ger ek verileri kullanıřlar ve deneysel sonu ları incelendikleri zaman LSTM, Destek Vekt r Makineleri, Rastgele Orman (RF) ve dięer makine  ęrenimi modellerinden daha iyi tahmin performansına sahip olduęunu ortaya koymuřlardır.

H. Hu vd., (2021),  alıřmalarında Erie G l 'n n ideale yakın dalga b y me kořulları altında dalga y kseklięi ve periyodunu tahmin etmek i in XGB ve Uzun Kısa S reli Bellek (LSTM) tekrarlayan sinir aęına dayalı yeni makine  ęrenimi y ntemleri kullanmıřlardır. 1994-2017 yılları arasında iki a ık deniz řamandırasından alınan  nemli dalga y kseklięi (H), tepe dalga periyodu (Tp) ve y zey r zgarı veri setleri model eęitimi ve testi i in iřlenmiřtir. ML modellerini 1994'ten 2015'e kadar olan veri setleriyle eęitilmiř ve doęrulanmıřtır. Ardından 2016 ve 2017 i in  nemli dalga y kseklięini ve tepe periyodunu tahmin etmek i in eęitilmiř modelleri kullanılmıřtır. XGB modeli, dalga boyu y kseklięinde %15,6-%22,9 ve tepe dalga periyodunda %8,3-%13,4 Ortalama

Mutlak Yüzde Hata (MAPE) değerleri ile en iyi genel performansı verdiği gözlenmiştir. LSTM modeli, dalga boyu yüksekliğinde %23,4-%30,8 ve tepe dalga periyodunda %9,1-%13,6 MAPE değerleri gözlenmiştir. XGB ve LSTM, dalga boyu yüksekliğinde %-2,56 ila %-10,61 ve tepe dalga periyodunda %-8,08 ila %-10,13'lük göreceli sapmalarla bu tahminleri iyileştirdiğini ortaya koymuşlardır.

P. Abhigna vd., (2017), çalışmalarında Bengal Körfezi'ndeki demirli şamandıralardan elde edilen rüzgar ve dalga verileri, Yapay Sinir Ağları (YSA) kullanılarak dalga boyu yüksekliği tahmin etmek için kullanılmıştır. Tekrarlayan ve İleri Beslemeli Ağlar Levenberg Marquardt (LM), Conjugate Gradient (CG) ve Bayesian Regularization (BR) algoritmaları kullanılarak analiz edilmiştir. Çalışma sonucunda, BR algoritmaları Tekrarlayan Ağların diğer yöntemlere göre daha yüksek korelasyona ve daha az hataya sahip olduğunu ortaya konulmuştur.

Fan vd., (2020), dalga boyu yüksekliğinin tahmini için LSTM modeli önerilmiştir. LSTM modeli, farklı şamandıra verilerinden 10 adet istasyonda 1 saatlik ve 6 saatlik tahminler gerçekleştirilmiştir. Son 4 saatin rüzgar hızı ve son 1 saatin dalga yüksekliği ve rüzgar yönü girdi parametreleri olarak kullanılarak, LSTM tahmin sonuçları ile geri yayılım sinir ağı (RNN), aşırı öğrenme makinesi (ELM), destek vektör makinesi (SVM), artık ağ (ResNet) ve rastgele orman (RF) algoritmalarından elde edilen sonuçlarla karşılaştırılmıştır. LSTM modelinin performansının değerlendirilmesi için beş metrik değer kullanılmıştır. Minimum ortalama mutlak hata yüzdesi 1 saatlik ve 6 saatlik tahminlerde sırasıyla %5,14 ve %5,24 olarak gözlenmiştir. Sonuçlar, LSTM'nin 1 saatlik doğru tahminler ve tatmin edici 6 saatlik tahminler ile istikrarlı tahmin etkileri elde edebileceğini göstermektedir. Çalışmada, LSTM'nin uzun vadeli tahmin gerçekleştirme konusundaki güçlü yeteneğini ortaya koymuşlardır.

Xiao & Lu, (2024), çalışmalarında dalga yüksekliği tahminlerinin doğruluğunu artırmak için Konformer ve Uzun Kısa Süreli Bellek ağlarına (LSTM) dayanan hibrit bir model (Conformer-LSTM) önermişlerdir. Hibrit model içerisinde, LSTM katmanı dalga boyu yüksekliği tahminlerinin tutarlılığını ve istikrarını optimize edecek şekilde ele almaktadır. Ek olarak, modelin temel özellikleri tanıma ve kullanma verimliliğini daha da artırmak için uyarlanabilir bir özellik füzyon ağırlık ağı tanıtılmıştır. Değerlendirme ölçütleri olarak Ortalama Mutlak Hata (MAE), Ortalama Kare Hatanın Kökü (RMSE), Ortalama Mutlak Yüzde Hata (MAPE) ve Belirleme Katsayısı (R^2) parametreleri hesaplanarak model performansının kapsamlı bir şekilde değerlendirilmesini sağlamaktadır. Sonuçlar,

Conformer-LSTM modelinin birden fazla sahada geleneksel LSTM, CNN ve CNN-LSTM modellerinden daha iyi performans gösterdiğini ve dalga yüksekliği tahminindeki potansiyelini ortaya konulmuştur.

Kumar vd., (2017), çalışmalarında Minimal Kaynak Tahsis Ağı (MRAN) ve Büyüyen ve Budayan Radyal Taban Fonksiyonu (GAP-RBF) ağı gibi sıralı öğrenme algoritmaları kullanılarak farklı coğrafi bölgelerdeki günlük dalga yüksekliklerini tahmin etmişlerdir. Çalışmada, Meksika Körfezi, Kore bölgesi ve Birleşik Krallık bölgesi olmak üzere coğrafi olarak farklı üç bölgedeki 13 istasyondan 1 Ocak 2011 ile 30 Ağustos 2015 tarihleri arasında toplanan veriler kullanılarak gerçekleştirilmiştir. MRAN ve GAP-RBF'nin performansı Destek Vektör Makineleri (SVM) ve Aşırı Öğrenme Makinesi (ELM) ile karşılaştırılmıştır. Performans çalışması sonuçları, MRAN ve GAP-RBF'nin günlük dalga yüksekliği tahmininde minimum ağ kaynaklarıyla SVM ve ELM'den daha iyi performans gösterdiğini gözlenmiştir. MRAN ve GAP-RBF arasındaki performans karşılaştırması, MRAN'ın minimal mimari ile GAP-RBF'den daha iyi performans gösterdiğini ortaya koymuşlardır.

Zhang ve Dai, (2019), çalışmalarında klasik derin inanç ağındaki (DBN) kısıtlı Boltzmann makinesi (RBM), zamansal bilgi içeren koşullu kısıtlı Boltzmann makinesi (CRBM) ile değiştirilmiş ve CRBM-DBN modeli oluşturulmuştur. Parçacık sürüsü optimizasyonu (PSO) algoritması ile belirlenen model parametreleri, önemli dalga yüksekliğini tahmin etmek için kullanılmıştır. Modeli eğitmek için Ulusal Veri Şamandıra Merkezi'ne (NDBC) ait kıyıya yakın ve açık deniz şamandıralarından (42020 ve 42001 istasyonları) 2016 yılında gözlemlenen veriler alınmış ve 2017'deki ilgili veriler 1-24 saatlik veriler test için kullanılmıştır. Modelin tahmin performansının değerlendirilmesi için Nash-Sutcliffe etkinlik katsayısı (NSE) ve Kök Ortalama Kare Hatası (RMSE) metrik değerleri ile gerçekleştirilmiştir. Tahminler, kısa vadeli (9 saat) için, anlamlı dalga yüksekliği tahmini için RMSE ve NSE'nin sırasıyla 0,1 m ve 0,98 olduğunu gözlenmiştir.

M. Umair vd., (2019), çalışmalarında deniz dalgası parametrelerinin sınıflandırılması ve tahmini konusundaki makine öğrenimi çalışmalarının bir derlemesini sunmuşlardır. Deniz yüzeyinde sayısız ticari ve endüstriyel faaliyet gerçekleşmektedir, bu nedenle deniz yüzeyi dalgasını anlamak, sınıflandırmak ve tahmin etmek büyük ilgi çeken bir konudur. Deniz dalgalarının davranışını modellemek için birçok sayısal model incelenmiştir, ancak bu modeller sahaya özgü çalışmalardır. Veriye dayalı makine öğrenimi modellerinin

sahaya özgü sınıflandırma, gerçek zamanlı veya yakın gelecekteki tahmin problemleri için etkili bir çözüm olduğundan bahsedilmiştir.

Abed-Elmdoust ve Kerachian, (2012), çalışmalarında RST Kuzey Amerika'daki Superior Gölü'ne uygulanarak dalga yüksekliği tahmini için karar kuralları adı verilen bazı basit kurallar tanımlamışlardır. RST sonuçlarının Destek Vektör Makineleri (SVM), Bayes Ağları (BN), Yapay Sinir Ağları (ANN) ve Adaptif Nöro-Bulanık Çıkarım Sistemi (ANFIS) gibi diğer yumuşak hesaplama tekniklerinin sonuçlarıyla karşılaştırılması, RST'nin dalga yüksekliği tahmininde diğer yumuşak hesaplama tekniklerinden daha iyi performans gösterdiğini ve karar vericiler doğru bir şekilde kullanılabilecek bazı basit karar kuralları sağladığını ortaya koymuşlardır.

Karabulut ve Ozmen Koca, (2020), çalışmalarında açık deniz dalga yüksekliği tahmininin literatürden farklı olarak dalganın aynı fiziksel etkilerini içeren ve akış hızı olan tek bir parametre ile elde edilmesi önerilmiştir. Akış hızının farklı derinliklerdeki farklı değerlerinin etkisi de Relief algoritması kullanılarak araştırılmıştır. Doğrusal, Karar Ağacı, Destek Vektör Makinesi, Ensemble ve Gauss Regresyon modelleri, Türkiye'de Akdeniz'deki iki istasyon için belirlenen parametrelerin farklı değerleri kullanılarak incelenmiştir. Dalga yüksekliği tahmininin performansını doğrulamak için çeşitli değerlendirme kriterleri (MSE, RMSE, MAE ve R^2) kullanılmıştır. İki şamandıra için en iyi tahmin performansları sırasıyla 0,866 ve 0,954 R^2 değerleri ile elde edilmiştir. Bu sonuçlar önerilen yöntemin başarısını ortaya koymuşlardır.

L. Rusu, (2020), çalışmasında Karadeniz havzasındaki dalga gücü dinamiklerini iklim değişiklikleri açısından analizini gerçekleştirmiştir. Analiz için SWAN fiziksel modelleme yöntemini kullanmıştır. Tüm Karadeniz havzası için bir dalga modellemesi sistemi kullanmıştır. Uzak ve yakın gelecek olarak 50 yıllık periyotlarda toplamda 100 yıllık bir dalga gücü simülasyonu gerçekleştirmiştir. Simülasyon sonucunda Karadeniz havzasında beklene dalga gücü dinamiklerinin geniş perspektifli bir yaklaşımı ortaya konulmuştur.

E. Rusu, (2009), çalışmasında Karadeniz havzasında SWAN fiziksel modellemesini kullanılarak dalga enerjisi analizi gerçekleştirmiştir. Sistem hem dalga üretimi hem de kıyıya yakın dalga enerjisi dönüşüm sistemlerinin simülasyon modeline dayanmaktadır. Üç farklı noktadan alınan ölçüm değerleri referans alınarak simülasyonda dalga yüksekliği ve periyodu değerleri modellenerek dalga gücü hakkında bilgi edinilmiştir.

Analiz yöntemi ve dalga tahmin sistemi kıyıya yakın daha hassas araştırmalar için bir ön çalışma olduğunu ortaya koymuşlardır.

Mahjoobi ve Etemad-Shahidi, (2008), çalışmalarında dalga yüksekliğinin tahmini için sınıflandırma ve regresyon için karar ağaçlarının performansını incelemişlerdir. Regresyon ağaçlarının oluşturulması ve değerlendirilmesi için CART algoritması kullanılmıştır. Karar ağaçlarının performans sonuçları yapay sinir ağlarının sonuçları ile karşılaştırılmıştır. Sonuçlar, kabul edilebilir bir hata aralığına sahip verimli bir yeni yaklaşım olarak karar ağacının dalga yüksekliği tahmini için başarıyla kullanılabileceğini ortaya koymuşlardır.

LSTM, mimarisinin kararlı ve aşırı uyum sorunundan etkilenmemesi geçit ve bellek hücresi nedeniyle uzun vadeli veri kümelerinde yapılan eğitimlerde performansının artmasını sağlayan bir özelliğidir. Bu nedenle, uzun ya da kısa dönem gerektiren zaman serisi veri kümeleri, model iletimini işlemek için LSTM'yi kullanabilir. Hu ve diğerleri (J. Hu vd., 2020), LSTM'yi bir aşırı öğrenme makinesiyle birleştirerek yeni bir doğrusal olmayan algoritma ortaya koymuştur. Hibrit modelin yapı karmaşıklığı ile performansını dengelemek için gizli katman sayısını iyileştirmek üzere bir diferansiyel evrim algoritması kullanmışlardır. LSTM modeli aşırı uyum sorununu çözse ve daha uzun belleğe sahip olsa da yine de bazı dezavantajları vardır. Önceden eğitilmesi için daha fazla zaman ve daha büyük veri kümesi gerektirir ve farklı ağırlık başlatma sınırlamalarına sahiptir. Geçitli tekrarlayan birimler (GRU'lar) (Ding vd., 2019), unutmaya geçidini ve giriş geçidini tek bir güncelleme geçidiyle değiştiren popüler bir LSTM çeşididir. GRU'nun daha az parametre değiştiricisi olduğundan, eğitim biraz daha hızlıdır ve genelleştirmek için daha az veri gerektirir ve GRU daha az hesaplama ile birden fazla görevde benzer bir performans elde eder.

Literatürde gerçekleştirilen çalışmalarda, dalga yüksekliği tahmini için farklı algoritmaların performansları yaygın olarak karşılaştırılmıştır. Özellikle kısa ve uzun süreli zaman serilerinde yüksek performans gösteren LSTM, ResNet, RNN gibi derin öğrenme algoritmalarının, farklı coğrafi konumlardaki şamandıra verilerinde uygulanarak değerlendirmeleri yapılmıştır. Ayrıca, bazı çalışmalarda makine öğrenmesi teknikleri optimizasyon algoritmalarıyla birleştirilerek dalga yüksekliği tahmininde iyileştirmeler sağlanmıştır. Ancak bu çalışmaların çoğu, dalga yüksekliği ve periyodu tahminleri üzerine odaklanmış olup, bu tahminlerin dalga enerji potansiyelinin hesaplanmasına entegrasyonu konusuna yeterince derinlemesine değinmemiştir. Bu

durum, literatürde önemli bir eksiklik olarak göze çarpmaktadır. Bununla birlikte, Karadeniz gibi spesifik bölgelerde dalga gücü tahminine yönelik kapsamlı ve detaylı incelemelerin sınırlı olduğu görülmektedir. Çoğu çalışma, genellikle okyanus veya yüksek dalga enerjisi potansiyeline sahip denizlere odaklanmışken, Karadeniz gibi daha az incelenmiş bölgelerde dalga enerjisi tahminine yönelik çalışmalar eksik kalmıştır. Bu bağlamda, bu tez çalışması önemli bir yenilik ortaya koymaktadır. Karadeniz'in Samsun ve Ordu açıklarındaki şamandıralardan alınan bir yıllık veriler kullanılarak, dalga yüksekliği ve periyodu tahminleri gerçekleştirilmiş ve bu tahminler kullanılarak dalga enerji potansiyeli hesaplanmıştır. Çalışmada LSTM, ResNet, RNN, Bayesian, ELM ve SVM gibi temel regresyon modellerinin performansları karşılaştırılmış, elde edilen sonuçlar XGB algoritması ile yığınlama (stacking) yaklaşımı kullanılarak tahmin performansı iyileştirilmiştir. Bu hibrit yaklaşım, farklı modellerin güçlü yönlerini bir araya getirerek tahmin doğruluğunu artırmayı ve enerji potansiyelinin daha güvenilir bir şekilde hesaplanmasını sağlamıştır.

Çalışmanın yeniliği ve katkısı, iki temel noktada öne çıkmaktadır. Bunlar:

- Dalga yüksekliği ve periyodu tahminlerinin enerji potansiyelinin hesaplanmasına entegre edilmesi: Literatürde eksik olan bu entegrasyon, dalga enerjisinin pratik uygulamalarına yönelik önemli bir adım olarak değerlendirilmektedir.
- Karadeniz bölgesinde detaylı dalga gücü tahmini: Türkiye'nin enerji potansiyelinin değerlendirilmesi açısından stratejik bir öneme sahip olan Karadeniz, bu çalışma ile derinlemesine analiz edilmiştir. Samsun ve Ordu açıklarındaki gerçek şamandıra verileri kullanılarak, bölgenin enerji potansiyeli ilk kez bu kadar kapsamlı bir şekilde ortaya konmuştur.


Bu tez çalışması, literatürdeki bu boşluğu doldurmayı amaçlamakta ve dalga enerjisi tahmini alanında yenilikçi bir modelleme yaklaşımı sunarak, gelecekte yapılacak çalışmalar için önemli bir referans oluşturmaktadır. Sonuç olarak, geliştirilen model ve elde edilen bulgular, Karadeniz'in dalga enerjisi potansiyelinin belirlenmesi ve dalga enerji sistemlerinin etkin planlamasına yönelik bilimsel ve pratik katkılar sunmaktadır.

5. MATERİYAL VE YÖNTEM

5.1 Veri Setinin Oluşturulması


Dalga enerjisinin tahmin edilmesi için kapsamlı bir veri seti hazırlanmıştır. Dalga enerjisi, dalga yüksekliğinin karesi ve dalga periyodu ile doğru orantılı olduğundan, bu iki parametrenin tahmini için ayrı ayrı şamandıra ölçümlerinden oluşan veri setleri oluşturulmuştur. Çalışma kapsamında, Meteoroloji Genel Müdürlüğü tarafından sağlanan Ordu ve Samsun açıklarındaki şamandıralardan elde edilen 2023 yılına ait bir yıllık veriler kullanılmıştır.

Ordu Şamandırası (17397), 41°2'39" N, 38°6'51" E koordinatlarında, Ordu-Giresun Havalimanı açıklarında yer almaktadır. Şamandıranın yüksekliği 4,51 metre, kule tipi 1,8 metre olup enerji kaynağı olarak güneş enerjisi kullanılmaktadır. Şamandıranın coğrafik konumu, Şekil 5.1'de gösterilmiştir.



Şekil 5.1 Ordu (17397) şamandırasının Türkiye haritası üzerindeki konumu

Samsun şamandırası (17391), 41°26'16" N, 38°33'34" E koordinatlarında, Samsun Körfezi açıklarında yer almaktadır. Şamandıranın yüksekliği 4,51 metre, kule tipi 1,8 metre olup enerji kaynağı olarak güneş enerjisi kullanılmaktadır. Şamandıranın coğrafik konumu, Şekil 5.2'de gösterilmiştir.



Şekil 5.2 Samsun (17391) şamandırasının Türkiye haritası üzerindeki konumu

Dalga gücünün hesaplanması için dalga boyu yüksekliğinin ve periyodunun ayrı ayrı tahminini yapan modeller hazırlanarak bir araya getirilmiştir. Hazırlanan hibrit model ilgili şamandıradan alınan veriler ile dalga gücü tahmini yapmaktadır. Şamandıralardan sağlanan parametreler tahmin modeli üzerinde pozitif ve negatif yönde etkilere sebep olabilmektedir. Bu nedenle dalga boyu yüksekliği için kullanılan parametreler ile dalga periyodu için kullanılan parametreler birbirlerinden farklı olarak belirlenmiştir. Ayrıca bu durum direkt olarak dalga gücünün değil dalda yüksekliği ve periyodunun ayrı ayrı tahmin edilmesinin de temel nedenidir.

Meteoroloji Genel Müdürlüğü tarafından sağlanan şamandıra verileri arasında; Akıntı Yönü 5m (°), Akıntı hızı 5m (cm/san.), Akıntı Yönü 10m (°), Akıntı hızı 10m (cm/san.), Akıntı Yönü 15m (°), Akıntı hızı 15m (cm/san.), Akıntı Yönü 20m (°), Akıntı hızı 20m (cm/san.), Belirgin Dalga Yüksekliği (m), Maks. Dalga Yüksekliği (m), Dalga Yönü (°), Ortalama Dalga Periyodu (sn), Pik Dalga Periyodu (sn), Deniz suyu Sıcaklığı (°C), Hava Sıcaklığı (°C), Aktüel Basınç (hPa), Ortalama Rüzgar Yönü (m/san), Maksimum Rüzgar Yönü (m/san) parametreleri sağlanmıştır. Dalga boyu yüksekliği için bu parametrelerden; Akıntı hızı 5m (cm/san.), Akıntı hızı 10m (cm/san.), Akıntı hızı 15m (cm/san.), Belirgin Dalga Yüksekliği (m), Maks. Dalga Yüksekliği (m), Pik Dalga Periyodu (sn), Ortalama Rüzgar Yönü (m/san) ve Maksimum Rüzgar Yönü (m/san) kullanılarak modellerin eğitimleri gerçekleştirilmiştir. Dalga periyodu için bunlar arasından Belirgin Dalga

Yüksekliği (m), Maks. Dalga Yüksekliği (m), Pik Dalga Periyodu (sn), Ortalama Rüzgar Yönü (m/san) ve Maksimum Rüzgar Yönü (m/san) parametreleri kullanılarak modellerin eğitimleri gerçekleştirilmiştir.

Dalga yüksekliği ve periyodu tahmini için geliştirilen modeller, bir hibrit modelde birleştirilerek dalga gücü tahmini gerçekleştirilmiştir. Hibrit model, ilgili şamandıralardan alınan verileri kullanarak, dalga gücü potansiyelini hesaplamak için optimize edilmiştir. Bu yaklaşım, farklı parametrelerin dalga gücü üzerindeki etkilerini dikkate alarak daha güvenilir sonuçlar elde edilmesini sağlamaktadır.

Sonuç olarak, bu veri seti ve kullanılan parametreler, dalga enerjisi tahminine yönelik modellerin geliştirilmesi ve Karadeniz'deki enerji potansiyelinin belirlenmesi için önemli bir temel oluşturmuştur.

5.2 Aşırı Öğrenme Makinesi (ELM)

Aşırı öğrenme makinesi (ELM) tek gizli katmanlı ileri beslemeli sinir ağları (SLFN) için geliştirilmiş bir algoritmadır (Guang-Bin Huang vd., 2004). Bu yöntem, geleneksel ileri beslemeli sinir ağlarına kıyasla daha hızlı öğrenme süreci ve daha iyi genelleme performansı sunmaktadır. ELM algoritmasında, giriş ağırlıkları ve gizli katman sapsmaları rastgele atanır ve gizli katman çıkış ağırlıkları, eğitim sürecinde analitik olarak belirlenir. Bu özellik, ELM'nin diğer gradyan tabanlı öğrenme algoritmalarından ayrışmasını ve öğrenme süresinin önemli ölçüde azalmasını sağlar.

ELM, Moore-Penrose (MP) genelleştirilmiş tersi yöntemi kullanarak gizli katman çıkış matrislerini çözümleyerek, çıkış ağırlıklarını hesaplar (Serre, 2002). Bu yaklaşım hem en küçük eğitim hatasına hem de en küçük ağırlık normuna ulaşmayı hedefler. Böylece, öğrenme sürecinde yerel minimumlara takılma riski azaltılmış olur.

ELM algoritmasının önemli bir avantajı, değiştirilemeyen aktivasyon fonksiyonlarına sahip SLFN'leri eğitebilmesidir. Geleneksel gradyan tabanlı öğrenme algoritmalarında yalnızca belirli aktivasyon fonksiyonları kullanılabilirken, ELM bu sınırlamayı aşarak geniş bir uygulama alanına sahiptir. Giriş ağırlıkları başlangıç değerlerinde sabit kaldığı ve yalnızca çıkış ağırlıkları eğitildiği için ELM'nin eğitim süresi, klasik sinir ağlarına kıyasla çok daha kısadır (Huang vd., 2006).

Bir ELM'nin çıktısı, gizli düğümlerin aktivasyon değerlerinin ağırlıklı toplamına uygulanan aktivasyon fonksiyonunun değeridir:

$$ELM(x) = g(\sum_{j=1}^L \beta_j h_j[x] + b_0) \quad (5.1)$$

Burada g , aktivasyon fonksiyonu; $h_j[x]$, gizli düğümün aktivasyon değeri, β_j ise çıkış ağırlıklarıdır.

Aktivasyon fonksiyonu olarak dışbükey bir aktivasyon fonksiyonu seçilmiştir. Yerel minimumlara takılmayı önlemek amacıyla sigmoid fonksiyonu tercih edilmiştir:

$$g(z) = \frac{1}{1+e^{-z}} \quad (5.2)$$


x girişi için birinci gizli düğümün aktivasyon değeri aşağıdaki gibi hesaplanır:

$$h_i[x] = g(\sum_{j=1}^n a_{j,i} x_j + b_j) \quad (5.3)$$

Burada $a_{j,i}$ giriş ağırlıkları ve b_j ise gizli katman sapmalarıdır.

Bu tez çalışmasında, dalga yüksekliğinin tahmini için kullanılan regresyon yöntemlerinden biri ELM'dir. Modelin eğitimi sırasında, Ordu ve Samsun şamandıralarından alınan 1 ve 2 yıllık geniş veri setleri kullanılmıştır. ELM'nin, geniş veri setleriyle çalışırken en küçük eğitim hatasına ve en küçük ağırlık normuna ulaşma eğiliminde olması, bu yöntemin tercih edilmesinin temel nedenlerinden biridir. Ayrıca, ELM'nin yapay sinir ağlarına kıyasla çok daha yüksek eğitim hızına sahip olması, büyük veri setleriyle yapılan tahminlerde önemli bir avantaj sağlamaktadır.

ELM algoritmasının yapısal gösterimi Şekil 5.3'te sunulmuştur. Bu yapı, ELM'nin regresyon modelinde giriş katmanı, gizli katman ve çıkış katmanı arasındaki ilişkiyi görsel olarak açıklamaktadır.




Şekil 5.3 ELM'nin regresyon yapısı

5.3 Bayes Regresyon

Bayes regresyonu, veriler hakkında daha kesin tahminler oluşturmak için önceki bilgi veya fikirlerden yararlanan, olasılıksal bir regresyon yöntemidir. Bu yöntem, belirsizlik içeren veri yapılarında, verilerin karmaşıklığını modellemek ve daha doğru tahminler elde etmek için etkili bir araç olarak öne çıkmaktadır (Moe vd., 2021). Bayes regresyonu, özellikle belirsizliklerin yüksek olduğu durumlarda, geleneksel doğrusal regresyon yöntemlerine kıyasla daha esnek ve açıklayıcı sonuçlar sunar.

Bayes regresyonu, doğrusal bir regresyon modelinin parametrelerini, parametreler hakkındaki ön bilgiler de dahil olmak üzere verilerden tahmin etmek için bir Bayes algoritması kullanır. Bayes ağı, düğümlerden ve düğümler arasındaki bir grup koşullu olasılık tablosundan oluşan yönlendirilmiş çevrim olmayan bir graftır. Çizge modeli temel olarak iki bölümden oluşur: düğümlerin ağ topolojisi ve düğümlerin koşullu olasılık tablosudur (Jones vd., 2016). Bayes algoritmasının çalışma prensibi Şekil 5.4'te gösterilmiştir. Bayes regresyonu, model seçimi ve aykırı değer tespiti gibi ilgili regresyon analizi görevleri için de kullanılabilir.



Şekil 5.4 Bayesian regresyon algoritmasının çalışma prensibi

Bayes regresyonu, temelinde bir modele ait parametrelerin belirlenmesinde Bayes istatistiklerini kullanan doğrusal özellikli bir regresyon algoritmasıdır. Gözlemlenen veriler ele alındığında bir dizi parametrenin olasılığını tahmin etmek için Bayes teoremi kullanılmaktadır. Bayes regresyonunun amacı, bağımsız ve bağımlı değişkenler arasındaki ilişkiyi tanımlayan doğrusal bir modelin parametrelerinin en iyi tahminini belirlemektir.

Bayes regresyonunda, Y bağımlı bir hedef değişken ve $X_1, \dots, X_m$ bağımsız değişkenler olmak üzere veri seti şu şekilde ifade edilebilir.

$$(y_i, x_{1,i}, \dots, x_{m,i}) \quad (i = 1, \dots, T) \quad (5.4)$$

Burada y_i hedef değer ve $x_{j,i}$ i . gözlemdeki X_j eş değişkeninin değeri, T ise veri setindeki toplam gözlem sayısıdır.

Bayes doğrusal regresyon modeli, bağımlı değişken ile bağımsız değişkenler arasındaki ilişkiyi şu şekilde tanımlar:

$$y_i = \beta_0 + \beta_1 \cdot x_{1,i} + \dots + \beta_m \cdot x_{m,i} + v_i \quad (i = 1, \dots, T) \quad (5.5)$$

burada $\beta_0, \dots, \beta_m$ bilinmeyen regresyon katsayısı parametreleri ve v_i hedef değer ile i gözlemindeki ortak değişken değerlerinin doğrusal kombinasyonu arasındaki açıklanamayan kalıntı veya uyumsuzluktur. $v_1, \dots, v_T$, tipik olarak Gauss dağılımını takip

ettiği varsayılan rastgele bir gürültü değişkeninin gerçekleştirmeleri olarak kabul edilmektedir.


Geleneksel doğrusal regresyonlar ile Bayesian regresyon arasındaki temel farklılık, veri hazırlama işlemine ilişkin gerçekleştirilen temel varsayımdır. Geleneksel doğrusal regresyon algoritmaları, verilerin Gauss veya normal dağılım izlediğini varsayarken, Bayesian regresyon verilerin doğası hakkında daha güçlü varsayımlara sahiptir ve parametrelere bir ön olasılık dağılımı ortaya koymaktadır (S. Nie vd., 2018). Bayes regresyonu ayrıca ek parametrelere veya önceki dağılımlara izin verdiği için daha fazla esneklik sağlar ve verilerle ilgili önceki bilgileri açıkça ifade eden karmaşık bir model oluşturmak için kullanılabilir. Ayrıca, Bayes regresyonu daha az veri noktasından daha doğru tahmin ölçümleri sağlar ve tahminlerin etrafındaki belirsizlik için tahminler oluşturabilir. Öte yandan, geleneksel doğrusal regresyonların uygulanması daha kolaydır ve genellikle daha basit modellerle daha hızlıdır ve verilerle ilgili varsayımlar geçerli olduğunda iyi sonuçlar sağlayabilmektedir. Bayes Regresyonu, veri setinde yetersiz veri olduğunda veya veriler kötü dağıldığında daha faydalı olabilmektedir (L. Wang vd., 2017)

Bayes regresyonu, dalga boyu yüksekliği tahmini gibi karmaşık ve belirsizlik içeren sistemlerde avantajlı bir yapıya sahiptir. Özellikle belirsizliklerin ve değişkenlerin etkilerini daha esnek bir şekilde modelleme yeteneğine sahip olması Bayes yaklaşımının tercih edilmesi için güçlü bir sebep olarak ele alınabilir. Bayes regresyonu, belirsizliğin olduğu ve önceden bir bilgi (prior) kullanılabileceği durumlarda daha esnek ve açıklayıcı sonuçlar vermektedir. Ayrıca, elde edilen sonuçları olasılıksal dağılımlar olarak sunabilmekte ve tahminlerin doğruluk aralıklarını belirtebilmektedir. Bayes regresyonun sahip olduğu avantajlar ve olasılıksal olarak regresyon yapması sebebiyle tez çalışmasında dalga boyu yüksekliğinin tahmini için şamandıralardan alınan veri seti ile regresyon modeli eğitimi gerçekleştirilmiştir.

5.4 Uzun-Kısa Süreli Bellek (LSTM)

Uzun Kısa Süreli Bellek (LSTM), özellikle zaman serisi verilerindeki uzun vadeli bağımlılıkları modellemek için tasarlanmış bir tür Tekrarlayan Sinir Ağı mimarisidir. RNN'lerin temel avantajlarından biri, önceki bilgileri mevcut görevlere bağlayabilme yeteneğidir (Graves, 2012).

LSTM, bu zorluğun üstesinden gelmek için geliştirilmiştir (S. Hochreiter & J. Schmidhuber, 1997). LSTM ağları, uzun vadeli bağımlılıkları öğrenme yetenekleri sayesinde, geçmişteki bilgileri uzun zaman dilimleri boyunca hatırlayabilir ve bu bilgileri gelecekteki tahminler için kullanabilir. Bu özellik, dalga yüksekliği gibi dinamik ve zamana bağlı süreçlerde LSTM'yi etkili bir yöntem haline getirmektedir. LSTM, standart RNN'lerden farklı olarak, hücre durumu ve bir dizi kapı mekanizması içerir. Hücre durumu, bilgiyi bir zincir boyunca taşıyan bir "taşıma otoyolu" gibi çalışır ve yalnızca gerekli bilgilerin hücre durumuna eklenmesini veya çıkarılmasını sağlar. LSTM'nin temel yapısı Şekil 5.5'te gösterilmiştir.



Şekil 5.5 LSTM hücresinin yapısı


Üstteki yatay çizgi hücre durumudur. Bu modelin anahtarıdır. Hücre durumu, göreceli bilgiyi dizi zincirinden aşağı aktaran bir taşıma otoyolu görevi görür (Aljohani vd., 2024). Bu, uzun süreli hafızayı uzun zaman dizileri boyunca taşımalarını sağlayan şeydir. Bu, uzun dönemli bağımlılıklarla ve ayrıca bu modelin temel motivasyonlarından biri olan kaybolan ve patlayan gradyan problemleriyle daha iyi başa çıkmasına izin vermektedir. Ancak yine de patlayan gradyanla ilgili sorunlarla karşılaşabilir. Hücre durumunda zaman içinde sadece küçük değişiklikler yapılır, bu nedenle çok gerideki zaman noktalarından gelen hafıza neredeyse hiç değişmeden geçebilir. Yapılan değişiklikler, bilginin eklendiği ya da çıkarıldığı 8 kapı aracılığıyla gerçekleştirilir. Kapılar, hangi bilginin ilgili olduğuna ve hücre durumuna aktarılması gerektiğine ve hangisinin olmadığına karar veren farklı sinir ağları olarak görülebilir.

LSTM algoritmasında hücreden hangi bilginin atılacağına karar verilmesidir. Bu karar “unutma kapısı katmanı” (forget gate) adı verilen bir sigmoid katman tarafından

belirlenmektedir. Bu katman h_{t-1} ve x_t 'ye bakar ve C_{t-1} hücre durumundaki her sayı için 0 ile 1 arasında bir değer üretilmektedir. Sigmoid fonksiyonun sonucunda “1” elde edilmesi bilginin korunması gerektiğini, “0” elde edilmesi bilginin unutulması gerektiği anlamına gelmektedir (Mohan & Gaitonde, 2018). Unutma kapısına ait fonksiyon;

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (5.6)$$

Olarak tanımlanmaktadır. LSTM yapısında unutma kapısının konumu Şekil 5.6’da gösterilmiştir.




Şekil 5.6 Unutma (forgot) kapısının akış şeması

Hücre durumunda hangi yeni bilgilerin saklanılacağına karar verilmektedir. Bu işlem için iki bölüm bulunmaktadır. İlk olarak, “giriş kapısı katmanı” (input gate) adı verilen bir sigmoid katmanı hangi değerlerin güncelleneceğine karar vermektedir. Daha sonra, bir tanh katmanı, duruma eklenebilecek yeni aday bilgilerin bir vektörünü C_t oluşturmaktadır. Son kısımda, bu iki bilgiyi birleştirerek duruma bir güncelleme gerçekleştirilmektedir. Güncelleme aşamasında kullanılan formüller:

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (5.7)$$

$$C_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (5.8)$$

Olarak tanımlanmaktadır. Bilgi güncellemesine dair işlemlerin LSTM yapısındaki konumları Şekil 5.7’de gösterilmiştir.




Şekil 5.7 Bilgi güncelleme işleminin akış şeması

Önceki hücreden eski durum olan C_{t-1} yeni hücre durumu olan C_t 'ye güncellenmektedir. Hücre içerisinde bilgilerin unutulup unutulmaması ve güncelleme durumları karar verilmiştir. Unutulması planlanan bilgiler için eski hücre durumu f_t ile çarpılmaktadır. Çarpım sonucu ile bilgi güncelleme parametrelerinin $i_t \times \tilde{C}_t$ çarpımları toplanarak hücrenin yeni çıktı bilgisi elde edilmektedir. Yeni hücre bilgisi:

$$C_t = f_t \times C_{t-1} + i_t \times \tilde{C}_t \quad (5.9)$$

Olarak hesaplanmaktadır. Yeni hücre bilgisinin hesaplanmasına ait işlemlerin LSTM yapısındaki konumları Şekil 5.8'de gösterilmiştir.



Şekil 5.8 Yeni hücre bilgisinin oluşturulmasına ait akış şeması


Son olarak, hücrenin çıktı bilgisinin hesaplanmasıdır. Çıktı bilgisi hücre durumuna bağlı olarak hesaplanır ancak değerler normalize edilerek çıktı olarak verilmektedir. İlk olarak, hücre durumunun hangi kısımlarının çıktısının alınacağına karar veren bir sigmoid katmanı bulunmaktadır. Ardından, hücre durumunu $\tanh$ 'tan geçirilip (değerleri -1 ile 1 arasında olması için) sigmoid fonksiyonun çıktısıyla çarpılmaktadır. Böylece yalnızca

hücre içerisinde karar verilen kısımların çıktısı alınmaktadır. Hücreden elde edilen çıktı bilgisi:

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (5.10)$$

$$h_t = o_t \cdot \tanh(C_t) \quad (5.11)$$

olarak hesaplanmaktadır. Çıktı bilgisinin hesaplanmasına ait işlemlerin LSTM yapısındaki konumları Şekil 5.9’da gösterilmiştir.




Şekil 5.9 Çıktı değerlerinin hesaplanmasına ait akış şeması

LSTM, zaman serisi verilerinin ardışık bağımlılıklarını modellemek için tasarlanmış özel bir yapıya sahip olması sayesinde dalga boyu yüksekliği tahmini gibi dinamik ve karmaşık sistemlerde etkili sonuçlar vermektedir. Geçmişteki verilerle gelecekteki dalga yüksekliğini tahmin ederken uzun vadeli bağımlılıkları (long-term dependencies) başarılı bir şekilde yakalayabilmektedir. Bu özelliği sayesinde rüzgar hızı, su sıcaklığı, rüzgar yönü, su seviyesi ve diğer çevresel faktörlerin dalga üzerindeki etkilerini öğrenmede faydalıdır. Denizdeki dalga hareketlerinin mevsimsel değişiklikleri gibi uzun vadeli etkilerini yakalamak etkili bir yöntemdir. Tez çalışmasında LSTM kullanmanın en önemli avantajı, dalga yüksekliği gibi zamana dayalı ve dinamik süreçlerde uzun vadeli bağımlılıkları ve karmaşık ilişkileri öğrenme kapasitesidir. LSTM, şamandıradan alınan verilerdeki değişkenleri ve bu değişkenlerin dalgalar üzerindeki etkilerini anlamada başarılı ve kapasitesi yüksektir. Diğer yöntemler kısa vadeli tahminlerde iyi olabilirken, LSTM, dalgaların uzun vadeli davranışlarını modelleyebilir ve belirsiz çevresel faktörlere karşı daha dayanıklı tahminler sunabilmektedir.


5.5 Tekrarlayan Sinir Ağı (RNN)

Tekrarlayan Sinir Ağları (RNN), özellikle zaman serileri gibi sıralı verilerin işlenmesi için tasarlanmış bir yapay sinir ağı türüdür. RNN'ler, önceki adımlardan elde edilen bilgiyi saklayarak, geçmiş verilerle gelecekteki tahminler arasında bağlantı kurabilir. Bu özellik, zamana bağlı bağımlılıkların olduğu durumlarda RNN'leri etkili bir araç haline getirir (Bianchi vd., 2017). İleri beslemeli sinir ağları (MLP) da zaman serilerini modellemek için kullanılabilir; ancak, MLP'lerin sabit giriş ve çıkış düğümleri nedeniyle zaman serisi verilerinde RNN kadar esnek ve doğru olmadığı bilinmektedir. RNN'ler, bir dizinin veya zaman serisinin uzunluğuna dinamik olarak uyum sağlayarak, zaman serisi modelleme sorunlarını çözmek için daha uygun bir yaklaşım sunar (Tsoi, 1998). Bu durum, ilgilenilen zamansal bağımlılıklar seçilen girdi sayısını aştığında, zaman serisi modellemesinde sorun yaratabilmektedir. RNN ile ileri beslemeli sinir ağları arasındaki temel farklılık Şekil 5.10'da gösterilmiştir. Burada siyah renkli oklar sadece ileri beslemeli sinir ağları için geçerli akış şemasını gösterirken, RNN yapıları gereği ileri beslemeli sinir ağının akış şemasına ek olarak kırmızı renkli bağlantıları da içeren bir yapısı bulunmaktadır.



Şekil 5.10 İleri beslemeli sinir ağı ve RNN arasındaki yapısal farklılık

Tekrarlayan sinir ağları daha esnek bir yaklaşım sağlamaktadır. Tekrarlayan bağlantılar sayesinde, önceki sonuçlardan bir sonrakine bağımlılıklar yaratabilmektedir. Bu bağlantılar bilginin döngüye girmesini sağlar ve zaman serilerinde veya diğer sıralı verilerde altta yatan zamansal bağımlılıklar tespit edilebilmektedir. Bir zaman adımının sonuçları gizli bir durum değişkeni h_t 'de hafızaya alınarak kalmaktadır. Böylece T uzunluğundaki bir dizinin veya zaman serisinin her bir t adımı aynı şekilde işlenmekte ve saklanmaktadır (Mahdavi-Meymand & Sulisz, 2023). RNN yapısında bilginin sonraki hücreye taşınmasının akış şeması Şekil 5.11'de gösterilmiştir.



Şekil 5.11 RNN algoritmasının yapısal döngüsü

RNN, sıralı veriler üzerinde çalışan ve geçmiş bilgiyi gelecekteki tahminlerde kullanma yeteneğine sahip bir yapay sinir ağı türüdür. Dalga boyu yüksekliği gibi zaman serisi verilerinde geçmişteki veriler geleceği tahmin etmek için kritik olduğundan, RNN'ler bu tür problemlerde etkili olarak kullanılmaktadır. Geçmiş dalga verilerini öğrenip bunları gelecekteki tahminler için kullanabilen bir yapıya sahiptir. Dalga boyu yüksekliği, geçmişteki dalga dinamiklerinden etkilendiği için bu bağımlılıkları yakalayabilmektedir. Daha karmaşık modellere göre daha basit bir yapıya sahiptir ve daha hızlı eğitilebilmektedir (Y. Bai, vd., 2021). RNN algoritması sahip olduğu özellikler göz önüne alınarak tez çalışmasında dalga boyu yüksekliğinin tahmini için şamandıra verileri ile eğitilerek regresyon modeli hazırlanmıştır.

5.6 Destek Vektör Makinesi (SVM)


Destek vektör makinesi (SVM) kavramı Vapnik ve çalışma arkadaşları tarafından geliştirilmiştir (Vapnik, 1995). SVM, verilen bir eğitim setini doğru bir şekilde ayırmak için hiper düzlem kullanan bir regresyon ve sınıflandırma algoritmasıdır. Her iki tarafta da hiper düzleme en yakın veri noktalarından mümkün olduğunca en fazla mesafe bırakılarak orijinal girdi uzayında bir hiper düzlem bulmaya çalışan bir optimizasyon gerçekleştirilmektedir. SVM regresyon tahmininde kullanılırken maksimum farkı gerçekleştiren veri noktalarına destek vektörleri adı verilmektedir. Başka bir deyişle, yaklaşım hataları SVM'nin tüp boyutu olarak adlandırılan boyuta eşit veya daha büyük olan veri noktalarıdır. Eğitim seti doğrusal bir dağılıma sahip değilse, doğrusal olmayan bir sınır oluşturulmaktadır. Doğrusal olmayan sınırı elde etmek için orijinal girdi uzayı, özellik uzayı adı verilen daha yüksek boyutlu bir uzaya eşlenmektedir. Özellik uzayı daha sonra aynı özellik uzayındaki örnekleri ayırabilecek bir hiper düzlem için aranmaktadır. Girdi uzayından özellik uzayına eşleme bir çekirdek fonksiyonu ile

tanımlanmaktadır. Teknik, optimizasyon modeline bir ceza faktörü (C) ekleyerek yanlış sınıflandırmaya da izin verir ve toplam ceza, her bir yanlış tahmin üzerindeki cezaların toplanmasıyla bulunmaktadır. Bu nedenle teknik, marjın ve toplam cezanın karşılıklı toplamını en aza indiren bir hiper düzlem bulunmaktadır. Birleştirilmiş ceza fonksiyonu, optimizasyon modelinde amaç fonksiyonu olarak belirtilmektedir (Dash vd., 2023).

Vapnik tarafından önerilen ε -duyarsız kayıp fonksiyonunu kullanan SVM algoritması ε 'den büyük olmayan hatalara tolerans derecesi sağlamaktadır. Tanım Smola ve Schölkopf (Smola & Schölkopf, 2004) ve Müller ve diğerlerinde (Müller vd., 1998) kullanılan terminolojiye dayanmaktadır. DVR algoritması, başlangıçtaki girdi uzayındaki orijinal veri noktalarına, genellikle daha yüksek boyutlu bir özellik uzayına (F) bir Φ dönüşüm fonksiyonu uygulanır. Bu yeni uzayda, orijinal uzaydaki doğrusal olmayan bir modele karşılık gelen doğrusal bir model oluşturulur:

$$\left. \begin{aligned} \Phi : R^n &\rightarrow F, w \in F \\ f(x) &= \langle w, \Phi(x) \rangle + b \end{aligned} \right\} \quad (5.12)$$

ε 'ye duyarsız kayıp fonksiyonunu kullanırken amaç, mevcut eğitim verilerini ε 'ye eşit veya daha az bir sapma ile filtreleyen ve aynı zamanda mümkün olduğunca flat olan bir fonksiyon bulmaktır. Bu, $\|w\|^2$ normunu minimize ederek küçük bir ağırlık vektörü w aramak anlamına gelmektedir. Destek vektör makinesinin verileri ayrıştırma için kullanılan düzlemler Şekil 5.12'de gösterilmiştir.



Şekil 5.12 Destek vektör makinesinin çalışma prensibi


Dalga boyu yüksekliği, rüzgar hızı, su seviyesi ve hava basıncı gibi birçok faktöre bağlı karmaşık ve doğrusal olmayan bir süreçtir. SVM, doğrusal olmayan çekirdek

fonksiyonları (kernel functions) kullanarak bu karmaşık ilişkileri öğrenebilmektedir. Özellikle RBF (Radial Basis Function) çekirdeği, veriler arasındaki karmaşık ilişkileri iyi modelleyebilir ve dalga boyu yüksekliğinin tahmin edilmesinde yüksek doğruluk sağlayabilmektedir. Doğrusal olmayan dinamikleri yüksek doğrulukla tahmin edebilir ve belirli sınırlar içinde tahmin yapmaktadır. Dalga yüksekliği gibi dinamik olayların tahmininde, modelin sınırları aşırı tahmin yapmasına izin vermemek önem arz etmektedir. SVM'in sağladığı esneklik ve doğruluk dengesi bu tür tahminlerde avantajlıdır. Birçok bağımsız değişkenin (rüzgar hızı, hava basıncı, su sıcaklığı, vb.) olduğu durumlarda başarılı sonuçlar verebilmektedir. Dalga yüksekliği tahmininde birçok farklı parametreyi aynı anda değerlendirilmesi gerektiğinde, SVM bu değişkenlerin etkilerini etkili bir şekilde öğrenebilmektedir. Bunun yanı sıra çok iyi genelleme yeteneğine sahiptir. Bu, eğitim verisine çok fazla uyum sağlamadan yeni ve görülmemiş verilerle gelecek verilerin doğru şekilde tahmin edilmesi anlamına gelir. SVM, sahip özellikler göz önüne alındığı zaman dalga boyu yüksekliğinin tahmini için uygun bir algoritma olduğu düşünülmüştür. Tez çalışmasında şamandıralardan alınan veriler SVM algoritması ile eğitilerek regresyon modeli hazırlanmıştır.

5.7 Artık Sinir Ağı (ResNet)

Bu çalışmada, derin öğrenme tabanlı bir mimari olan Residual Network (ResNet) kullanılarak regresyon işlemi gerçekleştirilmiştir. ResNet, derin sinir ağlarının eğitim sürecinde karşılaşılan gradyan kaybolması (vanishing gradient) sorununu çözmek için geliştirilmiştir (He vd., 2016). Geleneksel derin ağlar, katman sayısı arttıkça performansın düşmesi gibi bir problemle karşılaşırken, ResNet mimarisi bu sorunu "residual bağlantılar" (ya da atlama bağlantıları) ile aşarak, daha derin ağların verimli bir şekilde eğitilmesini sağlamaktadır. ResNet algoritmasındaki atlama bağlantıları Şekil 5.13'te gösterilmiştir.

ResNet'in ana fikri, her iki veya üç katmanda bir, girdinin çıktıya doğrudan eklenmesini sağlayan bir kısa yol bağlantısı oluşturmaktır. Bu residual bağlantılar, ağın hata fonksiyonunun gradyanının ağ boyunca verimli bir şekilde yayılmasına olanak tanıyarak, daha derin yapıların öğrenilebilirliğini artırmaktadır. Bu özellik sayesinde, daha derin mimariler oluşturulabilir ve büyük veri setleriyle yapılan eğitim süreçlerinde daha hassas ve doğru sonuçlar elde edilebilir (Ghafoorian vd., 2017).



Şekil 5.13 Res-Net algoritmasının yapısı

ResNet'in regresyon problemlerinde kullanılması, özellikle büyük veri setlerinde ve karmaşık fonksiyon ilişkilerinin öğrenilmesinde etkin sonuçlar vermektedir. Regresyon problemlerinde, modelin son katmanı, sürekli değerler üreten bir çıkış katmanı ile değiştirilerek uygulanmaktadır (Bodhwani vd., 2019).

ResNet, derin öğrenme modellerinde katmanlar arasındaki bilgi akışını iyileştiren ve derin ağların eğitiminde sık karşılaşılan problemlerin üstesinden gelen bir mimaridir. Başlangıçta görüntü işleme için geliştirilmiş olsa da, regresyon ve zaman serisi tahminlerinde de başarılı bir şekilde kullanılabilir. ResNet, çok derin sinir ağlarını eğitme kabiliyeti sayesinde, dalga yüksekliği gibi karmaşık ve doğrusal olmayan ilişkileri başarılı bir şekilde öğrenebilmektedir.

Dalga yüksekliği, birçok çevresel faktörle (örneğin, rüzgar hızı, su sıcaklığı, hava basıncı vb.) etkileşim halindedir ve bu faktörler arasındaki karmaşık ilişkileri öğrenmek için derin ağlar gereklidir. ResNet, bu tür karmaşık yapıları etkili bir şekilde modelleyebilmektedir. ResNet'in en önemli özelliklerinden biri, artık bağlantılar (residual connections) kullanarak derin ağların eğitimini kolaylaştırmasıdır. Bu bağlantılar, ağın katmanlar arasında bilgiyi atlayarak daha derin yapılar kurmasına olanak tanımaktadır.

Dalga yüksekliği tahmininde, çok sayıda katman kullanılarak daha doğru tahminler yapılabilir ve bu yapı daha hızlı öğrenme sağlamaktadır. Dalga yüksekliği tahmininde, önceki zamanlardaki bilgilerin etkisi büyüktür. ResNet, artık bağlantıları sayesinde derin öğrenme yaparak bu uzun vadeli bağımlılıkları etkili bir şekilde öğrenebilmektedir.

ResNet kullanarak, derin öğrenme modellerinin sağladığı güçlü genelleme ve karmaşık veri analiz yeteneklerinden yararlanılmakta ve dalga yüksekliği tahmini gibi zorlayıcı bir

problem etkili bir şekilde çözülebilmektedir. Özellikle çoklu değişkenlerle çalışıldığında ve derin modellerin sunduğu esneklik ve doğruluğa ihtiyaç duyulduğunda, ResNet iyi bir regresyon modeli olarak tanımlanmaktadır.

Bu özellikler göz önüne alındığında, tez çalışmasında şamandıra verileri kullanarak ResNet algoritması ile bir regresyon modeli eğitilmiştir.


5.8 Yığınlama Algoritmaları (Stacking Algorithm)

Yığınlama algoritmaları, birden fazla temel modelden elde edilen çıktıları birleştirerek yeni bir topluluk modeli oluşturmak için kullanılan etkili bir makine öğrenmesi yöntemidir. Bu yöntem, çeşitli makine öğrenimi görevlerinde doğruluğu artırmak amacıyla yaygın olarak kullanılmaktadır. Yığınlama yaklaşımında, birden fazla modelin çıktıları entegre edilerek, tahmin performansı önemli ölçüde artırılabilir.

Bu çalışmada kullanılan yığınlama algoritmaları, yığınlama modelleri olarak ifade edilmektedir. Yığınlama yaklaşımında, orijinal veri kümesi, ilk katmandaki her bir temel regresyon modeline girdi olarak sağlanan ve k-kat çapraz doğrulama ile tahmin edilen birkaç alt veri kümesine bölünmektedir. İlk katmandaki temel modellerin her birinin tahmin çıktıları, meta-model olarak bilinen ikinci katman regresyon modelinin giriş verileri olarak kullanılmaktadır.

Meta-model, temel regresyon modellerinin tahmin sonuçlarını ağırlıklandırarak, nihai tahmin sonuçlarını oluşturur (Hajihosseini vd., 2024; Meharie vd., 2022). Bu yaklaşım, birden fazla modelin güçlü yönlerini birleştirerek genel tahmin performansını artırmayı hedeflemektedir.

Yığınlama modelinin tahmin sonuçları, temel modellerin performansına bağlıdır. Ancak, seçilen temel modellerin sayısı hesaplama süresini doğrudan etkileyebilmektedir. Bu nedenle, bu çalışmada yığınlama yaklaşımı için temel modeller seçilirken hem performans hem de hesaplama süresi dikkate alınmıştır. Yığınlama algoritmasının genel akış şeması Şekil 5.14'te gösterilmiştir.




Şekil 5.14 Yığınlama yaklaşımı ile regresyon işleminin akış şeması

XGB (Extreme Gradient Boosting) algoritması, bir ağaç topluluğu oluşturmak için gradyan inişi yöntemini kullanır (Massaoudi vd., 2021). XGB, Gradyan Artırma Makinesi (GBM) ile benzer bir mantıkla çalışsa da bazı önemli avantajlara sahiptir. En belirgin fark, XGB'nin aşırı uyumu azaltmak için daha düzenli bir model oluşturma stratejisi kullanmasıdır. Özellikle, XGB, regresyon ağaçları için atlama (dropout) düzenlemesi uygulamaktadır (Vinayak & Gilad-Bachrach, 2015). Bu düzenleme, XGB'nin daha iyi genelleme yapmasını, düşük hata ve düşük varyansa sahip olmasını sağlamaktadır. Temel çalışma ilkesi ise model hatalarının minimize etmek için kayıp fonksiyonunun ikinci türevi göre bir adım boyutu hesaplamasıdır.

XGB'nin Eğilim Artırma Makinesine (GBM) göre diğer avantajları arasında ölçeklenebilirlik ve verimlilik öne çıkmaktadır. XGB, aralıklı matrisleri seyrekliğe duyarlı algoritmalar ile işleyebilir. Ayrıca, daha iyi işlemci önbellek kullanımı için optimize edilmiş veri yapıları kullanır ve çok çekirdekli paralel işleme desteği sunar. GPU hızlandırıcı kullanıldığında, XGB'nin hesaplama süresi önemli ölçüde azalır. Bir GBM

modelini eğitmek için gereken süre, bir XGB modelinin eğitimi için gereken sürenin en az 10 katıdır (Kulkarni vd., 2022).

Bu tez çalışmasında, XGB algoritması, diğer regresyon modelleriyle doğrudan entegre edilmek yerine, yığınlama yaklaşımı çerçevesinde bir meta-model olarak kullanılmıştır. XGB, temel regresyon modellerinin (LSTM, ELM, SVM, ResNet, Bayesian ve RNN) tahmin çıktıları üzerinde çalışarak genel tahmin modelinin performansını artırmıştır. XGB algoritmasının genel akış şeması Şekil 5.15'te gösterilmiştir.



Şekil 5.15 XGBoost algoritmasının akış şeması

XGB'nin yığınlama yaklaşımı çerçevesindeki rolü şu şekildedir:

Temel Modellerin Güçlü Yönlerinden Yararlanma: Her bir temel modelin güçlü yönlerini birleştirerek daha yüksek doğruluk sağlanmıştır.

Hataların Minimize Edilmesi: Temel modellerin tahmin hataları XGB ile optimize edilmiştir.

Doğrusal ve Doğrusal Olmayan Modellerin Birleşimi: Hem doğrusal hem de doğrusal olmayan regresyon modelleri, XGB sayesinde aynı yapıda birleştirilmiştir.

XGB algoritmasının sağlamış olduğu avantajlar sayesinde, dalga boyu yüksekliği tahmini etkili bir şekilde gerçekleştirilmiştir. XGB, hiper-parametre optimizasyonu ile performansı artırabilecek esnek bir yapıya sahiptir. Bu tezde, farklı hiper-parametre ayarları ile tahmin modelleri değerlendirilmiş ve en uygun parametreler belirlenmiştir.

5.9 Metrik Değerlendirme Parametreleri

Tahmin modellerinin doğruluğunu değerlendirmek için dört farklı metrik kullanılmıştır: Korelasyon Katsayısı (R^2), Kök Ortalama Kare Hatası (RMSE), Ortalama Mutlak Hata (MAE) ve Ortalama Kare Hatası (MSE). Bu metrikler, tahmin edilen ve gerçek değerler arasındaki uyumu ve hata oranlarını ölçmek için yaygın olarak kullanılan yöntemlerdir.

R^2 katsayısı, modelin uyum iyiliğini değerlendiren bir ölçüttür ve $[0, 1]$ aralığında değerler alır. R^2 değeri 1'e ne kadar yakınsa, modelin tahminleri o kadar doğrudur. Formülü aşağıdaki gibi tanımlanmaktadır.

$$R^2 = \left(1 - \frac{\sum_t (f_t - y_t)^2}{\sum_t (y_a + y_t)^2}\right) \quad (5.13)$$

Burada, f_t tahmin değeri, y_t test değeri ve y_a test değerlerinin ortalamasıdır.

RMSE, deneysel noktaların regresyon çizgisine olan uzaklığını ölçen ve artıklar olarak adlandırılan tahmin hatalarının standart sapmasıdır. RMSE değeri ne düşük olarak hesaplanırsa tahmin performansı yüksek anlamına gelir. Uygulamada RMSE, verilerin en iyi uyum çizgisi etrafındaki dağılımını ölçer ve Denklem (5.14)'te formülü verilmiştir.

$$RMSE = \sqrt{\frac{\sum_t (f_t - y_t)^2}{N}} \quad (5.14)$$

Burada N tahmin edilen değer sayısıdır.

MAE, yönlerini dikkate almadan, bir bütün olarak tahminlerdeki hataların ortalama büyüklüğünü tahmin eder ve Denklem (5.15)'de formülü verilmiştir. MAE değerinin 0'a yakın olması tahminin doğruluğunu temsil etmektedir.

$$MAE = \frac{\sum_t |f_t - y_t|}{N} \quad (5.15)$$

MSE, bir tahmin edici için hataların karelerinin ortalamasını ölçen istatistiksel bir metriktir ve Denklem (5.16)'da formülü verilmiştir. RMSE ile orantılı olarak değişkenlik göstermektedir ve benzer şekilde değer düştükçe tahmin performansı artar.

$$MSE = \frac{\sum_t (f_t - y_t)^2}{N} \quad (5.16)$$

5.10 Sistem Tasarımı


Dalga enerjisi dönüşüm sistemlerinin geliştirilmesinde, elektrik üretimindeki düzensiz karakteristiği gidermek amacıyla farklı yapay zeka algoritmaları (makine öğrenmesi, derin öğrenme vb.) kullanılmaktadır. Derin öğrenme yöntemleri, yalnızca doğrusal korelasyonlar için değil, aynı zamanda doğrusal olmayan dinamik tahmin ve korelasyon süreçleri için de uygun bir yaklaşım sunarak yenilenebilir enerji alanında önemli bir rol oynamaktadır. Deniz enerjisinin kullanımının artmasıyla birlikte, dalga enerjisi, kontrol, davranış keşfi, hareket takibi, kararlılık ve üretim büyümesi gibi alanlarda çeşitli olasılıklar sağlayarak giderek daha önemli bir enerji kaynağı haline gelmiştir.

Deniz şamandıralarından ölçülen veriler kullanılarak dalga yüksekliği tahmini yapan modeller geliştirilmiştir. Bu modeller, dalga enerjisinden üretilecek potansiyel elektrik gücünün tahmin edilmesine olanak tanımaktadır. Üretilecek enerji tahminine göre, enerji dalgalanmalarının önüne geçilerek şebekeye güvenli bir şekilde enerji sağlanması hedeflenmiştir.

Bu tez çalışmasında, Samsun ve Ordu şamandıralarından elde edilen veriler kullanılarak, dalga yüksekliği ve periyodu tahminlerinin enerji potansiyeline dönüştürülmesi amaçlanmıştır. Ayrıca, farklı regresyon modellerinin performanslarının XGB algoritması ile yığınlama yaklaşımı çerçevesinde iyileştirilmesi hedeflenmiştir.

Tez çalışmasında, dalga gücü tahmini için Meteoroloji Genel Müdürlüğü'nden Karadeniz bölgesindeki Samsun ve Ordu şamandıralarından 2023 yılına ait 1 yıllık veri seti kullanılmıştır. Veri setinde 11 parametreye ait değerler bulunmaktadır. Farklı zaman aralıkları (1 saat, 3 saat, 6 saat, 12 saat, 24 saat ve 72 saat) için dalga gücü tahmini gerçekleştirilmiştir. Dalga gücü hesaplaması için dalga boyu yüksekliğini ve dalga periyodunu tahmin eden iki ayrı regresyon modeli geliştirilmiştir. Tahmin edilen dalga boyu yüksekliği ve periyodu kullanılarak potansiyel dalga gücü tahmini gerçekleştirilmiştir. Yöntem aşamasında LSTM, ELM, SVM, ResNet, Bayesian ve RNN algoritmaları kullanılarak temel regresyon modelleri kullanılmıştır. Temel regresyon modelleri MATLAB ortamında eğitilmiştir. Kullanılan regresyon modellerinin birbirlerine göre güçlü ve zayıf yönleri bulunmaktadır. Temel regresyon modellerinin performanslarını arttırmak için XGB algoritması ile yığınlama yaklaşımı uygulanmıştır.


Temel regresyon modellerinin çıktıları (tahmini) XGB algoritmasının girdi veri setini oluşturmaktadır. Regresyon modellerinin değerlendirme kriterleri olarak MAE, RMSE, MSE ve R^2 değerleri hesaplanmıştır. Kullanılan regresyon modellerinin birbirlerine göre güçlü ve zayıf yönleri bulunmaktadır. Güçlü ve zayıf yönlere bağlı olarak tahmin kısa süreli tahmin ve uzun süreli tahminlerde modellerde farklılık gözlemlenmiştir. XGB algoritması sonucunda bir meta-model regresyon modeli hazırlanmıştır. XGB modeli Python dilinde gerçekleştirilmiştir. Bu sayede farklı modellerin güçlü yanları bir araya getirilip zayıf yönleri minimize edilmiştir. Çalışma sonucundan meta-modelin metrik değerleri temel regresyon modellerinin metrik değerlerine göre daha iyi performans gösterdiğini ortaya koymuştur. Yığınlama yaklaşımı kullanılarak hazırlanan hibrit makine öğrenimi modeli sayesinde dalga gücünün tahmin performansı geliştirilmiştir. Çalışmanın akış şeması Şekil 5.16'da gösterilmiştir. Eğitilen modellerin dalga gücü tahmini, kısa süreli olarak sisteme verilen düzensiz karakteristik gösteren elektrik enerjisi miktarının öngörülerek sistemdeki enerjinin düzenlenmesini sağlayacağı düşünülmektedir. Aynı zamanda uzun süreli olarak dalga dönüşüm sisteminin kurulması planlanan bölgeden belirli periyottaki elektrik üretim kapasitesinin belirlenmesinde bilgi sağlayacaktır.




Şekil 5.16 Sistemin akış şeması

6. BULGULAR

Bu tez çalışmasında, dalga boyu yüksekliği tahmini için Meteoroloji Genel Müdürlüğü tarafından sağlanan Ordu açık deniz şamandırası verileri kullanılmıştır. Çalışmada, 2023 yılına ait bir yıllık veri seti değerlendirilmiş ve bu veri setinde 11 farklı parametreye ait toplam 23.183 veri noktası bulunmaktadır. Ordu şamandırasına ait 2023 yılı dalga boyu yüksekliği verilerinin örneklem sayısına göre dağılımı Şekil 6.1'de, dalga periyodu verilerinin örneklem sayısına göre dağılımı ise Şekil 6.2'de görselleştirilmiştir.




Şekil 6.1 Ordu şamandırasının 1 yıllık ölçülen dalga boyu yüksekliği değerleri




Şekil 6.2 Ordu şamandırasının 1 yıllık ölçülen dalga periyodu değerleri

Samsun açık deniz şamandırasından 2023 yılına ait 1 yıllık veri seti kullanılmıştır. Veri setinde 11 parametreye ait 15282 farklı veri seti bulunmaktadır. Samsun şamandırasının 2023 yılına ait 1 yıllık dalga boyu yüksekliği değerlerinin örneklem sayısına göre değerleri Şekil 6.3'te gösterilmiştir. Samsun şamandırasının 2023 yılına ait 1 yıllık dalga periyodu değerlerinin örneklem sayısına göre değerleri Şekil 6.4'te gösterilmiştir.



Şekil 6.3 Samsun şamandırasının 1 yıllık ölçülen dalga boyu yüksekliği değerleri



Şekil 6.4 Samsun şamandırasının 1 yıllık ölçülen dalga periyodu değerleri

Ordu şamandırasından alınan 11 farklı ölçüm, Akıntı Hızı 5 m (cm/s), Akıntı Hızı 10 m (cm/s), Akıntı Hızı 15 m (cm/s), Belirgin Dalga Yüksekliği (m), Maksimum Dalga

Yüksekliği (m), Pik Dalga Periyodu (sn), Ortalama Rüzgar Yönü (m/s) ve Maksimum Rüzgar Yönü (m/s) değerlerinin 1 yıllık girdi veri setindeki ortalama, standart sapma, minimum ve maksimum değerleri Tablo 6.1’de gösterilmiştir. Akıntı Hızı 5 m için $17,35 \pm 15,86$, Akıntı Hızı 10 m için $23,70 \pm 28,77$, Akıntı Hızı 15 m için $26,88 \pm 34,26$, Belirgin Dalga Yüksekliği için $0,62 \pm 0,40$, Maksimum Dalga Yüksekliği için $1,00 \pm 0,61$, Pik Dalga Periyodu için $2,98 \pm 0,38$, Deniz Suyu Sıcaklığı için $17,18 \pm 5,90$, Aktüel Basınç için $1015,86 \pm 6,06$, Denize İndirgenmiş Basınç için $1016,12 \pm 6,06$, Ortalama Rüzgar Yönü için $3,95 \pm 2,46$ ve Maksimum Rüzgar Yönü için $4,96 \pm 2,95$ olarak ortalama ve standart sapma değerleri hesaplanmıştır.

Tablo 6.1 Ordu şamandırasının ölçüm parametrelerinin ortalama, standart sapma, minimum ve maksimum değerleri

Ölçüm Parametresi	Ortalama	Std. Sapma	Min.	Max.
Akıntı hızı 5m (cm/san.)	17,35026	15,8672	0,1	383,9
Akıntı hızı 10m (cm/san.)	23,70388	28,77252	0,1	453,6
Akıntı hızı 15m (cm/san.)	26,88185	34,26088	0,1	387,2
Belirgin Dalga Yüksekliği (m)	0,62427	0,401684	0,01	3,65
Maks. Dalga Yüksekliği (m)	1,002865	0,61748	0,01	5,58
Pik Dalga Periyodu (sn)	2,981115	0,387211	1,9	4,9
Deniz Suyu Sıcaklığı (°C)	17,18893	5,905946	7,7	35,8
Aktüel Basınç (hPa)	1015,861	6,062908	1000,1	1036,6
Denize İndirgenmiş Basınç (hPa)	1016,124	6,066819	1000,3	1036,9
Ortalama Rüzgar Yönü (m/san)	3,953751	2,467034	0,6	15,7
Maksimum Rüzgar Yönü (m/san)	4,963413	2,957617	0,7	20,4

Samsun şamandırasından alınan 11 farklı ölçüm, Akıntı Hızı 5 m (cm/s), Akıntı Hızı 10 m (cm/s), Akıntı Hızı 15 m (cm/s), Belirgin Dalga Yüksekliği (m), Maksimum Dalga Yüksekliği (m), Pik Dalga Periyodu (sn), Ortalama Rüzgar Yönü (m/s) ve Maksimum

Rüzgar Yönü (m/s) değerlerinin 1 yıllık girdi veri setindeki ortalama, standart sapma, minimum ve maksimum değerleri Tablo 6.2’de gösterilmiştir. Akıntı Hızı 5 m için $17,34 \pm 19,15$, Akıntı Hızı 10 m için $18,35 \pm 18,40$, Akıntı Hızı 15 m için $18,98 \pm 18,69$, Belirgin Dalga Yüksekliği için $0,67 \pm 0,45$, Maksimum Dalga Yüksekliği için $1,10 \pm 0,72$, Pik Dalga Periyodu için $2,88 \pm 0,36$, Deniz Suyu Sıcaklığı için $15,97 \pm 6,24$, Aktüel Basınç için $1017,08 \pm 6,62$, Denize İndirgenmiş Basınç için $1017,37 \pm 6,63$, Ortalama Rüzgar Yönü için $5,25 \pm 2,93$ ve Maksimum Rüzgar Yönü için $6,39 \pm 3,48$ olarak ortalama ve standart sapma değerleri hesaplanmıştır.

Tablo 6.2 Samsun şamandırasının ölçüm parametrelerinin ortalama, standart sapma, minimum ve maksimum değerleri

Ölçüm Parametresi	Ortalama	Std. Sapma	Min.	Max.
Akıntı hızı 5m (cm/san.)	17,34091	19,15226	0,1	723,6
Akıntı hızı 10m (cm/san.)	18,35301	18,40436	0,1	686,2
Akıntı hızı 15m (cm/san.)	18,98239	18,69834	0,1	633,1
Belirgin Dalga Yüksekliği (m)	0,675079	0,459394	0,01	3,8
Maks. Dalga Yüksekliği (m)	1,105912	0,727934	0,01	5,96
Pik Dalga Periyodu (sn)	2,886031	0,368869	1,9	4,8
Deniz Suyu Sıcaklığı (°C)	15,97444	6,243396	7,6	35,3
Aktüel Basınç (hPa)	1017,084	6,62997	1000,1	1039,7
Denize İndirgenmiş Basınç (hPa)	1017,37	6,636431	1000,3	1039,9
Ortalama Rüzgar Yönü (m/san)	5,250988	2,939678	0,6	15,9
Maksimum Rüzgar Yönü (m/san)	6,390048	3,480062	0,8	20,9

Ordu şamandırasından alınan 11 farklı ölçümün kendi aralarındaki korelasyon davranışlarının incelenmesi için Spearman Korelasyon Testi kullanılmıştır. Spearman Korelasyon Testi sonuçları incelendiğinde, tüm faktörlerin "Belirgin Dalga Yüksekliği" ve "Pik Dalga Periyodu" parametreleri ile korelasyon içerisinde olduğu ($p < 0.01$)

gözlenmiştir. Spearman Korelasyon Testi sonucunda elde edilen r değerlerinin pozitif olması, ölçüm değerlerinin pozitif (doğru orantılı) yönlü korelasyonda olduğunu, negatif olması ise ölçüm değerlerinin negatif (ters orantılı) yönlü korelasyonda olduğunu göstermektedir. Belirgin Dalga Yüksekliği parametresinin diğer ölçüm değerleri ile korelasyonları incelendiğinde; Akıntı Hızı 10 m, Deniz Suyu Sıcaklığı, Aktüel Basınç, Denize İndirgenmiş Basınç ve Akıntı Hızı 10 m ölçümleri ile çok zayıf bir ilişki ($0 < r < 0.19$), Ortalama Rüzgar Yönü ile pozitif yönlü orta düzeyde bir ilişki ($0.40 < r < 0.59$), Pik Dalga Periyodu ve Maksimum Rüzgar Yönü ölçümleri ile pozitif yönlü iyi bir ilişki ($0.60 < r < 0.79$) olduğu gözlenmiştir. Ordu şamandırasına ait ölçüm değerlerinin birbirleri ile Pearson Korelasyon Testi sonucu Tablo 6.3'te gösterilmiştir.

Tablo 6.3 Ordu şamandırası ölçümlerinin Pearson korelasyon testi sonuçları

Parametre		V1	V2	V3	V4	V5	V6	V7	V8	V9	V10	V11
Akıntı hızı 5m	r	1	,521**	,402**	,024**	,027**	,037**	,029**	,079**	,079**	,059**	,059**
	p		0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000
Akıntı hızı 10m	r		1	,684**	-,019**	-0,013	,042**	,171**	,125**	,125**	0,009	0,008
	p			0,000	0,004	0,053	0,000	0,000	0,000	0,000	0,188	0,230
Akıntı hızı 15m	r			1	-,029**	-,023**	,039**	,237**	,128**	,128**	-0,010	-0,012
	p				0,000	0,001	0,000	0,000	0,000	0,000	0,116	0,073
Belirgin Dalga Yüksekliği	r				1	,997**	,727**	-,158**	,140**	,140**	,489**	,511**
	p					0,000	0,000	0,000	0,000	0,000	0,000	0,000
Max Dalga Yüksekliği	r					1	,701**	-,150**	,146**	,146**	,514**	,535**
	p						0,000	0,000	0,000	0,000	0,000	0,000
Pik Dalga Periyodu	r						1	-,228**	,153**	,154**	,103**	,128**
	p							0,000	0,000	0,000	0,000	0,000
Deniz suyu Sıcaklığı	r							1	-,346**	-,346**	-,051**	-,068**
	p								0,000	0,000	0,000	0,000
Aktüel Basınç	r								1	1,000**	,028**	,038**
	p									0,000	0,000	0,000
Denize İndirgenmiş Basınç	r									1	,028**	,038**
	p										0,000	0,000
Ortalama Rüzgar Yönü	r										1	,986**
	p											0,000
Maksimum Rüzgar Yönü	r											1
	p											

Samsun şamandırasından alınan 11 farklı ölçümün kendi aralarındaki korelasyon davranışlarının incelenmesi için Spearman Korelasyon Testi kullanılmıştır. Spearman Korelasyon Testi sonuçları incelendiğinde, tüm faktörlerin "Belirgin Dalga Yüksekliği" ve "Pik Dalga Periyodu" parametreleri ile korelasyon içerisinde olduğu ($p < 0.01$) gözlenmiştir. Belirgin Dalga Yüksekliği parametresinin diğer ölçüm değerleri ile korelasyonları incelendiğinde; Akıntı Hızı 10 m, Deniz Suyu Sıcaklığı, Aktüel Basınç, Denize İndirgenmiş Basınç ve Akıntı Hızı 10 m ölçümleri ile çok zayıf bir ilişki ($0 < r < 0.19$), Ortalama Rüzgar Yönü ile pozitif yönlü orta düzeyde bir ilişki ($0.40 < r < 0.59$), Pik Dalga Periyodu ve Maksimum Rüzgar Yönü ölçümleri ile pozitif yönlü iyi bir ilişki ($0.60 < r < 0.79$) olduğu gözlenmiştir. Samsun şamandırasına ait ölçüm değerlerinin birbirleri ile Pearson Korelasyon Testi sonucu Tablo 6.4'te gösterilmiştir.

Tablo 6.4 Samsun şamandırası ölçümlerinin Pearson korelasyon testi sonuçları


Parametre		V1	V2	V3	V4	V5	V6	V7	V8	V9	V10	V11
Akıntı hızı 5m	r	1	,784**	,723**	,047**	,044**	,154**	-	-,018*	-,018*	,071**	,079**
	p		0,000	0,000	0,000	0,000	0,000	,102**	0,025	0,024	0,000	0,000
Akıntı hızı 10m	r		1	,887**	,028**	,024**	,159**	-	0,001	0,001	,040**	,051**
	p			0,000	0,001	0,003	0,000	,112**	0,870	0,872	0,000	0,000
Akıntı hızı 15m	r			1	0,005	0,001	,150**	-	,020*	,019*	0,006	,019*
	p				0,515	0,901	0,000	,071**	0,016	0,017	0,455	0,018
Belirgin Dalga Yüksekliği	r				1	,999**	,710**	-	,202**	,202**	,698**	,722**
	p					0,000	0,000	,173**	0,000	0,000	0,000	0,000
Max Dalga Yüksekliği	r					1	,698**	-	,197**	,197**	,711**	,734**
	p						0,000	,171**	0,000	0,000	0,000	0,000
Pik Dalga Periyodu	r						1	-	,225**	,225**	,219**	,249**
	p							,246**	0,000	0,000	0,000	0,000
Deniz suyu Sıcaklığı	r							1	-	-,377**	-	-
	p								,373**	0,000	,082**	,074**
Aktüel Basınç	r								1	1,000**	,036**	,047**
	p									0,000	0,000	0,000
Denize İndirgenmiş Basınç	r									1	,036**	,047**
	p										0,000	0,000
Ortalama Rüzgar Yönü	r										1	,986**
	p											0,000
Maksimum Rüzgar Yönü	r											1
	p											

6.1 Ordu Şamandıra Dalga Yüksekliği ve Periyodu Tahminleri

Dalga gücünün hesaplanması için dalga boyu yüksekliği ve dalga periyodu tahminleri ayrı ayrı gerçekleştirilerek, ardından dalga gücü hesaplanmaktadır. Dalga gücü hesaplamasında, direkt olarak gücün tahmin edilmesinde parametrelerin negatif etkilerinden kaçınmak amacıyla dalga yüksekliği ve periyodu tahminleri ayrı ayrı yapılmaktadır. Şamandıraların sağladığı ölçüm parametrelerinin etkileri negatif olabilmektedir. Tez çalışmasında, LSTM, ELM, Bayesian, SVM, ResNet ve RNN olmak üzere 6 farklı temel regresyon modeli kullanılarak dalga boyu yüksekliği ve periyodu tahmini yapılmıştır. Her modelin performans değerlendirmesi 4 metrik değer üzerinden gerçekleştirilmiştir.

6.1.1 ResNet regresyon modeli performansı

ResNet algoritması kullanılarak 1 saat, 3 saat, 6 saat, 12 saat, 24 saat ve 72 saatlik periyotlarda, 1 dakikalık örnekleme frekansı ile dalga boyu yüksekliği tahmini yapılmıştır. ResNet algoritması ile eğitilen tüm regresyon modellerinin test ve tahmin verileri elde edilerek, bu değerlerin karşılaştırılması yapılmıştır. ResNet algoritması ile eğitilen modelin 1 saatlik süre için dalga yüksekliği tahmin ve test verilerinin karşılaştırılması Şekil 6.5'te gösterilmiştir.




Şekil 6.5 ResNet regresyon modelinin dalga yükseklięi için 1 saatlik tahmin ve test verilerinin karşılaştırılması

ResNet algoritması kullanılarak çalışmaya konu olan 6 farklı saat dilimi için dalga yüksekliğini tahmin edecek regresyon modelleri eğitilmiştir. Dalga yüksekliği için regresyon modelinin değerlendirme metrik değerleri hesaplanmıştır. ResNet modelleri için değerlendirme metrikleri Tablo 6.5'te gösterilmiştir. ResNet regresyon modellerinin metrik değerleri incelendiğinde, RMSE değerinin en düşük değeri 1 saatlik tahmin için 0,010, en yüksek değeri ise 72 saatlik tahmin için 0,055 olarak elde edilmiştir. MAE değerleri arasında en düşük değer 1 saatlik tahmin için 0,006, en yüksek değer ise 72 saatlik tahmin için 0,045 olarak gözlemlenmiştir. R^2 korelasyon değeri arasında en yüksek korelasyon 1 saatlik tahmin için 0,998 olarak hesaplanmış, en düşük korelasyon değeri ise 72 saatlik tahmin için 0,988 olarak hesaplanmıştır. MSE değerleri incelendiğinde, en düşük değer 1 saatlik tahmin için 0,0001, en yüksek değer ise 72 saatlik tahmin için 0,003 olarak gözlemlenmiştir.

Tablo 6.5 Dalga yüksekliği için saat aralıklarına göre ResNet regresyon modellerinin değerlendirme metrik değerleri

Metrik	<u>1H</u>	<u>3H</u>	<u>6H</u>	<u>12H</u>	<u>24H</u>	<u>72H</u>
<u>RMSE</u>	0,0106	0,030679	0,032634	0,038877	0,053308	0,055508
<u>MAE</u>	0,006426	0,022436	0,022836	0,023249	0,029286	0,045202
<u>R²</u>	0,998193	0,997575	0,996594	0,995547	0,995186	0,988186
<u>MSE</u>	0,000112	0,000941	0,001065	0,001511	0,002842	0,003081

ResNet algoritması kullanılarak 1 saat, 3 saat, 6 saat, 12 saat, 24 saat ve 72 saatlik periyotlarda, 1 dakikalık örnekleme frekansı ile dalga periyodu tahmini yapılmıştır. ResNet algoritması ile eğitilen tüm regresyon modellerinin test ve tahmin verileri elde edilerek, bu değerlerin karşılaştırılması yapılmıştır. ResNet algoritması ile eğitilen modelin 1 saatlik süre için dalga periyodu tahmin ve test verilerinin karşılaştırılması Şekil 6.6'da gösterilmiştir.



Şekil 6.6 ResNet regresyon modelinin dalga periyodu için 1 saatlik tahmin ve test verilerinin karşılaştırılması


ResNet algoritması kullanılarak çalışmaya konu olan 6 farklı saat dilimi için dalga periyodu tahmin edecek regresyon modelleri eğitilmiştir. Dalga periyodu için regresyon modelinin değerlendirme metrik değerleri hesaplanmıştır. ResNet modelleri için değerlendirme metrikleri Tablo 6.6'da gösterilmiştir. ResNet regresyon modellerinin metrik değerleri incelendiğinde, RMSE değerinin en düşük değeri 1 saatlik tahmin için 0,033, en yüksek değeri ise 72 saatlik tahmin için 0,064 olarak elde edilmiştir. MAE değerleri arasında en düşük değer 1 saatlik tahmin için 0,026, en yüksek değer ise 72 saatlik tahmin için 0,055 olarak gözlemlenmiştir. R^2 korelasyon değeri arasında en yüksek korelasyon 1 saatlik tahmin için 0,982 olarak hesaplanmış, en düşük korelasyon değeri ise 72 saatlik tahmin için 0,957 olarak hesaplanmıştır. MSE değerleri incelendiğinde, en düşük değer 1 saatlik tahmin için 0,001, en yüksek değer ise 72 saatlik tahmin için 0,004 olarak gözlemlenmiştir.

Tablo 6.6 Dalga periyodu için saat aralıklarına göre ResNet regresyon modellerinin değerlendirme metrik değerleri

Metrik	<u>1H</u>	<u>3H</u>	<u>6H</u>	<u>12H</u>	<u>24H</u>	<u>72H</u>
<u>RMSE</u>	0,033254	0,050559	0,054543	0,057455	0,061464	0,064594
<u>MAE</u>	0,026929	0,038486	0,041655	0,045031	0,049179	0,055699
<u>R^2</u>	0,982226	0,97965	0,977666	0,971041	0,965608	0,95754
<u>MSE</u>	0,001106	0,002556	0,002975	0,003301	0,003778	0,004172

6.1.2 ELM regresyon modeli performansı

ELM algoritması kullanılarak 1 saat, 3 saat, 6 saat, 12 saat, 24 saat ve 72 saatlik periyotlarda, 1 dakikalık örnekleme frekansı ile dalga boyu yüksekliği tahmini yapılmıştır. ELM algoritması ile eğitilen tüm regresyon modellerinin test ve tahmin verileri elde edilerek, bu değerlerin karşılaştırılması yapılmıştır. ELM algoritması ile eğitilen modelin 24 saatlik periyot için tahmin ve test verilerinin karşılaştırılması Şekil 6.7'de gösterilmiştir.




Şekil 6.7 ELM regresyon modelinin dalga yüksekliği için 24 saatlik tahmin ve test verilerinin karşılaştırılması

ELM algoritması kullanılarak çalışmaya konu olan 6 farklı saat dilimi için dalga yüksekliğini tahmin edecek regresyon modelleri eğitilmiştir. Regresyon modelinin değerlendirme metrik değerleri hesaplanmıştır. ELM modelleri için değerlendirme metrikleri Tablo 6.7'de verilmiştir. ELM regresyon modellerinin metrik değerleri incelendiğinde, RMSE değerinin en düşük değeri 1 saatlik tahmin için 0,049, en yüksek değeri ise 72 saatlik tahmin için 0,100 olarak elde edilmiştir. MAE değerleri arasında en düşük değer 1 saatlik tahmin için 0,041, en yüksek değer ise 72 saatlik tahmin için 0,081 olarak gözlemlenmiştir. R^2 korelasyon değeri arasında en yüksek korelasyon 1 saatlik tahmin için 0,994, en düşük korelasyon ise 72 saatlik tahmin için 0,959 olarak gözlemlenmiştir. MSE değerleri incelendiğinde, en düşük değer 1 saatlik tahmin için 0,002, en yüksek değer ise 72 saatlik tahmin için 0,010 olarak gözlemlenmiştir.

Tablo 6.7 Dalga yüksekliği için saat aralıklarına göre ELM regresyon modellerinin değerlendirme metrik değerleri

Metrik	<u>1H</u>	<u>3H</u>	<u>6H</u>	<u>12H</u>	<u>24H</u>	<u>72H</u>
<u>RMSE</u>	0,049639	0,060707	0,082829	0,092336	0,097664	0,100297
<u>MAE</u>	0,041825	0,043851	0,063625	0,068917	0,070293	0,081398
<u>R²</u>	0,994779	0,972623	0,972488	0,971656	0,965049	0,95908
<u>MSE</u>	0,002464	0,003685	0,006861	0,008526	0,009538	0,01006

ELM algoritması kullanılarak 1 saat, 3 saat, 6 saat, 12 saat, 24 saat ve 72 saatlik periyotlarda, 1 dakikalık örnekleme frekansı ile dalga periyodu tahmini yapılmıştır. ELM algoritması ile eğitilen tüm regresyon modellerinin test ve tahmin verileri elde edilerek, bu değerlerin karşılaştırılması yapılmıştır. ELM algoritması ile eğitilen modelin 24 saatlik süre için dalga periyodu tahmin ve test verilerinin karşılaştırılması Şekil 6.8'de gösterilmiştir.



Şekil 6.8 ELM regresyon modelinin dalga periyodu için 24 saatlik tahmin ve test verilerinin karşılaştırılması

ELM algoritması kullanılarak çalışmaya konu olan 6 farklı saat dilimi için dalga periyodu tahmin edecek regresyon modelleri eğitilmiştir. Dalga periyodu için regresyon modelinin değerlendirme metrik değerleri hesaplanmıştır. ELM modelleri için değerlendirme metrikleri Tablo 6.8'de gösterilmiştir. ELM regresyon modellerinin metrik değerleri incelendiğinde, RMSE değerinin en düşük değeri 1 saatlik tahmin için 0,033, en yüksek değeri ise 72 saatlik tahmin için 0,064 olarak elde edilmiştir. MAE değerleri arasında en


düşük değer 1 saatlik tahmin için 0,026, en yüksek değer ise 72 saatlik tahmin için 0,055 olarak gözlemlenmiştir. R^2 korelasyon değeri arasında en yüksek korelasyon 1 saatlik tahmin için 0,982 olarak hesaplanmış, en düşük korelasyon değeri ise 72 saatlik tahmin için 0,957 olarak hesaplanmıştır. MSE değerleri incelendiğinde, en düşük değer 1 saatlik tahmin için 0,001, en yüksek değer ise 72 saatlik tahmin için 0,004 olarak gözlemlenmiştir.

Tablo 6.8 Dalga periyodu için saat aralıklarına göre ELM regresyon modellerinin değerlendirme metrik değerleri

Metrikler	<u>1H</u>	<u>3H</u>	<u>6H</u>	<u>12H</u>	<u>24H</u>	<u>72H</u>
<u>RMSE</u>	0,046294	0,055019	0,083154	0,084315	0,100236	0,106887
<u>MAE</u>	0,032636	0,048991	0,065663	0,06759	0,075808	0,083937
<u>R²</u>	0,98049	0,952701	0,951344	0,927657	0,91186	0,900181
<u>MSE</u>	0,002143	0,003027	0,006915	0,007109	0,010047	0,011425

6.1.3 Bayesian regresyon modeli performansı

Bayesian algoritması kullanılarak 1 saat, 3 saat, 6 saat, 12 saat, 24 saat ve 72 saatlik periyotlarda, 1 dakikalık örnekleme frekansı ile dalga boyu yüksekliği tahmini yapılmıştır. Bayesian algoritması ile eğitilen tüm regresyon modellerinin test ve tahmin verileri elde edilerek, bu değerlerin karşılaştırılması yapılmıştır. Bayesian algoritması ile eğitilen modelin 6 saatlik periyot için dalga boyu yüksekliği tahmin ve test verilerinin karşılaştırılması Şekil 6.9'da gösterilmiştir.




Şekil 6.9 Bayesian regresyon modelinin dalga yüksekliği için 6 saatlik tahmin ve test verilerinin karşılaştırılması

Bayesian algoritması kullanılarak çalışmaya konu olan 6 farklı saat dilimi için dalga yüksekliğini tahmin edecek regresyon modelleri eğitilmiştir. Regresyon modelinin değerlendirme metrik değerleri hesaplanmıştır. Bayesian modelleri için değerlendirme metrikleri Tablo 6.9'da verilmiştir. Bayesian regresyon modellerinin metrik değerleri incelendiğinde, RMSE değerinin en düşük değeri 1 saatlik tahmin için 0,075, en yüksek değeri ise 72 saatlik tahmin için 0,119 olarak elde edilmiştir. MAE değerleri arasında en düşük değer 1 saatlik tahmin için 0,067, en yüksek değer ise 72 saatlik tahmin için 0,103 olarak gözlemlenmiştir. R^2 korelasyon değeri arasında en yüksek korelasyon 1 saatlik tahmin için 0,996, en düşük korelasyon ise 72 saatlik tahmin için 0,985 olarak gözlemlenmiştir. MSE değerleri incelendiğinde, en düşük değer 1 saatlik tahmin için 0,005, en yüksek değer ise 72 saatlik tahmin için 0,014 olarak gözlemlenmiştir.

Tablo 6.9 Dalga yüksekliği için saat aralıklarına göre Bayesian regresyon modellerinin değerlendirme metrik değerleri

Metrik	<u>1H</u>	<u>3H</u>	<u>6H</u>	<u>12H</u>	<u>24H</u>	<u>72H</u>
<u>RMSE</u>	0,075166	0,093136	0,093903	0,098844	0,107352	0,119669
<u>MAE</u>	0,067638	0,06818	0,072437	0,080221	0,100109	0,103577
<u>R^2</u>	0,996325	0,994178	0,994663	0,992659	0,991174	0,985991
<u>MSE</u>	0,00565	0,008674	0,008818	0,00977	0,011525	0,014321

Bayesian algoritması kullanılarak 1 saat, 3 saat, 6 saat, 12 saat, 24 saat ve 72 saatlik periyotlarda, 1 dakikalık örnekleme frekansı ile dalga periyodu tahmini yapılmıştır. Bayesian algoritması ile eğitilen tüm regresyon modellerinin test ve tahmin verileri elde edilerek, bu değerlerin karşılaştırılması yapılmıştır. Bayesian algoritması ile eğitilen modelin 6 saatlik periyot için dalga periyodu tahmin ve test verilerinin karşılaştırılması Şekil 6.10'da gösterilmiştir.



Şekil 6.10 Bayesian regresyon modelinin dalga periyodu için 6 saatlik tahmin ve test verilerinin karşılaştırılması


Bayesian algoritması kullanılarak çalışmaya konu olan 6 farklı saat dilimi için dalga periyodu tahmin edecek regresyon modelleri eğitilmiştir. Dalga periyodu için regresyon modelinin değerlendirme metrik değerleri hesaplanmıştır. Bayesian modellerine ait değerlendirme metrikleri Tablo 6.10'da gösterilmiştir. Bayesian regresyon modellerinin metrik değerleri incelendiğinde, RMSE değerinin en düşük değeri 1 saatlik tahmin için 0,080, en yüksek değeri ise 72 saatlik tahmin için 0,140 olarak elde edilmiştir. MAE değerleri arasında en düşük değer 1 saatlik tahmin için 0,062, en yüksek değer ise 72 saatlik tahmin için 0,110 olarak gözlemlenmiştir. R^2 korelasyon değeri incelendiğinde, en yüksek korelasyon 1 saatlik tahmin için 0,956, en düşük korelasyon ise 72 saatlik tahmin için 0,680 olarak hesaplanmıştır. MSE değerleri incelendiğinde, en düşük değer 1 saatlik tahmin için 0,006, en yüksek değer ise 72 saatlik tahmin için 0,019 olarak gözlemlenmiştir.

Tablo 6.10 Dalga periyodu için saat aralıklarına göre Bayesian regresyon modellerinin değerlendirme metrik değerleri

Metrikler	<u>1H</u>	<u>3H</u>	<u>6H</u>	<u>12H</u>	<u>24H</u>	<u>72H</u>
<u>RMSE</u>	0,080162	0,085886	0,097911	0,105624	0,1128	0,140893
<u>MAE</u>	0,06247	0,065856	0,072963	0,074304	0,087042	0,110914
<u>R²</u>	0,956043	0,924935	0,915901	0,902526	0,884166	0,680931
<u>MSE</u>	0,006426	0,007376	0,009587	0,011156	0,012724	0,019851

6.1.4 LSTM regresyon modeli performansı

LSTM algoritması kullanılarak 1 saat, 3 saat, 6 saat, 12 saat, 24 saat ve 72 saatlik periyotlarda 1 dakikalık örnekleme frekansı ile dalga boyu yüksekliği tahmin edilmiştir. LSTM algoritması ile eğitilen tüm regresyon modellerinin test ve tahmin verileri elde edilerek bu veriler karşılaştırılmıştır. LSTM algoritması ile eğitilen modelin 3 saatlik periyot için tahmin ve test verilerinin karşılaştırılması Şekil 6.11'de gösterilmiştir.



Şekil 6.11 LSTM regresyon modelinin dalga yüksekliği için 3 saatlik tahmin ve test verilerinin karşılaştırılması


LSTM algoritması kullanılarak çalışmaya konu olan 6 farklı saat dilimi için dalga yüksekliğini tahmin edecek regresyon modelleri eğitilmiştir. Regresyon modelinin değerlendirme metrik değerleri hesaplanmış ve LSTM modelleri için değerlendirme metrikleri Tablo 6.11'de verilmiştir. LSTM regresyon modellerinin metrik değerleri incelendiğinde, RMSE değerinin en düşük değeri 1 saatlik tahmin için 0,074, en yüksek

değeri ise 72 saatlik tahmin için 0,119 olarak elde edilmiştir. MAE değerleri arasında en düşük değer 1 saatlik tahmin için 0,041, en yüksek değer ise 72 saatlik tahmin için 0,085 olarak gözlemlenmiştir. R2 korelasyon değeri arasında en yüksek korelasyon 1 saatlik tahmin için 0,971, en düşük korelasyon ise 72 saatlik tahmin için 0,803 olarak gözlemlenmiştir. MSE değerleri incelendiğinde, en düşük değer 1 saatlik tahmin için 0,005, en yüksek değer ise 72 saatlik tahmin için 0,014 olarak gözlemlenmiştir.

Tablo 6.11 Dalga yüksekliği için saat aralıklarına göre LSTM regresyon modellerinin değerlendirme metrik değerleri

Metrik	<u>1H</u>	<u>3H</u>	<u>6H</u>	<u>12H</u>	<u>24H</u>	<u>72H</u>
<u>RMSE</u>	0,074762	0,089147	0,099232	0,106321	0,107242	0,119611
<u>MAE</u>	0,041834	0,043547	0,063768	0,063977	0,075215	0,085013
<u>R²</u>	0,971351	0,971041	0,969386	0,9665	0,964748	0,803059
<u>MSE</u>	0,005589	0,007947	0,009847	0,011304	0,011501	0,014307

LSTM algoritması kullanılarak 1 saat, 3 saat, 6 saat, 12 saat, 24 saat ve 72 saatlik periyotlarda 1 dakikalık örnekleme frekansı ile dalga periyodu tahmini yapılmıştır. LSTM algoritması ile eğitilen tüm regresyon modellerinin test ve tahmin verileri elde edilerek bu değerlerin karşılaştırılması yapılmıştır. LSTM algoritması ile eğitilen modelin 3 saatlik süre için dalga periyodu tahmin ve test verilerinin karşılaştırılması Şekil 6.12'de gösterilmiştir.



Şekil 6.12 LSTM regresyon modelinin dalga periyodu için 3 saatlik tahmin ve test verilerinin karşılaştırılması


LSTM algoritması kullanılarak, çalışmaya konu olan 6 farklı saat dilimi için dalga periyodu tahmini yapacak regresyon modelleri eğitilmiştir. Dalga periyodu için regresyon modelinin değerlendirme metrik değerleri hesaplanmış ve LSTM modelleri için bu metrikler Tablo 6.12'de sunulmuştur. LSTM regresyon modellerinin metrik değerleri incelendiğinde, RMSE değerinin en düşük değeri 1 saatlik tahmin için 0,115, en yüksek değeri ise 72 saatlik tahmin için 0,164 olarak elde edilmiştir. MAE değerleri arasında en düşük değer 1 saatlik tahmin için 0,090, en yüksek değer ise 72 saatlik tahmin için 0,135 olarak gözlemlenmiştir. R^2 korelasyon değeri açısından, en yüksek korelasyon 1 saatlik tahmin için 0,863, en düşük korelasyon ise 72 saatlik tahmin için 0,665 olarak hesaplanmıştır. MSE değerleri incelendiğinde, en düşük değer 1 saatlik tahmin için 0,013, en yüksek değer ise 72 saatlik tahmin için 0,027 olarak gözlemlenmiştir.

Tablo 6.12 Dalga periyodu için saat aralıklarına göre LSTM regresyon modellerinin değerlendirme metrik değerleri

Metrikle	<u>1H</u>	<u>3H</u>	<u>6H</u>	<u>12H</u>	<u>24H</u>	<u>72H</u>
<u>RMSE</u>	0,115953	0,125044	0,136244	0,143337	0,157332	0,164522
<u>MAE</u>	0,090511	0,100137	0,110734	0,122836	0,125287	0,135849
<u>R^2</u>	0,863821	0,863389	0,83102	0,829296	0,76257	0,665794
<u>MSE</u>	0,013445	0,015636	0,018562	0,020546	0,024753	0,027067

6.1.5 RNN regresyon modeli performansı

RNN algoritması kullanılarak, 1 saat, 3 saat, 6 saat, 12 saat, 24 saat ve 72 saatlik periyotlarda, 1 dakikalık örnekleme frekansı ile dalga boyu yüksekliği tahmin edilmiştir. RNN algoritmasıyla eğitilen tüm regresyon modellerinin test ve tahmin verileri elde edilerek, bu değerlerin karşılaştırılması yapılmıştır. RNN algoritmasıyla eğitilen modelin 12 saatlik periyot için tahmin ve test verilerinin karşılaştırması, Şekil 6.13'te sunulmuştur.




Şekil 6.13 RNN regresyon modelinin dalga yüksekliği için 12 saatlik tahmin ve test verilerinin karşılaştırılması

RNN algoritması kullanılarak, çalışmaya konu olan 6 farklı saat dilimi için dalga yüksekliğini tahmin edecek regresyon modelleri eğitilmiştir. Bu modellerin değerlendirme metrik değerleri hesaplanmış olup, RNN modellerine ait metrikler Tablo 6.13'te verilmiştir. RNN regresyon modellerinin metrik değerleri incelendiğinde, RMSE değerinin en düşük değeri 1 saatlik tahmin için 0,143, en yüksek değeri ise 72 saatlik tahmin için 0,205 olarak elde edilmiştir. MAE değerleri arasında en düşük değer 1 saatlik tahmin için 0,087, en yüksek değer ise 72 saatlik tahmin için 0,127 olarak gözlemlenmiştir. R^2 korelasyon değeri incelendiğinde, en yüksek korelasyon 1 saatlik tahmin için 0,790, en düşük korelasyon ise 72 saatlik tahmin için 0,702 olarak hesaplanmıştır. MSE değerleri ise en düşük 1 saatlik tahmin için 0,020, en yüksek ise 72 saatlik tahmin için 0,042 olarak gözlemlenmiştir.

Tablo 6.13 Dalga yüksekliği için saat aralıklarına göre RNN regresyon modellerinin değerlendirme metrik değerleri

Metrik	<u>1H</u>	<u>3H</u>	<u>6H</u>	<u>12H</u>	<u>24H</u>	<u>72H</u>
<u>RMSE</u>	0,143326	0,164466	0,169378	0,172999	0,186414	0,205843
<u>MAE</u>	0,087251	0,09638	0,111766	0,111847	0,122545	0,127443
<u>R^2</u>	0,790172	0,785919	0,778063	0,769303	0,752123	0,702335
<u>MSE</u>	0,020542	0,027049	0,028689	0,029929	0,03475	0,042371

RNN algoritması kullanılarak, 1 saat, 3 saat, 6 saat, 12 saat, 24 saat ve 72 saatlik periyotlarda, 1 dakikalık örnekleme frekansı ile dalga periyodu tahmini yapılmıştır. RNN algoritması ile eğitilen tüm regresyon modellerinin test ve tahmin verileri elde edilerek bu veriler karşılaştırılmıştır. RNN algoritması ile eğitilen modelin 12 saatlik süre için dalga periyodu tahmin ve test verilerinin karşılaştırılması, Şekil 6.14'te gösterilmiştir.



Şekil 6.14 RNN regresyon modelinin dalga periyodu için 12 saatlik tahmin ve test verilerinin karşılaştırılması


RNN algoritması kullanılarak, çalışmaya konu olan 6 farklı saat dilimi için dalga periyodu tahmin edecek regresyon modelleri eğitilmiştir. Dalga periyodu için regresyon modelinin değerlendirme metrik değerleri hesaplanmıştır. RNN modellerine ait değerlendirme metrikleri Tablo 6.14'te gösterilmiştir. RNN regresyon modellerinin metrik değerleri incelendiğinde, RMSE değerinin en düşük değeri 1 saatlik tahmin için 0,139, en yüksek değeri ise 72 saatlik tahmin için 0,186 olarak elde edilmiştir. MAE değerleri arasında en düşük değeri 1 saatlik tahmin için 0,099, en yüksek değeri ise 72 saatlik tahmin için 0,141 olarak gözlemlenmiştir. R^2 korelasyon değeri arasında en yüksek korelasyon 1 saatlik tahmin için 0,816 olarak hesaplanmışken, en düşük korelasyon değeri 72 saatlik tahmin için 0,449 olarak hesaplanmıştır. MSE değerleri incelendiğinde, en düşük değeri 1 saatlik tahmin için 0,019, en yüksek değeri ise 72 saatlik tahmin için 0,034 olarak gözlemlenmiştir.

Tablo 6.14 Dalga periyodu için saat aralıklarına göre RNN regresyon modellerinin değerlendirme metrik değerleri

Metrik	<u>1H</u>	<u>3H</u>	<u>6H</u>	<u>12H</u>	<u>24H</u>	<u>72H</u>
<u>RMSE</u>	0,139281	0,142251	0,149376	0,154562	0,166651	0,186932
<u>MAE</u>	0,099923	0,103231	0,108363	0,116321	0,134386	0,141735
<u>R²</u>	0,816096	0,810096	0,806636	0,803464	0,790556	0,449128
<u>MSE</u>	0,019399	0,020235	0,022313	0,023889	0,027773	0,034944

6.1.6 SVM regresyon modeli performansı

SVM algoritması kullanılarak, 1 saat, 3 saat, 6 saat, 12 saat, 24 saat ve 72 saatlik periyotlarda 1 dakikalık örnekleme frekansı ile dalga boyu yüksekliği tahmini yapılmıştır. SVM algoritması ile eğitilen tüm regresyon modellerinin test ve tahmin verileri elde edilerek bu değerlerin karşılaştırılması yapılmıştır. SVM algoritması ile eğitilen modelin 72 saatlik periyot için tahmin ve test verilerinin karşılaştırılması Şekil 6.15'te gösterilmiştir.



Şekil 6.15 SVM regresyon modelinin dalga yüksekliği için 72 saatlik tahmin ve test verilerinin karşılaştırılması


SVM algoritması kullanılarak, çalışmaya konu olan 6 farklı saat dilimi için dalga yüksekliğini tahmin edecek regresyon modelleri eğitilmiştir. Regresyon modelinin değerlendirme metrik değerleri hesaplanmıştır. SVM modelleri için değerlendirme

metrikleri Tablo 6.15'te verilmiştir. Metrik değerler incelendiğinde, RMSE değerinin en düşük değeri 1 saatlik tahmin için 0,023, en yüksek değeri ise 72 saatlik tahmin için 0,135 olarak elde edilmiştir. MAE değerleri arasında en düşük değer 1 saatlik tahmin için 0,019, en yüksek değer ise 72 saatlik tahmin için 0,078 olarak gözlemlenmiştir. R^2 korelasyon değeri açısından en yüksek korelasyon 1 saatlik tahmin için 0,988, en düşük korelasyon ise 72 saatlik tahmin için 0,925 olarak hesaplanmıştır. MSE değerleri incelendiğinde, en düşük değer 1 saatlik tahmin için 0,0005, en yüksek değer ise 72 saatlik tahmin için 0,018 olarak gözlemlenmiştir.

Tablo 6.15 Dalga yüksekliği için saat aralıklarına göre SVM regresyon modellerinin değerlendirme metrik değerleri

Metrik	<u>1H</u>	<u>3H</u>	<u>6H</u>	<u>12H</u>	<u>24H</u>	<u>72H</u>
<u>RMSE</u>	0,02364	0,078867	0,095549	0,099487	0,100649	0,135608
<u>MAE</u>	0,019045	0,04985	0,060171	0,061593	0,066354	0,078272
<u>R^2</u>	0,988615	0,977537	0,973693	0,968502	0,952799	0,925361
<u>MSE</u>	0,000559	0,00622	0,00913	0,009898	0,01013	0,018389

SVM algoritması kullanılarak, 1, 3, 6, 12, 24 ve 72 saatlik periyotlarda dalga periyodu tahmini yapılmıştır. SVM algoritması ile eğitilen tüm regresyon modellerinin test ve tahmin verileri elde edilerek bu değerlerin karşılaştırılması yapılmıştır. Eğitilen modelin dalga periyodu tahmin ve test verilerinin karşılaştırılması Şekil 6.16'da gösterilmiştir.



Şekil 6.16 SVM regresyon modelinin dalga periyodu için 72 saatlik tahmin ve test verilerinin karşılaştırılması

SVM algoritması kullanılarak, çalışmaya konu olan 6 farklı saat dilimi için dalga periyodu tahmin edecek regresyon modelleri eğitilmiştir. Dalga periyodu için regresyon modelinin değerlendirme metrik değerleri hesaplanmıştır. SVM modelleri için değerlendirme metrikleri Tablo 6.16'da gösterilmiştir. Metrik değerler incelendiğinde, RMSE değerinin en düşük değeri 1 saatlik tahmin için 0,043, en yüksek değeri ise 72 saatlik tahmin için 0,101 olarak elde edilmiştir. MAE değerleri arasında en düşük değer 1 saatlik tahmin için 0,027, en yüksek değer ise 72 saatlik tahmin için 0,066 olarak gözlemlenmiştir. R^2 korelasyon değeri arasında en yüksek korelasyon 1 saatlik tahmin için 0,969, en düşük korelasyon ise 72 saatlik tahmin için 0,909 olarak hesaplanmıştır. MSE değerleri incelendiğinde, en düşük değer 1 saatlik tahmin için 0,001, en yüksek değer ise 72 saatlik tahmin için 0,010 olarak gözlemlenmiştir.

Tablo 6.16 Dalga periyodu için saat aralıklarına göre SVM regresyon modellerinin değerlendirme metrik değerleri

Metrik	<u>1H</u>	<u>3H</u>	<u>6H</u>	<u>12H</u>	<u>24H</u>	<u>72H</u>
<u>RMSE</u>	0,043475	0,065911	0,069527	0,091487	0,09236	0,101533
<u>MAE</u>	0,027909	0,041561	0,0445	0,060055	0,062108	0,066574
<u>R^2</u>	0,96962	0,955993	0,955791	0,941648	0,926872	0,909565
<u>MSE</u>	0,00189	0,004344	0,004834	0,00837	0,00853	0,010309


6.2 Samsun Şamandıra Dalga Yüksekliği ve Periyodu Tahminleri

Dalga gücünün hesaplanmasında, dalga boyu yüksekliği ve dalga periyodu tahminleri ayrı ayrı gerçekleştirilmekte ve bu tahminler kullanılarak dalga gücü hesaplanmaktadır. Bu yöntemin tercih edilmesinin nedeni, dalga gücü tahmininde parametrelerin negatif etkilerinden kaçınmaktır. Şamandıraların sağladığı ölçüm parametreleri, doğrudan dalga gücü tahmini üzerinde olumsuz etkiler oluşturabileceği için dalga yüksekliği ve periyodu ayrı ayrı tahmin edilmektedir. Tez çalışmasında, LSTM, ELM, Bayesian, SVM, ResNet ve RNN olmak üzere 6 farklı temel regresyon modeli kullanılarak dalga boyu yüksekliği ve dalga periyodu tahminleri yapılmıştır. Her modelin performansı, dört farklı değerlendirme metriği üzerinden analiz edilmiştir.

6.2.1 ResNet regresyon modeli performansı

ResNet algoritması kullanılarak, 1 saat, 3 saat, 6 saat, 12 saat, 24 saat ve 72 saatlik periyotlarda 1 dakikalık örnekleme frekansı ile dalga boyu yüksekliği tahmini gerçekleştirilmiştir. ResNet algoritmasıyla eğitilen tüm regresyon modellerinin test ve

tahmin verileri elde edilmiş ve bu veriler karşılaştırılmıştır. ResNet algoritması ile eğitilen modelin, 1 saatlik süre için dalga boyu yüksekliği tahmini ve test verilerinin karşılaştırılması Şekil 6.17’de sunulmuştur.



Şekil 6.17 ResNet regresyon modelinin dalga yüksekliği için 1 saatlik tahmin ve test verilerinin karşılaştırılması


ResNet algoritması kullanılarak çalışmaya konu olan 6 farklı saat dilimi için dalga yüksekliğini tahmin eden regresyon modelleri eğitilmiştir. Bu modellerin performansı, çeşitli değerlendirme metrikleri kullanılarak analiz edilmiştir. ResNet modellerine ait değerlendirme metrikleri Tablo 6.17’de sunulmuştur.

Metrik değerler incelendiğinde, RMSE değerinin en düşük olduğu tahmin 1 saatlik periyot için 0,034, en yüksek olduğu tahmin ise 72 saatlik periyot için 0,047 olarak elde edilmiştir. MAE değerleri arasında en düşük değer 1 saatlik tahmin için 0,022, en yüksek değer ise 72 saatlik tahmin için 0,303 olarak hesaplanmıştır. R^2 korelasyon değerleri arasında en yüksek korelasyon 1 saatlik tahmin için 0,993, en düşük korelasyon ise 72 saatlik tahmin için 0,984 olarak belirlenmiştir. MSE değerleri incelendiğinde, en düşük değer 1 saatlik tahmin için 0,001, en yüksek değer ise 72 saatlik tahmin için 0,002 olarak gözlenmiştir.

Tablo 6.17 Dalga yüksekliği için saat aralıklarına göre ResNet regresyon modellerinin değerlendirme metrik değerleri

Metrik	<u>1H</u>	<u>3H</u>	<u>6H</u>	<u>12H</u>	<u>24H</u>	<u>72H</u>
<u>RMSE</u>	0,034516	0,035642	0,038464	0,038966	0,0462	0,047156
<u>MAE</u>	0,022081	0,022934	0,025874	0,026555	0,027043	0,030349
<u>R²</u>	0,99331	0,992754	0,990542	0,988974	0,986547	0,984564
<u>MSE</u>	0,001191	0,00127	0,001479	0,001518	0,002134	0,002224

ResNet algoritması kullanılarak 1 saat, 3 saat, 6 saat, 12 saat, 24 saat ve 72 saatlik periyotlar için, 1 dakikalık örnekleme frekansı ile dalga periyodu tahmini gerçekleştirilmiştir. ResNet algoritması ile eğitilen tüm regresyon modellerinin test ve tahmin verileri elde edilmiş ve bu değerler karşılaştırılmıştır. ResNet algoritması ile eğitilen modelin, 1 saatlik süre için dalga periyodu tahmin ve test verilerinin karşılaştırılması Şekil 6.18’de sunulmuştur.



Şekil 6.18 ResNet regresyon modelinin dalga periyodu için 1 saatlik tahmin ve test verilerinin karşılaştırılması

ResNet algoritması kullanılarak çalışmaya konu olan 6 farklı saat dilimi için dalga periyodu tahminine yönelik regresyon modelleri eğitilmiştir. Dalga periyodu için regresyon modellerinin değerlendirme metrik değerleri hesaplanmış ve sonuçlar Tablo 6.18’de sunulmuştur. ResNet regresyon modellerinin metrik değerleri incelendiğinde, RMSE değerinin en düşük olduğu tahmin 1 saatlik periyot için 0,034, en yüksek olduğu tahmin ise 72 saatlik periyot için 0,068 olarak elde edilmiştir. MAE değerleri açısından, en düşük değer 1 saatlik tahmin için 0,025, en yüksek değer ise 72 saatlik tahmin için


0,053 olarak gözlenmiştir. R^2 korelasyon değerleri arasında en yüksek korelasyon 1 saatlik tahmin için 0,985, en düşük korelasyon ise 72 saatlik tahmin için 0,962 olarak hesaplanmıştır. MSE değerleri incelendiğinde ise, en düşük değer 1 saatlik tahmin için 0,001, en yüksek değer ise 72 saatlik tahmin için 0,004 olarak belirlenmiştir.

Tablo 6.18 Dalga periyodu için saat aralıklarına göre ResNet regresyon modellerinin değerlendirme metrik değerleri

Metrik	<u>1H</u>	<u>3H</u>	<u>6H</u>	<u>12H</u>	<u>24H</u>	<u>72H</u>
<u>RMSE</u>	0,034937	0,036385	0,042132	0,042487	0,043073	0,068731
<u>MAE</u>	0,025538	0,02894	0,032779	0,033137	0,034577	0,053925
<u>R^2</u>	0,9854	0,983949	0,982868	0,980689	0,980607	0,962161
<u>MSE</u>	0,001221	0,001324	0,001775	0,001805	0,001855	0,004724

6.2.2 ELM regresyon modeli performansı

ELM algoritması kullanılarak 1, 3, 6, 12, 24 ve 72 saatlik periyotlarda, dalga boyu yüksekliği tahmini gerçekleştirilmiştir. ELM algoritması ile eğitilen tüm regresyon modellerinin test ve tahmin verileri elde edilmiş ve bu değerlerin karşılaştırılması yapılmıştır. ELM algoritması ile eğitilen modelin 24 saatlik periyot için tahmin ve test verilerinin karşılaştırılması Şekil 6.19’da sunulmuştur.



Şekil 6.19 ELM regresyon modelinin dalga yüksekliği için 24 saatlik tahmin ve test verilerinin karşılaştırılması

ELM algoritması kullanılarak çalışmada ele alınan 6 farklı saat dilimi için dalga yüksekliğini tahmin edecek regresyon modelleri eğitilmiştir. Bu modellerin performansını değerlendirmek amacıyla çeşitli metrikler hesaplanmıştır. ELM modellerine ait değerlendirme metrikleri Tablo 6.19’da sunulmuştur.


ELM regresyon modellerinin metrik değerleri incelendiğinde, RMSE değerinin en düşük olduğu tahmin 1 saatlik periyot için 0,081, en yüksek olduğu tahmin ise 72 saatlik periyot için 0,135 olarak elde edilmiştir. MAE değerleri arasında en düşük değer 1 saatlik tahmin için 0,060, en yüksek değer ise 72 saatlik tahmin için 0,102 olarak gözlenmiştir. R^2 korelasyon değeri açısından en yüksek korelasyon 1 saatlik tahmin için 0,962, en düşük korelasyon ise 72 saatlik tahmin için 0,912 olarak hesaplanmıştır. MSE değerleri incelendiğinde ise en düşük değer 1 saatlik tahmin için 0,006, en yüksek değer ise 72 saatlik tahmin için 0,018 olarak belirlenmiştir.

Tablo 6.19 Dalga yüksekliği için saat aralıklarına göre ELM regresyon modellerinin değerlendirme metrik değerleri

Metrik	<u>1H</u>	<u>3H</u>	<u>6H</u>	<u>12H</u>	<u>24H</u>	<u>72H</u>
<u>RMSE</u>	0,081518	0,0819	0,086279	0,086684	0,110028	0,135443
<u>MAE</u>	0,06021	0,062441	0,066533	0,067988	0,083112	0,102889
<u>R²</u>	0,962681	0,959419	0,944055	0,937464	0,922333	0,91245
<u>MSE</u>	0,006645	0,006708	0,007444	0,007514	0,012106	0,018345

ELM algoritması kullanılarak 1 saat, 3 saat, 6 saat, 12 saat, 24 saat ve 72 saatlik periyotlarda 1 dakikalık örnekleme frekansı ile dalga periyodu tahmini gerçekleştirilmiştir. Bu süreçte, ELM algoritması ile eğitilen tüm regresyon modellerinin test ve tahmin verileri elde edilerek karşılaştırmaları yapılmıştır.

ELM algoritması ile eğitilen modelin 24 saatlik süre için dalga periyodu tahmin ve test verilerinin karşılaştırılması Şekil 6.20’de sunulmuştur. Bu karşılaştırma, modelin doğruluk performansını görselleştirmek ve tahmin edilen verilerin test verileriyle ne derece uyumlu olduğunu değerlendirmek için kullanılmıştır.



Şekil 6.20 ELM regresyon modelinin dalga periyodu için 24 saatlik tahmin ve test verilerinin karşılaştırılması

ELM algoritması kullanılarak çalışmaya konu olan 6 farklı saat dilimi için dalga periyodu tahmini gerçekleştirilmiştir. Bu tahminler sonucunda regresyon modellerinin değerlendirme metrik değerleri hesaplanmış ve Tablo 6.20’de sunulmuştur.

ELM regresyon modellerinin metrik değerleri incelendiğinde:

- RMSE değerleri: En düşük değer 1 saatlik tahmin için 0,049, en yüksek değer 72 saatlik tahmin için 0,087 olarak elde edilmiştir.
- MAE değerleri: En düşük değer 1 saatlik tahmin için 0,038, en yüksek değer 72 saatlik tahmin için 0,067 olarak gözlenmiştir.
- R^2 korelasyon değerleri: En yüksek korelasyon 1 saatlik tahmin için 0,976, en düşük korelasyon ise 72 saatlik tahmin için 0,916 olarak hesaplanmıştır.
- MSE değerleri: En düşük değer 1 saatlik tahmin için 0,002, en yüksek değer 72 saatlik tahmin için 0,007 olarak gözlenmiştir.

Bu sonuçlar, ELM algoritmasının kısa vadeli tahminlerde daha yüksek doğruluk sağladığını, ancak tahmin süresi uzadıkça performansın nispeten azaldığını göstermektedir.


Tablo 6.20 Dalga periyodu için saat aralıklarına göre ELM regresyon modellerinin değerlendirme metrik değerleri

Metrik	<u>1H</u>	<u>3H</u>	<u>6H</u>	<u>12H</u>	<u>24H</u>	<u>72H</u>
<u>RMSE</u>	0,049855	0,06259	0,066834	0,078362	0,083106	0,087023
<u>MAE</u>	0,038981	0,052652	0,053651	0,060351	0,064111	0,067912
<u>R²</u>	0,976411	0,953507	0,95314	0,950813	0,917265	0,916263
<u>MSE</u>	0,002486	0,003917	0,004467	0,006141	0,006907	0,007573

6.2.3 Bayesian regresyon modeli performansı

Bayesian algoritması kullanılarak 1 saat, 3 saat, 6 saat, 12 saat, 24 saat ve 72 saatlik periyotlarda 1 dakikalık örnekleme frekansı ile dalga boyu yüksekliği tahmini gerçekleştirilmiştir. Bayesian algoritması ile eğitilen tüm regresyon modellerinin test ve tahmin verileri elde edilmiş ve bu değerler karşılaştırılmıştır.

Bayesian algoritması ile eğitilen modelin 6 saatlik periyot için dalga boyu yüksekliği tahmin ve test verilerinin karşılaştırması Şekil 6.21’de sunulmuştur. Bu karşılaştırma, modelin tahmin performansını görsel olarak değerlendirmek için kullanılmıştır.



Şekil 6.21 Bayesian regresyon modelinin dalga yüksekliği için 6 saatlik tahmin ve test verilerinin karşılaştırılması

Bayesian algoritması kullanılarak çalışmaya konu olan 6 farklı saat dilimi için dalga yüksekliğini tahmin edecek regresyon modelleri eğitilmiştir. Dalga yüksekliği için

regresyon modelinin değerlendirme metrik değerleri hesaplanmıştır. Bayesian modelleri için değerlendirme metrikleri Tablo 6.21'de verilmiştir.

Bayesian regresyon modellerinin metrik değerleri incelendiğinde, şu sonuçlar elde edilmiştir:


- RMSE: En düşük değer 1 saatlik tahmin için 0,043, en yüksek değer ise 72 saatlik tahmin için 0,084 olarak gözlenmiştir.
- MAE: En düşük değer 1 saatlik tahmin için 0,032, en yüksek değer ise 72 saatlik tahmin için 0,064 olarak gözlenmiştir.
- R^2 Korelasyon Değeri: En yüksek korelasyon 1 saatlik tahmin için 0,980, en düşük korelasyon ise 72 saatlik tahmin için 0,955 olarak gözlenmiştir.
- MSE: En düşük değer 1 saatlik tahmin için 0,001, en yüksek değer ise 72 saatlik tahmin için 0,007 olarak gözlenmiştir.

Bu metrikler, Bayesian algoritmasının dalga yüksekliği tahminindeki doğruluğunu ve güvenilirliğini değerlendirmek için kullanılmaktadır.

Tablo 6.21 Dalga yüksekliği için saat aralıklarına göre Bayesian regresyon modellerinin değerlendirme metrik değerleri

Metrik	<u>1H</u>	<u>3H</u>	<u>6H</u>	<u>12H</u>	<u>24H</u>	<u>72H</u>
<u>RMSE</u>	0,043409	0,064599	0,067955	0,072651	0,076949	0,084862
<u>MAE</u>	0,032196	0,052144	0,055137	0,05967	0,064474	0,064816
<u>R^2</u>	0,98034	0,980085	0,972062	0,970358	0,9628	0,955915
<u>MSE</u>	0,001884	0,004173	0,004618	0,005278	0,005921	0,007201

Bayesian algoritması kullanılarak çalışmaya konu olan 6 farklı saat dilimi için dalga periyodu tahmini yapılmıştır. Bu tahminler, 1 dakikalık örnekleme frekansı ile gerçekleştirilmiştir. Bayesian algoritması ile eğitilen tüm regresyon modellerinin test ve tahmin verileri elde edilerek bu değerlerin karşılaştırılması yapılmıştır. Bayesian algoritması ile eğitilen modelin 6 saatlik süre için dalga periyodu tahmin ve test verilerinin karşılaştırılması Şekil 6.22'de gösterilmiştir.



Şekil 6.22 Bayesian regresyon modelinin dalga periyodu için 6 saatlik tahmin ve test verilerinin karşılaştırılması

Bayesian algoritması kullanılarak çalışmaya konu olan 6 farklı saat dilimi için dalga periyodu tahminine yönelik regresyon modelleri eğitilmiştir. Dalga periyodu için regresyon modelinin değerlendirme metrik değerleri hesaplanmış ve bu metrikler Tablo 6.22'de gösterilmiştir. Bayesian regresyon modellerinin metrik değerleri incelendiğinde aşağıdaki gözlemler elde edilmiştir:


- RMSE: En düşük değer 1 saatlik tahmin için 0,064, en yüksek değer ise 72 saatlik tahmin için 0,101 olarak hesaplanmıştır.
- MAE: En düşük değer 1 saatlik tahmin için 0,044, en yüksek değer ise 72 saatlik tahmin için 0,078 olarak gözlemlenmiştir.
- R^2 : En yüksek korelasyon 1 saatlik tahmin için 0,954, en düşük korelasyon ise 72 saatlik tahmin için 0,917 olarak hesaplanmıştır.
- MSE: En düşük değer 1 saatlik tahmin için 0,004, en yüksek değer ise 72 saatlik tahmin için 0,010 olarak gözlemlenmiştir.

Tablo 6.22 Dalga periyodu için saat aralıklarına göre Bayesian regresyon modellerinin değerlendirme metrik değerleri

Metrik	<u>1H</u>	<u>3H</u>	<u>6H</u>	<u>12H</u>	<u>24H</u>	<u>72H</u>
<u>RMSE</u>	0,064949	0,066007	0,07615	0,0799	0,086876	0,101247
<u>MAE</u>	0,044452	0,05061	0,059718	0,061032	0,064436	0,078827
<u>R²</u>	0,95465	0,949541	0,939411	0,929694	0,917888	0,917544
<u>MSE</u>	0,004218	0,004357	0,005799	0,006384	0,007547	0,010251

6.2.4 LSTM regresyon modeli performansı

LSTM algoritması kullanılarak 1 saat, 3 saat, 6 saat, 12 saat, 24 saat ve 72 saatlik periyotlarda 1 dakikalık örnekleme frekansı ile dalga boyu yüksekliği tahmin edilmiştir. LSTM algoritması ile eğitilen tüm regresyon modellerinin test ve tahmin verileri elde edilerek bu değerlerin karşılaştırılması yapılmıştır. LSTM algoritması ile eğitilen modelin 3 saatlik periyot için dalga boyu yüksekliği tahmin ve test verilerinin karşılaştırılması Şekil 6.23'te gösterilmiştir. Bu görsel, modelin tahmin doğruluğunu ve test verileriyle uyumunu görsel olarak değerlendirmeyi mümkün kılar.



Şekil 6.23 LSTM regresyon modelinin dalga yüksekliği için 3 saatlik tahmin ve test verilerinin karşılaştırılması

LSTM algoritması kullanılarak çalışmaya konu olan 6 farklı saat dilimi için dalga yüksekliğini tahmin edecek regresyon modelleri eğitilmiştir. Regresyon modelinin


değerlendirme metrik değerleri hesaplanmış ve LSTM modelleri için metrikler Tablo 6.23'te verilmiştir. LSTM regresyon modellerinin metrik değerleri incelendiğinde:

- RMSE: En düşük değer 1 saatlik tahmin için 0,086, en yüksek değer ise 72 saatlik tahmin için 0,161 olarak elde edilmiştir.
- MAE: En düşük değer 1 saatlik tahmin için 0,057, en yüksek değer ise 72 saatlik tahmin için 0,088 olarak gözlenmiştir.
- R^2 : En yüksek korelasyon 1 saatlik tahmin için 0,959, en düşük korelasyon ise 72 saatlik tahmin için 0,733 olarak hesaplanmıştır.
- MSE: En düşük değer 1 saatlik tahmin için 0,007, en yüksek değer ise 72 saatlik tahmin için 0,025 olarak gözlenmiştir.

Tablo 6.23 Dalga yüksekliği için saat aralıklarına göre LSTM regresyon modellerinin değerlendirme metrik değerleri

Metrik	<u>1H</u>	<u>3H</u>	<u>6H</u>	<u>12H</u>	<u>24H</u>	<u>72H</u>
<u>RMSE</u>	0,086036	0,091652	0,092704	0,108497	0,117502	0,161225
<u>MAE</u>	0,057323	0,058563	0,061271	0,069006	0,071643	0,088256
<u>R^2</u>	0,95997	0,958445	0,936188	0,928983	0,928796	0,733571
<u>MSE</u>	0,007402	0,0084	0,008594	0,011772	0,013807	0,025994

LSTM algoritması kullanılarak 1 saat, 3 saat, 6 saat, 12 saat, 24 saat ve 72 saatlik periyotlarda 1 dakikalık örnekleme frekansı ile dalga periyodu tahmini yapılmıştır. LSTM algoritması ile eğitilen tüm regresyon modellerinin test ve tahmin verileri elde edilerek bu değerlerin karşılaştırılması yapılmıştır. LSTM algoritması ile eğitilen modelin 3 saatlik süre için dalga periyodu tahmin ve test verilerinin karşılaştırılması, Şekil 6.24'te gösterilmiştir. Bu görselde, modelin 3 saatlik tahmin periyodunda ne kadar doğru sonuçlar verdiği ve test verileriyle karşılaştırıldığında modelin tahmin performansı görsel olarak sunulmaktadır.



Şekil 6.24 LSTM regresyon modelinin dalga periyodu için 3 saatlik tahmin ve test verilerinin karşılaştırılması

LSTM algoritması kullanılarak çalışmaya konu olan 6 farklı saat dilimi için dalga periyodu tahmin edecek regresyon modelleri eğitilmiştir. Dalga periyodu için regresyon modelinin değerlendirme metrik değerleri hesaplanmıştır. LSTM modelleri için değerlendirme metrikleri Tablo 6.24'te verilmiştir. LSTM regresyon modellerinin metrik değerleri incelendiğinde:


- RMSE değerinin en düşük değeri 1 saatlik tahmin için 0,110, en yüksek değeri ise 72 saatlik tahmin için 0,160 olarak elde edilmiştir.
- MAE değerleri arasında en düşük değer 1 saatlik tahmin için 0,078, en yüksek değer ise 72 saatlik tahmin için 0,085 olarak gözlemlenmiştir.
- R^2 korelasyon değeri arasında en yüksek korelasyon 1 saatlik tahmin için 0,876, en düşük korelasyon değeri ise 72 saatlik tahmin için 0,697 olarak hesaplanmıştır.
- MSE değerleri incelendiğinde, en düşük değer 1 saatlik tahmin için 0,012, en yüksek değer ise 72 saatlik tahmin için 0,025 olarak gözlemlenmiştir.

Tablo 6.24 Dalga periyodu için saat aralıklarına göre LSTM regresyon modellerinin değerlendirme metrik değerleri

Metrik	<u>1H</u>	<u>3H</u>	<u>6H</u>	<u>12H</u>	<u>24H</u>	<u>72H</u>
<u>RMSE</u>	0,110013	0,11067	0,116281	0,12421	0,124388	0,160481
<u>MAE</u>	0,078476	0,0814	0,083008	0,08495	0,085382	0,085868
<u>R²</u>	0,876404	0,873793	0,866404	0,853033	0,835652	0,697848
<u>MSE</u>	0,012103	0,012248	0,013521	0,015428	0,015472	0,025754

6.2.5 RNN regresyon modeli performansı

RNN algoritması kullanılarak, 1 saat, 3 saat, 6 saat, 12 saat, 24 saat ve 72 saatlik periyotlarda 1 dakikalık örnekleme frekansı ile dalga boyu yüksekliği tahmini yapılmıştır. RNN algoritması ile eğitilen tüm regresyon modellerinin test ve tahmin verileri elde edilerek bu değerlerin karşılaştırılması yapılmıştır. RNN algoritması ile eğitilen modelin 12 saatlik periyot için tahmin ve test verilerinin karşılaştırılması Şekil 6.25'te gösterilmiştir.



Şekil 6.25 RNN regresyon modelinin dalga yüksekliği için 12 saatlik tahmin ve test verilerinin karşılaştırılması

RNN algoritması kullanılarak çalışmaya konu olan 6 farklı saat dilimi için dalga yüksekliğini tahmin edecek regresyon modelleri eğitilmiştir. Regresyon modelinin

değerlendirme metrik değerleri hesaplanmıştır. RNN modelleri için değerlendirme metrikleri Tablo 6.25'te verilmiştir.

RNN regresyon modellerinin metrik değerleri incelendiğinde, aşağıdaki sonuçlar gözlenmiştir:


- RMSE: En düşük değer 1 saatlik tahmin için 0,197, en yüksek değer ise 72 saatlik tahmin için 0,279 olarak elde edilmiştir.
- MAE: En düşük değer 1 saatlik tahmin için 0,134, en yüksek değer ise 72 saatlik tahmin için 0,198 olarak gözlenmiştir.
- R^2 : En yüksek korelasyon 1 saatlik tahmin için 0,794, en düşük korelasyon ise 72 saatlik tahmin için 0,524 olarak hesaplanmıştır.
- MSE: En düşük değer 1 saatlik tahmin için 0,038, en yüksek değer ise 72 saatlik tahmin için 0,078 olarak gözlenmiştir.

Tablo 6.25 Dalga yüksekliği için saat aralıklarına göre RNN regresyon modellerinin değerlendirme metrik değerleri

Metrik	<u>1H</u>	<u>3H</u>	<u>6H</u>	<u>12H</u>	<u>24H</u>	<u>72H</u>
<u>RMSE</u>	0,197159	0,20127	0,208248	0,209843	0,250989	0,279693
<u>MAE</u>	0,134101	0,134959	0,141385	0,146861	0,177206	0,198724
<u>R^2</u>	0,794153	0,755148	0,75329	0,713931	0,68098	0,524752
<u>MSE</u>	0,038872	0,04051	0,043367	0,044034	0,062996	0,078228

RNN algoritması kullanılarak 1 saat, 3 saat, 6 saat, 12 saat, 24 saat ve 72 saatlik periyotlarda 1 dakikalık örnekleme frekansı ile dalga periyodu tahmini yapılmıştır. RNN algoritması ile eğitilen tüm regresyon modellerinin test ve tahmin verileri elde edilerek bu değerlerin karşılaştırılması yapılmıştır.

RNN algoritması ile eğitilen modelin 12 saatlik süre için dalga periyodu tahmini, tahmin ve test verilerinin karşılaştırılması Şekil 6.26'da gösterilmiştir. Bu görsel, modelin 12 saatlik periyotta dalga periyodu tahminindeki doğruluğunu görsel olarak değerlendirmeye olanak tanımaktadır.



Şekil 6.26 RNN regresyon modelinin dalga periyodu için 12 saatlik tahmin ve test verilerinin karşılaştırılması

RNN algoritması kullanılarak çalışmaya konu olan 6 farklı saat dilimi için dalga periyodu tahmin edecek regresyon modelleri eğitilmiştir. Dalga periyodu için regresyon modelinin değerlendirme metrik değerleri hesaplanmıştır. RNN modelleri için değerlendirme metrikleri Tablo 6.26'da gösterilmiştir.

RNN regresyon modellerinin metrik değerleri incelendiğinde, elde edilen sonuçlar şu şekildedir:


- RMSE: En düşük değeri 1 saatlik tahmin için 0,111, en yüksek değeri ise 72 saatlik tahmin için 0,174 olarak gözlemlenmiştir.
- MAE: En düşük değeri 1 saatlik tahmin için 0,072, en yüksek değeri ise 72 saatlik tahmin için 0,089 olarak belirlenmiştir.
- R^2 : En yüksek korelasyon değeri 1 saatlik tahmin için 0,864, en düşük korelasyon değeri ise 72 saatlik tahmin için 0,640 olarak hesaplanmıştır.
- MSE: En düşük değeri 1 saatlik tahmin için 0,012, en yüksek değeri ise 72 saatlik tahmin için 0,030 olarak gözlemlenmiştir.

Tablo 6.26 Dalga periyodu için saat aralıklarına göre RNN regresyon modellerinin değerlendirme metrik değerleri

Metrik	<u>1H</u>	<u>3H</u>	<u>6H</u>	<u>12H</u>	<u>24H</u>	<u>72H</u>
<u>RMSE</u>	0,111433	0,116323	0,120826	0,131112	0,134289	0,174062
<u>MAE</u>	0,072581	0,073145	0,079323	0,081553	0,082873	0,08993
<u>R²</u>	0,864448	0,862282	0,85886	0,828543	0,822575	0,640624
<u>MSE</u>	0,012417	0,013531	0,014599	0,01719	0,018034	0,030298

6.2.6 SVM regresyon modeli performansı

SVM algoritması kullanılarak 1 saat, 3 saat, 6 saat, 12 saat, 24 saat ve 72 saatlik periyotlarda 1 dakikalık örnekleme frekansı ile dalga boyu yüksekliği tahmini yapılmıştır. SVM algoritması ile eğitilen tüm regresyon modellerinin test ve tahmin verileri elde edilerek bu değerlerin karşılaştırılması yapılmıştır. SVM algoritması ile eğitilen modelin 72 saatlik periyot için tahmin ve test verilerinin karşılaştırılması Şekil 6.27'de gösterilmiştir.



Şekil 6.27 SVM regresyon modelinin dalga yüksekliği için 72 saatlik tahmin ve test verilerinin karşılaştırılması


SVM algoritması kullanılarak çalışmaya konu olan 6 farklı saat dilimi için dalga yüksekliğini tahmin edecek regresyon modelleri eğitilmiştir. Regresyon modelinin değerlendirme metrik değerleri hesaplanmıştır. SVM modelleri için değerlendirme

metrikleri Tablo 6.27'de verilmiştir. SVM regresyon modellerinin metrik değerleri incelendiğinde, RMSE değerinin en düşük değeri 1 saatlik tahmin için 0,095, en yüksek değeri 72 saatlik tahmin için 0,181 olarak elde edildiği gözlemlenmiştir. MAE değerleri arasında en düşük değer 1 saatlik tahmin için 0,058, en yüksek değer 72 saatlik tahmin için 0,099'dur. R^2 korelasyon değeri arasında en yüksek korelasyon 1 saatlik tahmin için 0,932, en düşük korelasyon 72 saatlik tahmin için 0,800'dir. MSE değerleri incelendiği zaman en düşük değer 1 saatlik tahmin için 0,009, en yüksek değer 72 saatlik tahmin için 0,032 olarak ortaya çıkmıştır.

Tablo 6.27 Dalga yüksekliği için saat aralıklarına göre SVM regresyon modellerinin değerlendirme metrik değerleri

Metrik	<u>1H</u>	<u>3H</u>	<u>6H</u>	<u>12H</u>	<u>24H</u>	<u>72H</u>
<u>RMSE</u>	0,09591	0,109891	0,111441	0,120484	0,14427	0,181559
<u>MAE</u>	0,058817	0,063968	0,065655	0,067731	0,090052	0,099443
<u>R²</u>	0,932182	0,930722	0,907536	0,904027	0,892485	0,800572
<u>MSE</u>	0,009199	0,012076	0,012419	0,014516	0,020814	0,032964

SVM algoritması kullanılarak 1, 3 saat, 6, 12, 24 ve 72 saatlik periyotlarda dalga periyodu tahmini yapılmıştır. SVM algoritması ile eğitilen tüm regresyon modellerinin test ve tahmin verileri elde edilerek bu değerlerin karşılaştırılması yapılmıştır. Eğitilen modelin dalga periyodu tahmini ve test verilerinin karşılaştırılması Şekil 6.28'de gösterilmiştir.



Şekil 6.28 SVM regresyon modelinin dalga periyodu için 72 saatlik tahmin ve test verilerinin karşılaştırılması

SVM algoritması kullanılarak çalışmaya konu olan 6 farklı saat dilimi için dalga periyodu tahmin edecek regresyon modelleri eğitilmiştir. Dalga periyodu için regresyon modelinin değerlendirme metrik değerleri hesaplanmıştır. SVM modelleri için değerlendirme metrikleri Tablo 6.28’de verilmiştir. SVM regresyon modellerinin metrik değerleri incelendiğinde:

- RMSE: En düşük değer 1 saatlik tahmin için 0,072, en yüksek değer 72 saatlik tahmin için 0,100 olarak elde edilmiştir. Bu, modelin tahminlerinin hata seviyesini gösterir; 1 saatlik tahminlerde daha düşük hata, 72 saatlik tahminlerde ise daha yüksek hata görülmektedir.
- MAE: En düşük değer 1 saatlik tahmin için 0,053, en yüksek değer 72 saatlik tahmin için 0,068 olarak gözlenmiştir. Bu, tahminlerin ortalama mutlak hatalarını gösterir; 1 saatlik tahminlerde hata daha düşük, 72 saatlik tahminlerde daha yüksek olmuştur.
- R^2 : En yüksek korelasyon 1 saatlik tahmin için 0,944, en düşük korelasyon değeri ise 72 saatlik tahmin için 0,903 olarak hesaplanmıştır. Bu, modelin veriye ne kadar iyi uyduğunu gösterir; 1 saatlik tahminlerde modelin açıklama gücü yüksek, 72 saatlik tahminlerde ise biraz daha düşük olmuştur.
- MSE: En düşük değer 1 saatlik tahmin için 0,005, en yüksek değer 72 saatlik tahmin için 0,010 olarak gözlenmiştir. Bu metrik, tahmin hatalarının karelerinin ortalamasını ifade eder; daha düşük MSE değeri, modelin daha doğru tahminler yaptığını gösterir.

Bu metriklerle modelin doğruluğu ve tahmin başarısını değerlendirildiğinde 1 saatlik tahminlerin genellikle daha doğru olduğu, 72 saatlik tahminlerin ise daha fazla hata içerdiği görülmüştür.

Tablo 6.28 Dalga periyodu için saat aralıklarına göre SVM regresyon modellerinin değerlendirme metrik değerleri

Metrik	<u>1H</u>	<u>3H</u>	<u>6H</u>	<u>12H</u>	<u>24H</u>	<u>72H</u>
<u>RMSE</u>	0,072939	0,072984	0,079906	0,094031	0,099423	0,100261
<u>MAE</u>	0,053644	0,058981	0,060446	0,061568	0,062896	0,068725
<u>R^2</u>	0,944625	0,936283	0,922587	0,919481	0,906184	0,903403
<u>MSE</u>	0,00532	0,005327	0,006385	0,008842	0,009885	0,010052

6.3 Ordu Şamandırası için Regresyon Modellerinin Saat Aralıklarındaki Performanslarının Karşılaştırılması

6.3.1 Dalga boyu yüksekliği tahmini

Çalışmada kullanılan 6 temel regresyon modelinin 1 saatlik dalga boyu yüksekliği tahminleri elde edilmiştir. Bu tahminlerin test verileri ile karşılaştırılması sonucunda ilgili 4 değerlendirme metriği hesaplanmıştır. 1 saatlik tahmin aralığında regresyon modellerinin değerlendirme metriklerinin değerleri Tablo 6.29’da gösterilmiştir.

- RMSE: En düşük RMSE değeri ResNet algoritmasında 0,010, en yüksek RMSE değeri ise RNN algoritmasında 0,143 olarak gözlenmiştir. Bu, ResNet modelinin 1 saatlik tahminler için daha düşük hata payı sunduğunu, RNN modelinin ise daha yüksek hata payı içerdiğini gösterir.
- MAE: En düşük MAE değeri ResNet algoritmasında 0,006, en yüksek MAE değeri ise Bayesian algoritmasında 0,067 olarak gözlenmiştir. Bu da, ResNet modelinin daha doğru tahminler yaptığı, Bayesian modelinin ise daha yüksek hata payı taşıdığı anlamına gelir.
- R^2 : En düşük R^2 değeri RNN algoritmasında 0,790, en yüksek R^2 değeri ise ResNet algoritmasında 0,998 olarak gözlenmiştir. Bu, ResNet modelinin 1 saatlik tahminlerde test verilerine en iyi uyum sağladığını, RNN modelinin ise daha düşük uyum gösterdiğini belirtir.
- MSE: En düşük MSE değeri ResNet algoritmasında 0,0001, en yüksek MSE değeri ise RNN algoritmasında 0,020 olarak gözlenmiştir. Bu, ResNet modelinin 1 saatlik tahminlerde en küçük hata karelerine sahip olduğunu, RNN modelinin ise daha büyük hata karelerine sahip olduğunu gösterir.

Tablo 6.29 1 saatlik dalga boyu yüksekliği tahmin aralığı için temel regresyon modellerinin değerlendirme metrik değerleri

Metrik	<u>Bayesian</u>	<u>ELM</u>	<u>LSTM</u>	<u>ResNet</u>	<u>RNN</u>	<u>SVM</u>
<u>RMSE</u>	0,075166	0,049639	0,074762	0,0106	0,143326	0,02364
<u>MAE</u>	0,067638	0,041825	0,041834	0,006426	0,087251	0,019045
<u>R^2</u>	0,996325	0,994779	0,971351	0,998193	0,790172	0,988615
<u>MSE</u>	0,00565	0,002464	0,005589	0,000112	0,020542	0,000559

Çalışmada kullanılan 6 temel regresyon modelinin 3 saatlik dalga boyu yüksekliği tahminleri elde edilmiştir. Bu tahminlerin test verileri ile karşılaştırılması sonucunda ilgili 4 değerlendirme metriği hesaplanmıştır. 3 saatlik tahmin aralığında regresyon modellerinin değerlendirme metriklerinin değerleri Tablo 6.30’da gösterilmiştir.

- RMSE: En düşük RMSE değeri ResNet algoritmasında 0,030, en yüksek RMSE değeri ise RNN algoritmasında 0,164 olarak gözlenmiştir. Bu, ResNet modelinin 3 saatlik tahminler için daha düşük hata payı sunduğunu, RNN modelinin ise daha yüksek hata payı içerdiğini gösterir.
- MAE: En düşük MAE değeri ResNet algoritmasında 0,022, en yüksek MAE değeri ise RNN algoritmasında 0,096 olarak gözlenmiştir. Bu, ResNet modelinin daha doğru tahminler yaptığı, RNN modelinin ise daha yüksek hata payı taşıdığı anlamına gelir.
- R^2 : En düşük R^2 değeri RNN algoritmasında 0,785, en yüksek R^2 değeri ise ResNet algoritmasında 0,997 olarak gözlenmiştir. Bu, ResNet modelinin 3 saatlik tahminlerde test verilerine en iyi uyum sağladığını, RNN modelinin ise daha düşük uyum gösterdiğini belirtir.
- MSE: En düşük MSE değeri ResNet algoritmasında 0,0009, en yüksek MSE değeri ise RNN algoritmasında 0,027 olarak gözlenmiştir. Bu, ResNet modelinin 3 saatlik tahminlerde en küçük hata karelerine sahip olduğunu, RNN modelinin ise daha büyük hata karelerine sahip olduğunu gösterir.

Tablo 6.30 3 saatlik dalga boyu yüksekliği tahmin aralığı için temel regresyon modellerinin değerlendirme metrik değerleri

Metrik	<u>Bayesian</u>	<u>ELM</u>	<u>LSTM</u>	<u>ResNet</u>	<u>RNN</u>	<u>SVM</u>
<u>RMSE</u>	0,093136	0,060707	0,089147	0,030679	0,164466	0,078867
<u>MAE</u>	0,06818	0,043851	0,043547	0,022436	0,09638	0,04985
<u>R^2</u>	0,994178	0,972623	0,971041	0,997575	0,785919	0,977537
<u>MSE</u>	0,008674	0,003685	0,007947	0,000941	0,027049	0,00622

Çalışmada kullanılan 6 temel regresyon modelinin 6 saatlik dalga boyu yüksekliği tahminleri elde edilmiştir. Bu tahminlerin test verileri ile karşılaştırılması sonucunda ilgili 4 değerlendirme metriği hesaplanmıştır. 6 saatlik tahmin aralığında regresyon modellerinin değerlendirme metriklerinin değerleri Tablo 6.31’de gösterilmiştir.

- RMSE: En düşük RMSE değeri ResNet algoritmasında 0,032, en yüksek RMSE değeri ise RNN algoritmasında 0,169 olarak gözlenmiştir. Bu, ResNet modelinin 6 saatlik tahminler için daha düşük hata payı sunduğunu, RNN modelinin ise daha yüksek hata payı içerdiğini gösterir.
- MAE: En düşük MAE değeri ResNet algoritmasında 0,022, en yüksek MAE değeri ise RNN algoritmasında 0,111 olarak gözlenmiştir. Bu, ResNet modelinin daha doğru tahminler yaptığı, RNN modelinin ise daha yüksek hata payı taşıdığı anlamına gelir.
- R^2 : En düşük R^2 değeri RNN algoritmasında 0,778, en yüksek R^2 değeri ise ResNet algoritmasında 0,996 olarak gözlenmiştir. Bu, ResNet modelinin 6 saatlik tahminlerde test verilerine en iyi uyum sağladığını, RNN modelinin ise daha düşük uyum gösterdiğini belirtir.
- MSE: En düşük MSE değeri ResNet algoritmasında 0,001, en yüksek MSE değeri ise RNN algoritmasında 0,028 olarak gözlenmiştir. Bu, ResNet modelinin 6 saatlik tahminlerde en küçük hata karelerine sahip olduğunu, RNN modelinin ise daha büyük hata karelerine sahip olduğunu gösterir.

Tablo 6.31 6 saatlik dalga boyu yüksekliği tahmin aralığı için temel regresyon modellerinin değerlendirme metrik değerleri

Metrik	<i>Bayesian</i>	<i>ELM</i>	<i>LSTM</i>	<i>ResNet</i>	<i>RNN</i>	<i>SVM</i>
<u>RMSE</u>	0,093903	0,082829	0,099232	0,032634	0,169378	0,095549
<u>MAE</u>	0,072437	0,063625	0,063768	0,022836	0,111766	0,060171
<u>R^2</u>	0,994663	0,972488	0,969386	0,996594	0,778063	0,973693
<u>MSE</u>	0,008818	0,006861	0,009847	0,001065	0,028689	0,00913

Çalışmada kullanılan 6 temel regresyon modelinin 12 saatlik dalga boyu yüksekliği tahminleri elde edilmiştir. Bu tahminlerin test verileri ile karşılaştırılması sonucunda ilgili 4 değerlendirme metriği hesaplanmıştır. 12 saatlik tahmin aralığında regresyon modellerinin değerlendirme metriklerinin değerleri Tablo 6.32’de gösterilmiştir.

- RMSE: En düşük RMSE değeri ResNet algoritmasında 0,038, en yüksek RMSE değeri ise RNN algoritmasında 0,172 olarak gözlenmiştir. Bu, ResNet modelinin 12 saatlik tahminler için daha düşük hata payı sunduğunu, RNN modelinin ise daha yüksek hata payı içerdiğini gösterir.

- MAE: En düşük MAE değeri ResNet algoritmasında 0,023, en yüksek MAE değeri ise RNN algoritmasında 0,111 olarak gözlenmiştir. Bu, ResNet modelinin daha doğru tahminler yaptığı, RNN modelinin ise daha yüksek hata payı taşıdığı anlamına gelir.
- R²: En düşük R² değeri RNN algoritmasında 0,769, en yüksek R² değeri ise ResNet algoritmasında 0,995 olarak gözlenmiştir. Bu, ResNet modelinin 12 saatlik tahminlerde test verilerine en iyi uyum sağladığını, RNN modelinin ise daha düşük uyum gösterdiğini belirtir.
- MSE: En düşük MSE değeri ResNet algoritmasında 0,001, en yüksek MSE değeri ise RNN algoritmasında 0,029 olarak gözlenmiştir. Bu, ResNet modelinin 12 saatlik tahminlerde en küçük hata karelerine sahip olduğunu, RNN modelinin ise daha büyük hata karelerine sahip olduğunu gösterir.

Tablo 6.32 12 saatlik dalga boyu yüksekliği tahmin aralığı için temel regresyon modellerinin değerlendirme metrik değerleri

Metrik	<u>Bayesian</u>	<u>ELM</u>	<u>LSTM</u>	<u>ResNet</u>	<u>RNN</u>	<u>SVM</u>
<u>RMSE</u>	0,098844	0,092336	0,106321	0,038877	0,172999	0,099487
<u>MAE</u>	0,080221	0,068917	0,063977	0,023249	0,111847	0,061593
<u>R²</u>	0,992659	0,971656	0,9665	0,995547	0,769303	0,968502
<u>MSE</u>	0,00977	0,008526	0,011304	0,001511	0,029929	0,009898

Çalışmada kullanılan 6 temel regresyon modelinin 24 saatlik dalga boyu yüksekliği tahminleri elde edilmiştir. Bu tahminlerin test verileri ile karşılaştırılması sonucunda ilgili 4 değerlendirme metriği hesaplanmıştır. 24 saatlik tahmin aralığında regresyon modellerinin değerlendirme metriklerinin değerleri Tablo 6.33'te gösterilmiştir.

- RMSE: En düşük RMSE değeri ResNet algoritmasında 0,053, en yüksek RMSE değeri ise RNN algoritmasında 0,186 olarak gözlenmiştir. Bu, ResNet modelinin 24 saatlik tahminler için daha düşük hata payı sunduğunu, RNN modelinin ise daha yüksek hata payı içerdiğini gösterir.
- MAE: En düşük MAE değeri ResNet algoritmasında 0,029, en yüksek MAE değeri ise RNN algoritmasında 0,122 olarak gözlenmiştir. Bu, ResNet modelinin daha doğru tahminler yaptığı, RNN modelinin ise daha yüksek hata payı taşıdığı anlamına gelir.

- R^2 : En düşük R^2 değeri RNN algoritmasında 0,752, en yüksek R^2 değeri ise ResNet algoritmasında 0,995 olarak gözlenmiştir. Bu, ResNet modelinin 24 saatlik tahminlerde test verilerine en iyi uyum sağladığını, RNN modelinin ise daha düşük uyum gösterdiğini belirtir.
- MSE: En düşük MSE değeri ResNet algoritmasında 0,002, en yüksek MSE değeri ise RNN algoritmasında 0,034 olarak gözlenmiştir. Bu, ResNet modelinin 24 saatlik tahminlerde en küçük hata karelerine sahip olduğunu, RNN modelinin ise daha büyük hata karelerine sahip olduğunu gösterir.

Tablo 6.33 24 saatlik dalga boyu yüksekliği tahmin aralığı için temel regresyon modellerinin değerlendirme metrik değerleri

Metrik	<i>Bayesian</i>	<i>ELM</i>	<i>LSTM</i>	<i>ResNet</i>	<i>RNN</i>	<i>SVM</i>
<u>RMSE</u>	0,107352	0,097664	0,107242	0,053308	0,186414	0,100649
<u>MAE</u>	0,100109	0,070293	0,075215	0,029286	0,122545	0,066354
<u>R^2</u>	0,991174	0,965049	0,964748	0,995186	0,752123	0,952799
<u>MSE</u>	0,011525	0,009538	0,011501	0,002842	0,03475	0,01013

Çalışmada kullanılan 6 temel regresyon modelinin 72 saatlik dalga boyu yüksekliği tahminleri elde edilmiştir. 72 saatlik tahmin aralığında regresyon modellerinin değerlendirme metriklerinin değerleri Tablo 6.34’te gösterilmiştir.

- RMSE: En düşük RMSE değeri ResNet algoritmasında 0,055, en yüksek RMSE değeri ise RNN algoritmasında 0,205 olarak gözlenmiştir. Bu, ResNet modelinin 72 saatlik tahminler için daha düşük hata payı sunduğunu, RNN modelinin ise daha yüksek hata payı içerdiğini gösterir.
- MAE: En düşük MAE değeri ResNet algoritmasında 0,045, en yüksek MAE değeri ise RNN algoritmasında 0,127 olarak gözlenmiştir. Bu, ResNet modelinin daha doğru tahminler yaptığı, RNN modelinin ise daha yüksek hata payı taşıdığı anlamına gelir.
- R^2 : En düşük R^2 değeri RNN algoritmasında 0,702, en yüksek R^2 değeri ise ResNet algoritmasında 0,988 olarak gözlenmiştir. Bu, ResNet modelinin 72 saatlik tahminlerde test verilerine en iyi uyum sağladığını, RNN modelinin ise daha düşük uyum gösterdiğini belirtir.
- MSE: En düşük MSE değeri ResNet algoritmasında 0,003, en yüksek MSE değeri ise RNN algoritmasında 0,042 olarak gözlenmiştir. Bu, ResNet modelinin 72

saatlik tahminlerde en küçük hata karelerine sahip olduğunu, RNN modelinin ise daha büyük hata karelerine sahip olduğunu gösterir.

Tablo 6.34 72 saatlik dalga boyu yüksekliği tahmin aralığı için temel regresyon modellerinin değerlendirme metrik değerleri

Metrik	<i><u>Bayesian</u></i>	<i><u>ELM</u></i>	<i><u>LSTM</u></i>	<i><u>ResNet</u></i>	<i><u>RNN</u></i>	<i><u>SVM</u></i>
<i><u>RMSE</u></i>	0,119669	0,100297	0,119611	0,055508	0,205843	0,135608
<i><u>MAE</u></i>	0,103577	0,081398	0,085013	0,045202	0,127443	0,078272
<i><u>R²</u></i>	0,985991	0,95908	0,803059	0,988186	0,702335	0,925361
<i><u>MSE</u></i>	0,014321	0,01006	0,014307	0,003081	0,042371	0,018389

6.3.2 Dalga periyodu tahmini

Çalışmada kullanılan 6 temel regresyon modelinin 1 saatlik dalga periyodu tahminleri elde edilmiştir. Bu tahminlerin test verileri ile karşılaştırılması sonucunda ilgili 4 değerlendirme metriği hesaplanmıştır. 1 saatlik tahmin aralığında regresyon modellerinin değerlendirme metriklerinin değerleri Tablo 6.35’te gösterilmiştir.

- RMSE: En düşük RMSE değeri ResNet algoritmasında 0,033, en yüksek RMSE değeri ise RNN algoritmasında 0,139 olarak gözlenmiştir. Bu, ResNet modelinin 1 saatlik tahminlerde daha düşük hata payı sunduğunu, RNN modelinin ise daha yüksek hata payı içerdiğini gösterir.
- MAE: En düşük MAE değeri ResNet algoritmasında 0,026, en yüksek MAE değeri ise RNN algoritmasında 0,099 olarak gözlenmiştir. Bu, ResNet modelinin daha doğru tahminler yaptığı, RNN modelinin ise daha yüksek hata payı taşıdığı anlamına gelir.
- R²: En düşük R² değeri RNN algoritmasında 0,816, en yüksek R² değeri ise ResNet algoritmasında 0,982 olarak gözlenmiştir. Bu, ResNet modelinin 1 saatlik tahminlerde test verilerine en iyi uyum sağladığını, RNN modelinin ise daha düşük uyum gösterdiğini belirtir.
- MSE: En düşük MSE değeri ResNet algoritmasında 0,001, en yüksek MSE değeri ise RNN algoritmasında 0,019 olarak gözlenmiştir. Bu, ResNet modelinin 1 saatlik tahminlerde en küçük hata karelerine sahip olduğunu, RNN modelinin ise daha büyük hata karelerine sahip olduğunu gösterir.

Tablo 6.35 1 saatlik dalga periyodu tahmin aralığı için temel regresyon modellerinin değerlendirme metrik değerleri

Metrik	<i>Bayesian</i>	<i>ELM</i>	<i>LSTM</i>	<i>ResNet</i>	<i>RNN</i>	<i>SVM</i>
<i>RMSE</i>	0,080162	0,046294	0,115953	0,033254	0,139281	0,043475
<i>MAE</i>	0,06247	0,032636	0,090511	0,026929	0,099923	0,027909
<i>R²</i>	0,956043	0,98049	0,863821	0,982226	0,816096	0,96962
<i>MSE</i>	0,006426	0,002143	0,013445	0,001106	0,019399	0,00189

3 saatlik tahminlerin test verileri ile karşılaştırılması sonucunda ilgili 4 değerlendirme metriği hesaplanmıştır. 3 saatlik tahmin aralığında regresyon modellerinin değerlendirme metriklerinin değerleri Tablo 6.36’da gösterilmiştir.

- RMSE: En düşük RMSE değeri ResNet algoritmasında 0,050, en yüksek RMSE değeri ise RNN algoritmasında 0,142 olarak gözlenmiştir. Bu, ResNet modelinin 3 saatlik tahminlerde daha düşük hata payı sunduğunu, RNN modelinin ise daha yüksek hata payı içerdiğini gösterir.
- MAE: En düşük MAE değeri ResNet algoritmasında 0,038, en yüksek MAE değeri ise RNN algoritmasında 0,106 olarak gözlenmiştir. Bu, ResNet modelinin daha doğru tahminler yaptığı, RNN modelinin ise daha yüksek hata payı taşıdığı anlamına gelir.
- R²: En düşük R² değeri RNN algoritmasında 0,810, en yüksek R² değeri ise ResNet algoritmasında 0,979 olarak gözlenmiştir. Bu, ResNet modelinin 3 saatlik tahminlerde test verilerine en iyi uyum sağladığını, RNN modelinin ise daha düşük uyum gösterdiğini belirtir.
- MSE: En düşük MSE değeri ResNet algoritmasında 0,002, en yüksek MSE değeri ise RNN algoritmasında 0,020 olarak gözlenmiştir. Bu, ResNet modelinin 3 saatlik tahminlerde en küçük hata karelerine sahip olduğunu, RNN modelinin ise daha büyük hata karelerine sahip olduğunu gösterir.

Tablo 6.36 3 saatlik dalga periyodu tahmin aralığı için temel regresyon modellerinin değerlendirme metrik değerleri

Metrik	<i>Bayesian</i>	<i>ELM</i>	<i>LSTM</i>	<i>ResNet</i>	<i>RNN</i>	<i>SVM</i>
<i>RMSE</i>	0,085886	0,055019	0,125044	0,050559	0,142251	0,065911
<i>MAE</i>	0,065856	0,048991	0,100137	0,038486	0,103231	0,041561
<i>R²</i>	0,924935	0,952701	0,863389	0,97965	0,810096	0,955993
<i>MSE</i>	0,007376	0,003027	0,015636	0,002556	0,020235	0,004344

Çalışmada kullanılan 6 temel regresyon modelinin 6 saatlik dalga periyodu tahminleri elde edilmiştir. Bu tahminlerin test verileri ile karşılaştırılması sonucunda ilgili 4 değerlendirme metriği hesaplanmıştır. 6 saatlik tahmin aralığında regresyon modellerinin değerlendirme metriklerinin değerleri Tablo 6.37’de gösterilmiştir.

- RMSE: En düşük RMSE değeri ResNet algoritmasında 0,054, en yüksek RMSE değeri ise RNN algoritmasında 0,149 olarak gözlenmiştir. Bu sonuç, ResNet modelinin 6 saatlik tahminlerde daha düşük hata payı sunduğunu, RNN modelinin ise daha yüksek hata payına sahip olduğunu göstermektedir.
- MAE: En düşük MAE değeri ResNet algoritmasında 0,041, en yüksek MAE değeri ise RNN algoritmasında 0,108 olarak gözlenmiştir. Bu, ResNet modelinin daha doğru tahminler yaptığını, RNN modelinin ise daha büyük sapmalara sahip olduğunu ifade eder.
- R^2 : En düşük R^2 değeri RNN algoritmasında 0,806, en yüksek R^2 değeri ise ResNet algoritmasında 0,977 olarak gözlenmiştir. Bu durum, ResNet modelinin test verilerine en iyi uyum sağladığını, RNN modelinin ise daha düşük bir uyum sunduğunu belirtir.
- MSE: En düşük MSE değeri ResNet algoritmasında 0,002, en yüksek MSE değeri ise RNN algoritmasında 0,022 olarak gözlenmiştir. Bu, ResNet modelinin hata karelerinin en düşük olduğunu, RNN modelinin ise daha büyük hata karelerine sahip olduğunu gösterir.

Tablo 6.37 6 saatlik dalga periyodu tahmin aralığı için temel regresyon modellerinin değerlendirme metrik değerleri

Metrik	<u>Bayesian</u>	<u>ELM</u>	<u>LSTM</u>	<u>ResNet</u>	<u>RNN</u>	<u>SVM</u>
<u>RMSE</u>	0,097911	0,083154	0,136244	0,054543	0,149376	0,069527
<u>MAE</u>	0,072963	0,065663	0,110734	0,041655	0,108363	0,0445
<u>R^2</u>	0,915901	0,951344	0,83102	0,977666	0,806636	0,955791
<u>MSE</u>	0,009587	0,006915	0,018562	0,002975	0,022313	0,004834

6 temel regresyon modelinin 12 saatlik dalga periyodu tahminleri elde edilmiş ve bu tahminler test verileriyle karşılaştırılarak 4 farklı değerlendirme metriği hesaplanmıştır. 12 saatlik tahmin aralığında regresyon modellerine ait metrikler Tablo 6.38’de sunulmuştur.

- RMSE: En düşük RMSE değeri ResNet algoritmasında 0,057, en yüksek ise RNN algoritmasında 0,154 olarak tespit edilmiştir. Bu durum, ResNet modelinin daha düşük hata oranına sahip olduğunu, RNN modelinin ise tahminlerde daha büyük hatalar yaptığını göstermektedir.
- MAE: MAE değerleri arasında en düşük değer ResNet algoritmasında 0,045, en yüksek değer ise RNN algoritmasında 0,116 olarak gözlemlenmiştir. Bu, ResNet modelinin tahminlerinde daha az sapma olduğunu, RNN modelinin ise daha büyük sapmalar içerdiğini ifade etmektedir.
- R^2 : En yüksek R^2 değeri ResNet algoritmasında 0,971, en düşük R^2 değeri ise RNN algoritmasında 0,803 olarak hesaplanmıştır. Bu sonuç, ResNet modelinin test verilerine en iyi uyumu sağladığını, RNN modelinin ise diğer modellere göre daha zayıf bir uyum sunduğunu göstermektedir.
- MSE: MSE değerleri arasında en düşük değer ResNet algoritmasında 0,003, en yüksek değer ise RNN algoritmasında 0,023 bulunmuştur. Bu, ResNet modelinin hata karelerinin en düşük seviyede olduğunu, ortaya koymaktadır.

Tablo 6.38 12 saatlik dalga periyodu tahmin aralığı için temel regresyon modellerinin değerlendirme metrik değerleri

Metrik	<u>Bayesian</u>	<u>ELM</u>	<u>LSTM</u>	<u>ResNet</u>	<u>RNN</u>	<u>SVM</u>
<u>RMSE</u>	0,105624	0,084315	0,143337	0,057455	0,154562	0,091487
<u>MAE</u>	0,074304	0,06759	0,122836	0,045031	0,116321	0,060055
<u>R²</u>	0,902526	0,927657	0,829296	0,971041	0,803464	0,941648
<u>MSE</u>	0,011156	0,007109	0,020546	0,003301	0,023889	0,00837

24 saatlik tahmin aralığında 6 temel regresyon modelinin performansı değerlendirilmiş ve sonuçlar Tablo 6.39’da sunulmuştur.

- RMSE: En düşük hata değeri ResNet algoritmasında (0,061), en yüksek ise RNN algoritmasında (0,166) elde edilmiştir.
- MAE: ResNet modeli 0,049 ile en düşük, RNN modeli ise 0,134 ile en yüksek sapmayı göstermiştir.
- R^2 : Korelasyon değerleri arasında en iyi uyum 0,965 ile ResNet algoritmasında, en zayıf uyum ise 0,790 ile RNN algoritmasında görülmüştür.
- MSE: Hata karelerinin ortalaması açısından, ResNet modeli 0,003 ile en düşük, RNN modeli ise 0,027 ile en yüksek değeri sağlamıştır.

Tablo 6.39 24 saatlik dalga periyodu tahmin aralığı için temel regresyon modellerinin değerlendirme metrik değerleri

Metrik	<i>Bayesian</i>	<i>ELM</i>	<i>LSTM</i>	<i>ResNet</i>	<i>RNN</i>	<i>SVM</i>
<i>RMSE</i>	0,1128	0,100236	0,157332	0,061464	0,166651	0,09236
<i>MAE</i>	0,087042	0,075808	0,125287	0,049179	0,134386	0,062108
<i>R²</i>	0,884166	0,91186	0,76257	0,965608	0,790556	0,926872
<i>MSE</i>	0,012724	0,010047	0,024753	0,003778	0,027773	0,00853

72 saatlik tahmin aralığında 6 temel regresyon modelinin performansı değerlendirilmiş ve sonuçlar Tablo 6.40'ta özetlenmiştir.

- RMSE: En düşük hata değeri ResNet algoritmasında (0,064), en yüksek ise RNN algoritmasında (0,186) elde edilmiştir.
- MAE: ResNet modeli 0,055 ile en düşük, RNN modeli ise 0,141 ile en yüksek sapmayı göstermiştir.
- R²: Korelasyon değerleri arasında en iyi uyum 0,957 ile ResNet algoritmasında, en zayıf uyum ise 0,449 ile RNN algoritmasında görülmüştür.
- MSE: Hata karelerinin ortalaması açısından, ResNet modeli 0,004 ile en düşük, RNN modeli ise 0,034 ile en yüksek değeri sağlamıştır.

Tablo 6.40 72 saatlik dalga periyodu tahmin aralığı için temel regresyon modellerinin değerlendirme metrik değerleri

Metrik	<i>Bayesian</i>	<i>ELM</i>	<i>LSTM</i>	<i>ResNet</i>	<i>RNN</i>	<i>SVM</i>
<i>RMSE</i>	0,140893	0,106887	0,164522	0,064594	0,186932	0,101533
<i>MAE</i>	0,110914	0,083937	0,135849	0,055699	0,141735	0,066574
<i>R²</i>	0,680931	0,900181	0,665794	0,95754	0,449128	0,909565
<i>MSE</i>	0,019851	0,011425	0,027067	0,004172	0,034944	0,010309

6.4 Samsun Şamandırası için Regresyon Modellerinin Saat Aralıklarındaki Performanslarının Karşılaştırılması

6.4.1 Dalga boyu yüksekliği tahmini

Çalışmada kullanılan 6 temel regresyon modeliyle, 1 saatlik dalga boyu yüksekliği tahminleri gerçekleştirilmiş ve bu tahminler test verileriyle karşılaştırılmıştır. Bu karşılaştırma sonucunda, ilgili 4 değerlendirme metriğinin değerleri hesaplanmış ve Tablo 6.41'de sunulmuştur.

- RMSE: En düşük hata değeri, ResNet algoritması ile 0,035 olarak bulunurken, en yüksek hata değeri 0,197 ile RNN algoritmasında gözlenmiştir.
- MAE: Ortalama mutlak hata açısından, ResNet algoritması 0,022 ile en düşük sapmayı, RNN algoritması ise 0,134 ile en yüksek sapmayı göstermiştir.
- R^2 : Korelasyon katsayısı değerlendirildiğinde, 0,993 ile ResNet algoritması en iyi uyumu sağlarken, 0,794 ile RNN algoritması en zayıf uyumu sergilemiştir.
- MSE: Ortalama hata kareleri açısından, en düşük değer 0,001 ile ResNet algoritmasında, en yüksek değer ise 0,038 ile RNN algoritmasında elde edilmiştir.

Tablo 6.41 1 saatlik dalga boyu yüksekliği tahmin aralığı için temel regresyon modellerinin değerlendirme metrik değerleri

Metrik	<i>Bayesian</i>	<i>ELM</i>	<i>LSTM</i>	<i>ResNet</i>	<i>RNN</i>	<i>SVM</i>
<i>RMSE</i>	0,043409	0,081518	0,086036	0,034516	0,197159	0,09591
<i>MAE</i>	0,032196	0,06021	0,057323	0,022081	0,134101	0,058817
<i>R²</i>	0,98034	0,962681	0,95997	0,99331	0,794153	0,932182
<i>MSE</i>	0,001884	0,006645	0,007402	0,001191	0,038872	0,009199

Çalışmada kullanılan 6 temel regresyon modeliyle, 3 saatlik dalga boyu yüksekliği tahminleri gerçekleştirilmiş ve bu tahminler test verileriyle karşılaştırılmıştır. Bu karşılaştırma sonucunda, ilgili 4 değerlendirme metriğinin değerleri hesaplanmış ve Tablo 6.42’de sunulmuştur.

- RMSE: En düşük hata değeri, ResNet algoritması ile 0,035 olarak bulunurken, en yüksek hata değeri 0,201 ile RNN algoritmasında gözlenmiştir.
- MAE: Ortalama mutlak hata açısından, ResNet algoritması 0,022 ile en düşük sapmayı, RNN algoritması ise 0,134 ile en yüksek sapmayı göstermiştir.
- R^2 : Korelasyon katsayısı değerlendirildiğinde, 0,992 ile ResNet algoritması en iyi uyumu sağlarken, 0,755 ile RNN algoritması en zayıf uyumu sergilemiştir.
- MSE: Ortalama hata kareleri açısından, en düşük değer 0,001 ile ResNet algoritmasında, en yüksek değer ise 0,040 ile RNN algoritmasında elde edilmiştir.

Tablo 6.42 3 saatlik dalga boyu yüksekliği tahmin aralığı için temel regresyon modellerinin değerlendirme metrik değerleri

Metrik	<u>Bayesian</u>	<u>ELM</u>	<u>LSTM</u>	<u>ResNet</u>	<u>RNN</u>	<u>SVM</u>
<u>RMSE</u>	0,064599	0,0819	0,091652	0,035642	0,20127	0,109891
<u>MAE</u>	0,052144	0,062441	0,058563	0,022934	0,134959	0,063968
<u>R²</u>	0,980085	0,959419	0,958445	0,992754	0,755148	0,930722
<u>MSE</u>	0,004173	0,006708	0,0084	0,00127	0,04051	0,012076

Çalışmada kullanılan 6 temel regresyon modeliyle, 6 saatlik dalga boyu yüksekliği tahminleri gerçekleştirilmiş ve bu tahminler test verileriyle karşılaştırılmıştır. Bu karşılaştırma sonucunda, ilgili 4 değerlendirme metriğinin değerleri hesaplanmış ve Tablo 6.43'te sunulmuştur.

- RMSE: En düşük hata değeri, ResNet algoritması ile 0,038 olarak bulunurken, en yüksek hata değeri 0,208 ile RNN algoritmasında gözlenmiştir.
- MAE: Ortalama mutlak hata açısından, ResNet algoritması 0,025 ile en düşük sapmayı, RNN algoritması ise 0,141 ile en yüksek sapmayı göstermiştir.
- R²: Korelasyon katsayısı değerlendirildiğinde, 0,990 ile ResNet algoritması en iyi uyumu sağlarken, 0,753 ile RNN algoritması en zayıf uyumu sergilemiştir.
- MSE: Ortalama hata kareleri açısından, en düşük değer 0,001 ile ResNet algoritmasında, en yüksek değer ise 0,043 ile RNN algoritmasında elde edilmiştir.

Tablo 6.43 6 saatlik dalga boyu yüksekliği tahmin aralığı için temel regresyon modellerinin değerlendirme metrik değerleri

Metrik	<u>Bayesian</u>	<u>ELM</u>	<u>LSTM</u>	<u>ResNet</u>	<u>RNN</u>	<u>SVM</u>
<u>RMSE</u>	0,067955	0,086279	0,092704	0,038464	0,208248	0,111441
<u>MAE</u>	0,055137	0,066533	0,061271	0,025874	0,141385	0,065655
<u>R²</u>	0,972062	0,944055	0,936188	0,990542	0,75329	0,907536
<u>MSE</u>	0,004618	0,007444	0,008594	0,001479	0,043367	0,012419

Çalışmada kullanılan 6 temel regresyon modeliyle, 12 saatlik dalga boyu yüksekliği tahminleri gerçekleştirilmiş ve bu tahminler test verileriyle karşılaştırılmıştır. Bu karşılaştırma sonucunda, ilgili 4 değerlendirme metriğinin değerleri hesaplanmış ve Tablo 6.44'te sunulmuştur.

- RMSE: En düşük hata değeri, ResNet algoritması ile 0,038 olarak bulunurken, en yüksek hata değeri 0,209 ile RNN algoritmasında gözlenmiştir.

- MAE: Ortalama mutlak hata açısından, ResNet algoritması 0,026 ile en düşük sapmayı, RNN algoritması ise 0,146 ile en yüksek sapmayı göstermiştir.
- R^2 : Korelasyon katsayısı değerlendirildiğinde, 0,988 ile ResNet algoritması en iyi uyumu sağlarken, 0,713 ile RNN algoritması en zayıf uyumu sergilemiştir.
- MSE: Ortalama hata kareleri açısından, en düşük değer 0,001 ile ResNet algoritmasında, en yüksek değer ise 0,044 ile RNN algoritmasında elde edilmiştir.

Tablo 6.44 12 saatlik dalga boyu yüksekliği tahmin aralığı için temel regresyon modellerinin değerlendirme metrik değerleri

Metrik	<u>Bayesian</u>	<u>ELM</u>	<u>LSTM</u>	<u>ResNet</u>	<u>RNN</u>	<u>SVM</u>
<u>RMSE</u>	0,072651	0,086684	0,108497	0,038966	0,209843	0,120484
<u>MAE</u>	0,05967	0,067988	0,069006	0,026555	0,146861	0,067731
<u>R^2</u>	0,970358	0,937464	0,928983	0,988974	0,713931	0,904027
<u>MSE</u>	0,005278	0,007514	0,011772	0,001518	0,044034	0,014516

Çalışmada kullanılan 6 temel regresyon modeliyle, 24 saatlik dalga boyu yüksekliği tahminleri gerçekleştirilmiş ve bu tahminler test verileriyle karşılaştırılmıştır. Bu karşılaştırma sonucunda, ilgili 4 değerlendirme metriğinin değerleri hesaplanmış ve Tablo 6.45'te sunulmuştur.

- RMSE: En düşük hata değeri, ResNet algoritması ile 0,046 olarak bulunurken, en yüksek hata değeri 0,250 ile RNN algoritmasında gözlenmiştir.
- MAE: Ortalama mutlak hata açısından, ResNet algoritması 0,027 ile en düşük sapmayı, RNN algoritması ise 0,177 ile en yüksek sapmayı göstermiştir.
- R^2 : Korelasyon katsayısı değerlendirildiğinde, 0,986 ile ResNet algoritması en iyi uyumu sağlarken, 0,680 ile RNN algoritması en zayıf uyumu sergilemiştir.
- MSE: Ortalama hata kareleri açısından, en düşük değer 0,002 ile ResNet algoritmasında, en yüksek değer ise 0,062 ile RNN algoritmasında elde edilmiştir.

Tablo 6.45 24 saatlik dalga boyu yüksekliği tahmin aralığı için temel regresyon modellerinin değerlendirme metrik değerleri

Metrik	<u>Bayesian</u>	<u>ELM</u>	<u>LSTM</u>	<u>ResNet</u>	<u>RNN</u>	<u>SVM</u>
<u>RMSE</u>	0,076949	0,110028	0,117502	0,0462	0,250989	0,14427
<u>MAE</u>	0,064474	0,083112	0,071643	0,027043	0,177206	0,090052
<u>R^2</u>	0,9628	0,922333	0,928796	0,986547	0,68098	0,892485
<u>MSE</u>	0,005921	0,012106	0,013807	0,002134	0,062996	0,020814

Çalışmada kullanılan 6 temel regresyon modeliyle, 72 saatlik dalga boyu yüksekliği tahminleri gerçekleştirilmiş ve bu tahminler test verileriyle karşılaştırılmıştır. Bu karşılaştırma sonucunda, ilgili 4 değerlendirme metriğinin değerleri hesaplanmış ve Tablo 6.46’da sunulmuştur.

- RMSE: En düşük hata değeri, ResNet algoritması ile 0,047 olarak bulunurken, en yüksek hata değeri 0,279 ile RNN algoritmasında gözlenmiştir.
- MAE: Ortalama mutlak hata açısından, ResNet algoritması 0,030 ile en düşük sapmayı, RNN algoritması ise 0,198 ile en yüksek sapmayı göstermiştir.
- R^2 : Korelasyon katsayısı değerlendirildiğinde, 0,984 ile ResNet algoritması en iyi uyumu sağlarken, 0,524 ile RNN algoritması en zayıf uyumu sergilemiştir.
- MSE: Ortalama hata kareleri açısından, en düşük değer 0,002 ile ResNet algoritmasında, en yüksek değer ise 0,078 ile RNN algoritmasında elde edilmiştir.

Tablo 6.46 72 saatlik dalga boyu yüksekliği tahmin aralığı için temel regresyon modellerinin değerlendirme metrik değerleri

Metrik	<u>Bayesian</u>	<u>ELM</u>	<u>LSTM</u>	<u>ResNet</u>	<u>RNN</u>	<u>SVM</u>
<u>RMSE</u>	0,084862	0,135443	0,161225	0,047156	0,279693	0,181559
<u>MAE</u>	0,064816	0,102889	0,088256	0,030349	0,198724	0,099443
<u>R^2</u>	0,955915	0,91245	0,733571	0,984564	0,524752	0,800572
<u>MSE</u>	0,007201	0,018345	0,025994	0,002224	0,078228	0,032964

6.4.2 Dalga periyodu tahmini

Çalışmada kullanılan 6 temel regresyon modeliyle, 1 saatlik dalga periyodu tahminleri gerçekleştirilmiş ve bu tahminler test verileriyle karşılaştırılmıştır. Bu karşılaştırma sonucunda, ilgili 4 değerlendirme metriğinin değerleri hesaplanmış ve Tablo 6.47’de sunulmuştur.

- RMSE: En düşük hata değeri, ResNet algoritması ile 0,034 olarak bulunurken, en yüksek hata değeri 0,111 ile RNN algoritmasında gözlenmiştir.
- MAE: Ortalama mutlak hata açısından, ResNet algoritması 0,025 ile en düşük sapmayı, RNN algoritması ise 0,072 ile en yüksek sapmayı göstermiştir.
- R^2 : Korelasyon katsayısı değerlendirildiğinde, 0,985 ile ResNet algoritması en iyi uyumu sağlarken, 0,864 ile RNN algoritması en zayıf uyumu sergilemiştir.

- MSE: Ortalama hata kareleri açısından, en düşük değer 0,001 ile ResNet algoritmasında, en yüksek değer ise 0,012 ile RNN algoritmasında elde edilmiştir.

Tablo 6.47 1 saatlik dalga periyodu tahmin aralığı için temel regresyon modellerinin değerlendirme metrik değerleri

Metrik	<u>Bayesian</u>	<u>ELM</u>	<u>LSTM</u>	<u>ResNet</u>	<u>RNN</u>	<u>SVM</u>
<u>RMSE</u>	0,064949	0,049855	0,110013	0,034937	0,111433	0,072939
<u>MAE</u>	0,044452	0,038981	0,078476	0,025538	0,072581	0,053644
<u>R²</u>	0,95465	0,976411	0,876404	0,9854	0,864448	0,944625
<u>MSE</u>	0,004218	0,002486	0,012103	0,001221	0,012417	0,00532

Çalışmada kullanılan 6 temel regresyon modeliyle, 3 saatlik dalga periyodu tahminleri gerçekleştirilmiş ve bu tahminler test verileriyle karşılaştırılmıştır. Bu karşılaştırma sonucunda, ilgili 4 değerlendirme metriğinin değerleri hesaplanmış ve Tablo 6.48’de sunulmuştur.

- RMSE: En düşük hata değeri, ResNet algoritması ile 0,036 olarak bulunurken, en yüksek hata değeri 0,116 ile RNN algoritmasında gözlenmiştir.
- MAE: Ortalama mutlak hata açısından, ResNet algoritması 0,028 ile en düşük sapmayı, RNN algoritması ise 0,073 ile en yüksek sapmayı göstermiştir.
- R²: Korelasyon katsayısı değerlendirildiğinde, 0,983 ile ResNet algoritması en iyi uyumu sağlarken, 0,862 ile RNN algoritması en zayıf uyumu sergilemiştir.
- MSE: Ortalama hata kareleri açısından, en düşük değer 0,001 ile ResNet algoritmasında, en yüksek değer ise 0,013 ile RNN algoritmasında elde edilmiştir.

Tablo 6.48 3 saatlik dalga periyodu tahmin aralığı için temel regresyon modellerinin değerlendirme metrik değerleri

Metrik	<u>Bayesian</u>	<u>ELM</u>	<u>LSTM</u>	<u>ResNet</u>	<u>RNN</u>	<u>SVM</u>
<u>RMSE</u>	0,066007	0,06259	0,11067	0,036385	0,116323	0,072984
<u>MAE</u>	0,05061	0,052652	0,0814	0,02894	0,073145	0,058981
<u>R²</u>	0,949541	0,953507	0,873793	0,983949	0,862282	0,936283
<u>MSE</u>	0,004357	0,003917	0,012248	0,001324	0,013531	0,005327

Çalışmada kullanılan 6 temel regresyon modeliyle, 6 saatlik dalga periyodu tahminleri gerçekleştirilmiş ve bu tahminler test verileriyle karşılaştırılmıştır. Bu karşılaştırma sonucunda, ilgili 4 değerlendirme metriğinin değerleri hesaplanmış ve Tablo 6.49’da sunulmuştur.

- RMSE: En düşük hata değeri, ResNet algoritması ile 0,042 olarak bulunurken, en yüksek hata değeri 0,120 ile RNN algoritmasında gözlenmiştir.
- MAE: Ortalama mutlak hata açısından, ResNet algoritması 0,032 ile en düşük sapmayı, RNN algoritması ise 0,079 ile en yüksek sapmayı göstermiştir.
- R^2 : Korelasyon katsayısı değerlendirildiğinde, 0,983 ile ResNet algoritması en iyi uyumu sağlarken, 0,858 ile RNN algoritması en zayıf uyumu sergilemiştir.
- MSE: Ortalama hata kareleri açısından, en düşük değer 0,001 ile ResNet algoritmasında, en yüksek değer ise 0,014 ile RNN algoritmasında elde edilmiştir.

Tablo 6.49 6 saatlik dalga periyodu tahmin aralığı için temel regresyon modellerinin değerlendirme metrik değerleri

Metrik	<i>Bayesian</i>	<i>ELM</i>	<i>LSTM</i>	<i>ResNet</i>	<i>RNN</i>	<i>SVM</i>
<i>RMSE</i>	0,07615	0,066834	0,116281	0,042132	0,120826	0,079906
<i>MAE</i>	0,059718	0,053651	0,083008	0,032779	0,079323	0,060446
<i>R²</i>	0,939411	0,95314	0,866404	0,982868	0,85886	0,922587
<i>MSE</i>	0,005799	0,004467	0,013521	0,001775	0,014599	0,006385

Çalışmada kullanılan 6 temel regresyon modeliyle, 12 saatlik dalga periyodu tahminleri gerçekleştirilmiş ve bu tahminler test verileriyle karşılaştırılmıştır. Bu karşılaştırma sonucunda, ilgili 4 değerlendirme metriğinin değerleri hesaplanmış ve Tablo 6.50’de sunulmuştur.

- RMSE: En düşük hata değeri, ResNet algoritması ile 0,042 olarak bulunurken, en yüksek hata değeri 0,131 ile RNN algoritmasında gözlenmiştir.
- MAE: Ortalama mutlak hata açısından, ResNet algoritması 0,033 ile en düşük sapmayı, RNN algoritması ise 0,081 ile en yüksek sapmayı göstermiştir.
- R^2 : Korelasyon katsayısı değerlendirildiğinde, 0,980 ile ResNet algoritması en iyi uyumu sağlarken, 0,828 ile RNN algoritması en zayıf uyumu sergilemiştir.
- MSE: Ortalama hata kareleri açısından, en düşük değer 0,001 ile ResNet algoritmasında, en yüksek değer ise 0,017 ile RNN algoritmasında elde edilmiştir.

Tablo 6.50 12 saatlik dalga periyodu tahmin aralığı için temel regresyon modellerinin değerlendirme metrik değerleri

Metrik	<u>Bayesian</u>	<u>ELM</u>	<u>LSTM</u>	<u>ResNet</u>	<u>RNN</u>	<u>SVM</u>
<u>RMSE</u>	0,0799	0,078362	0,12421	0,042487	0,131112	0,094031
<u>MAE</u>	0,061032	0,060351	0,08495	0,033137	0,081553	0,061568
<u>R²</u>	0,929694	0,950813	0,853033	0,980689	0,828543	0,919481
<u>MSE</u>	0,006384	0,006141	0,015428	0,001805	0,01719	0,008842

Çalışmada kullanılan 6 temel regresyon modeliyle, 24 saatlik dalga periyodu tahminleri gerçekleştirilmiş ve bu tahminler test verileriyle karşılaştırılmıştır. Bu karşılaştırma sonucunda, ilgili 4 değerlendirme metriğinin değerleri hesaplanmış ve Tablo 6.51’de sunulmuştur.

- RMSE: En düşük hata değeri, ResNet algoritması ile 0,043 olarak bulunurken, en yüksek hata değeri 0,134 ile RNN algoritmasında gözlenmiştir.
- MAE: Ortalama mutlak hata açısından, ResNet algoritması 0,034 ile en düşük sapmayı, RNN algoritması ise 0,082 ile en yüksek sapmayı göstermiştir.
- R²: Korelasyon katsayısı değerlendirildiğinde, 0,980 ile ResNet algoritması en iyi uyumu sağlarken, 0,822 ile RNN algoritması en zayıf uyumu sergilemiştir.
- MSE: Ortalama hata kareleri açısından, en düşük değer 0,001 ile ResNet algoritmasında, en yüksek değer ise 0,018 ile RNN algoritmasında elde edilmiştir.

Tablo 6.51 24 saatlik dalga periyodu tahmin aralığı için temel regresyon modellerinin değerlendirme metrik değerleri

Metrik	<u>Bayesian</u>	<u>ELM</u>	<u>LSTM</u>	<u>ResNet</u>	<u>RNN</u>	<u>SVM</u>
<u>RMSE</u>	0,086876	0,083106	0,124388	0,043073	0,134289	0,099423
<u>MAE</u>	0,064436	0,064111	0,085382	0,034577	0,082873	0,062896
<u>R²</u>	0,917888	0,917265	0,835652	0,980607	0,822575	0,906184
<u>MSE</u>	0,007547	0,006907	0,015472	0,001855	0,018034	0,009885

Çalışmada kullanılan 6 temel regresyon modeliyle, 72 saatlik dalga periyodu tahminleri gerçekleştirilmiş ve bu tahminler test verileriyle karşılaştırılmıştır. Bu karşılaştırma sonucunda, ilgili 4 değerlendirme metriğinin değerleri hesaplanmış ve Tablo 6.52’de sunulmuştur.

- RMSE: En düşük hata değeri, ResNet algoritması ile 0,068 olarak bulunurken, en yüksek hata değeri 0,174 ile RNN algoritmasında gözlenmiştir.

- MAE: Ortalama mutlak hata açısından, ResNet algoritması 0,053 ile en düşük sapmayı, RNN algoritması ise 0,089 ile en yüksek sapmayı göstermiştir.
- R^2 : Korelasyon katsayısı değerlendirildiğinde, 0,962 ile ResNet algoritması en iyi uyumu sağlarken, 0,640 ile RNN algoritması en zayıf uyumu sergilemiştir.
- MSE: Ortalama hata kareleri açısından, en düşük değer 0,004 ile ResNet algoritmasında, en yüksek değer ise 0,030 ile RNN algoritmasında elde edilmiştir.

Tablo 6.52 72 saatlik dalga periyodu tahmin aralığı için temel regresyon modellerinin değerlendirme metrik değerleri

Metrik	<u>Bayesian</u>	<u>ELM</u>	<u>LSTM</u>	<u>ResNet</u>	<u>RNN</u>	<u>SVM</u>
<u>RMSE</u>	0,101247	0,087023	0,160481	0,068731	0,174062	0,100261
<u>MAE</u>	0,078827	0,067912	0,085868	0,053925	0,08993	0,068725
<u>R^2</u>	0,917544	0,916263	0,697848	0,962161	0,640624	0,903403
<u>MSE</u>	0,010251	0,007573	0,025754	0,004724	0,030298	0,010052

6.5 Yığınlama Yaklaşımının Ordu ve Samsun Şamandıra Verilerindeki Performansı

Ordu şamandırasında dalga boyu yüksekliği için eğitim sonrasında XGB algoritması sırasıyla 1 saatlik, 3 saatlik, 6 saatlik, 12 saatlik, 24 saatlik ve 72 saatlik dalga boyu yükseklikleri tahminleri ile test verileri karşılaştırılmıştır. Bu karşılaştırma sonucunda, saat aralıklarına göre 4 değerlendirme metriğinin değerleri hesaplanmış ve Tablo 6.53'te sunulmuştur.


- RMSE: En düşük hata değeri, 1 saatlik zaman periyodunda 0,017 olarak bulunurken, en yüksek hata değeri 0,038 ile 72 saatlik zaman aralığında gözlenmiştir.
- MAE: Ortalama mutlak hata açısından, 1 saatlik tahmin değerleri 0,013 ile en düşük sapmayı, 72 saatlik tahmin değerleri ise 0,023 ile en yüksek sapmayı göstermiştir.
- R^2 : Korelasyon katsayısı değerlendirildiğinde, 0,994 ile 1 saatlik zaman dilimi en iyi uyumu sağlarken, 0,917 ile 72 saatlik zaman dilimi en zayıf uyumu sergilemiştir.

- MSE: Ortalama hata kareleri açısından, en düşük değer 0,0003 ile 1 saatlik zaman aralığında, en yüksek değer ise 0,0014 ile 72 saatlik zaman diliminde elde edilmiştir.

Tablo 6.53 XGB algoritmasının (meta-model) Ordu şamandırası dalga yüksekliği tahmini için saat aralıklarına ait değerlendirme metrik değerleri

Metrik	<u>1H</u>	<u>3H</u>	<u>6H</u>	<u>12H</u>	<u>24H</u>	<u>72H</u>
<u>RMSE</u>	0,017307	0,01796	0,019348	0,019498	0,026192	0,038649
<u>MAE</u>	0,013508	0,014267	0,015913	0,01592	0,018071	0,023898
<u>R²</u>	0,994846	0,994712	0,994488	0,984436	0,931584	0,917878
<u>MSE</u>	0,0003	0,000323	0,000374	0,00038	0,000686	0,001494

Ordu şamandırasında dalga boyu yüksekliği için XGB algoritmasının tahminleri ve test verilerinin karşılaştırılması Şekil 6.29’da gösterilmiştir.



Şekil 6.29 XGB algoritmasının Ordu şamandırasında dalga boyu yüksekliği için tahmin ve test verilerinin karşılaştırılması


Ordu şamandırasında dalga periyodu için eğitim sonrasında XGB algoritması sırasıyla 1 saatlik, 3 saatlik, 6 saatlik, 12 saatlik, 24 saatlik ve 72 saatlik dalga periyodu tahminleri ile test verileri karşılaştırılmıştır. Bu karşılaştırma sonucunda, saat aralıklarına göre 4 değerlendirme metriğinin değerleri hesaplanmış ve Tablo 6.54’te sunulmuştur.

- RMSE: En düşük hata değeri, 1 saatlik zaman periyodunda 0,028 olarak bulunurken, en yüksek hata değeri 0,081 ile 72 saatlik zaman aralığında gözlenmiştir.
- MAE: Ortalama mutlak hata açısından, 1 saatlik tahmin değerleri 0,013 ile en düşük sapmayı, 72 saatlik tahmin değerleri ise 0,076 ile en yüksek sapmayı göstermiştir.
- R^2 : Korelasyon katsayısı değerlendirildiğinde, 0,994 ile 1 saatlik zaman dilimi en iyi uyumu sağlarken, 0,815 ile 72 saatlik zaman dilimi en zayıf uyumu sergilemiştir.
- MSE: Ortalama hata kareleri açısından, en düşük değer 0,0008 ile 1 saatlik zaman aralığında, en yüksek değer ise 0,0066 ile 72 saatlik zaman diliminde elde edilmiştir.

Tablo 6.54 XGB algoritmasının (meta-model) Ordu şamandırası dalga yüksekliği tahmini için saat aralıklarına ait değerlendirme metrik değerleri

Metrik	<u>1H</u>	<u>3H</u>	<u>6H</u>	<u>12H</u>	<u>24H</u>	<u>72H</u>
<u>RMSE</u>	0,028827	0,029762	0,040537	0,042378	0,049605	0,081537
<u>MAE</u>	0,013846	0,013882	0,023686	0,027188	0,033911	0,076216
<u>R^2</u>	0,99484	0,994265	0,993447	0,992563	0,992116	0,815655
<u>MSE</u>	0,000831	0,000886	0,001643	0,001796	0,002461	0,006648

Ordu şamandırasında dalga periyodu için XGB algoritmasının tahminleri ve test verilerinin karşılaştırılması Şekil 6.30'da gösterilmiştir.



Şekil 6.30 XGB algoritmasının Ordu şamandırasında dalga periyodu için tahmin ve test verilerinin karşılaştırılması


Samsun şamandırasında dalga boyu yüksekliği için eğitim sonrasında XGB algoritması sırasıyla 1 saatlik, 3 saatlik, 6 saatlik, 12 saatlik, 24 saatlik ve 72 saatlik dalga boyu yükseklikleri tahminleri ile test verileri karşılaştırılmıştır. Bu karşılaştırma sonucunda, saat aralıklarına göre 4 değerlendirme metriğinin değerleri hesaplanmış ve Tablo 6.55’te sunulmuştur.

- RMSE: En düşük hata değeri, 1 saatlik zaman periyodunda 0,018 olarak bulunurken, en yüksek hata değeri 0,025 ile 72 saatlik zaman aralığında gözlenmiştir.
- MAE: Ortalama mutlak hata açısından, 1 saatlik tahmin değerleri 0,015 ile en düşük sapmayı, 72 saatlik tahmin değerleri ise 0,018 ile en yüksek sapmayı göstermiştir.
- R^2 : Korelasyon katsayısı değerlendirildiğinde, 0,998 ile 1 saatlik zaman dilimi en iyi uyumu sağlarken, 0,984 ile 72 saatlik zaman dilimi en zayıf uyumu sergilemiştir.
- MSE: Ortalama hata kareleri açısından, en düşük değer 0,0003 ile 1 saatlik zaman aralığında, en yüksek değer ise 0,0006 ile 72 saatlik zaman diliminde elde edilmiştir.

Tablo 6.55 XGB algoritmasının (meta-model) Samsun şamandırası dalga yüksekliği tahmini için saat aralıklarına ait değerlendirme metrik değerleri

Metrik	<u>1H</u>	<u>3H</u>	<u>6H</u>	<u>12H</u>	<u>24H</u>	<u>72H</u>
<u>RMSE</u>	0,018975	0,019548	0,02099	0,021088	0,022574	0,025189
<u>MAE</u>	0,015756	0,016084	0,016114	0,016391	0,016588	0,01821
<u>R²</u>	0,998061	0,997603	0,997	0,996864	0,9869	0,984364
<u>MSE</u>	0,00036	0,000382	0,000441	0,000445	0,00051	0,000635

Samsun şamandırasında dalga boyu yüksekliği için XGB algoritmasının tahminleri ve test verilerinin karşılaştırılması Şekil 6.31’de gösterilmiştir.



Şekil 6.31 XGB algoritmasının Samsun şamandırasında dalga boyu yüksekliği için tahmin ve test verilerinin karşılaştırılması

Samsun şamandırasında dalga periyodu için eğitim sonrasında XGB algoritması sırasıyla 1 saatlik, 3 saatlik, 6 saatlik, 12 saatlik, 24 saatlik ve 72 saatlik dalga periyodu tahminleri ile test verileri karşılaştırılmıştır. Bu karşılaştırma sonucunda, saat aralıklarına göre 4 değerlendirme metriğinin değerleri hesaplanmış ve Tablo 6.56’da sunulmuştur.


- RMSE: En düşük hata değeri, 1 saatlik zaman periyodunda 0,007 olarak bulunurken, en yüksek hata değeri 0,040 ile 72 saatlik zaman aralığında gözlenmiştir.
- MAE: Ortalama mutlak hata açısından, 1 saatlik tahmin değerleri 0,005 ile en düşük sapmayı, 72 saatlik tahmin değerleri ise 0,022 ile en yüksek sapmayı göstermiştir.

- R^2 : Korelasyon katsayısı değerlendirildiğinde, 0,999 ile 1 saatlik zaman dilimi en iyi uyumu sağlarken, 0,983 ile 72 saatlik zaman dilimi en zayıf uyumu sergilemiştir.
- MSE: Ortalama hata kareleri açısından, en düşük değer 0,0004 ile 1 saatlik zaman aralığında, en yüksek değer ise 0,001 ile 72 saatlik zaman diliminde elde edilmiştir.

Tablo 6.56 XGB algoritmasının (meta-model) Ordu şamandırası dalga yüksekliği tahmini için saat aralıklarına ait değerlendirme metrik değerleri

Metrik	<u>1H</u>	<u>3H</u>	<u>6H</u>	<u>12H</u>	<u>24H</u>	<u>72H</u>
<u>RMSE</u>	0,007018	0,011524	0,018484	0,031327	0,032911	0,040469
<u>MAE</u>	0,00515	0,009206	0,010123	0,01859	0,019175	0,022927
<u>R^2</u>	0,999047	0,996998	0,99425	0,993882	0,987716	0,983139
<u>MSE</u>	4,93E-05	0,000133	0,000342	0,000981	0,001083	0,001638

Samsun şamandırasında dalga periyodu için XGB algoritmasının tahmin değerleri ve test verilerinin karşılaştırılması Şekil 6.32’te gösterilmiştir.



Şekil 6.32 XGB algoritmasının Samsun şamandırasında dalga periyodu için tahmin ve test verilerinin karşılaştırılması

6.6 Dalga Gücünün Hesaplanması ve Sistem Performansının Değerlendirilmesi

Dalga gücünün dalga boyu ve periyoduna bağlı olarak formülü Denklem (6.1)’de gösterilmiştir.

$$P \left(\frac{W}{m} \right) = \frac{\rho g^2}{64\pi} H^2 T \quad \text{Denklem (6.1)}$$

Karadeniz için $\rho = 1015 \text{ kg/m}^3$ olarak kabul edersek güç denklemi basit olarak Denklem (6.2)'de gösterildiği gibi düzenlenebilir.

$$P \left(\frac{kW}{m} \right) = 0.486 H^2 T \quad \text{Denklem (6.2)}$$


Önerilen sistemin temel amacı şamandıra verilerinden dalga gücünün hesaplanmasıdır. Bunun için dalga yüksekliği ve dalga periyodu ayrı ayrı tahmin edilmiştir. Modellerden elde edilen tahmin yüksekliği ve periyodu kullanılarak tahmin edilen dalga gücü Denklem (6.3)'te belirtildiği şekilde hesaplanmıştır.

$$P_{tahmin} \left(\frac{kW}{m} \right) = 0.486 H_{tahmin}^2 T_{tahmin} \quad \text{Denklem (6.3)}$$

Şamandıra verilerinde bulunan dalga boyu yüksekliği ve periyodu değerleri kullanılarak Denklem (6.4)'te belirtildiği şekilde test edilen dalga gücü hesaplanmıştır.


$$P_{test} \left(\frac{kW}{m} \right) = 0.486 H_{test}^2 T_{test} \quad \text{Denklem (6.4)}$$

Sistemde temel regresyon modelleri arasında en iyi performans gösteren algoritma ResNet olarak gözlenmiştir. Yığınlama yaklaşımında kullanılan XGB algoritmasının sisteme etkisinin değerlendirilmesi için XGB ile ResNet algoritmalarının dalga gücü hesaplamalarında performans metrikleri değerlendirilmiştir. Ordu şamandırasında XGB algoritmasının 6 saatlik test ve tahmin edilen dalga gücü değerleri Şekil 6.33'te gösterilmiştir. Dalga gücünde ani yükselmelerin olduğu zaman aralıklarında tahmin modelinin test dalga gücünü tahmin etmek de zorluk ortaya çıktığı görülmektedir. Bunun temel nedeni dalga gücünün genelde daha küçük hareket ettiği için az sayıdaki bu ani yükselmelerde tahmin modellerinde sorun çıkmaktadır.




Şekil 6.33 Ordu şamandırasında XGB algoritmasının dalga gücü için tahmin ve test verilerinin karşılaştırılması

Ordu şamandırasında ResNet algoritmasının 6 saatlik test ve tahmin edilen dalga gücü değerleri Şekil 6.34'te gösterilmiştir. XGB algoritması ile karşılaştırıldığında ResNet algoritması ani yükselmelerin tahmin etmede daha düşük performans gösterdiği gözlenmektedir.




Şekil 6.34 Ordu şamandırasında ResNet algoritmasının dalga gücü için tahmin ve test verilerinin karşılaştırılması

Samsun şamandırasında XGB algoritmasının 6 saatlik test ve tahmin edilen dalga gücü değerleri Şekil 6.35'te gösterilmiştir. XGB algoritması sonucunda tahmin edilen dalga gücü değerlerinin test değerlerine oldukça yakın olduğu gözlenmiştir.



Şekil 6.35 Samsun şamandırasında XGB algoritmasının dalga gücü için tahmin ve test verilerinin karşılaştırılması

Samsun şamandırasında ResNet algoritmasının 6 saatlik test ve tahmin edilen dalga gücü değerleri Şekil 6.36'da gösterilmiştir.



Şekil 6.36 Samsun şamandırasında ResNet algoritmasının dalga gücü için tahmin ve test verilerinin karşılaştırılması

7. TARTIŞMA

Ordu ve Samsun şamandıralarında dalga yüksekliği ve periyodu tahmini için Bayesian, ELM, LSTM, ResNet, RNN ve SVM temel regresyon modelleri ile tahminler gerçekleştirilmiştir. Temel regresyon modellerinin tahmin değerleri XGB algoritmasının girdi veri setini oluşturmaktadır. Temel regresyon modelleri arasında tahmin değerlerinin performansını değerlendirmek için 4 adet metrik değer hesaplanmıştır. Temel regresyon modelleri arasında metrik değerlere göre en iyi performans gösteren temel regresyon algoritması ResNet olarak gözlenmiştir. Bu yüzden yığınlama yaklaşımında kullanılan XGB algoritmasının performans karşılaştırılması en iyi performans gösteren temel regresyon modeli ResNet algoritması ile gerçekleştirilmiştir.

Tez çalışmasında Ordu şamandırasında ait verilerde dalga boyu yüksekliğini ve periyodunu tahmin eden regresyon modellerinin yapısal düzeni (gizli nöron sayısı vb.) ve öğrenme oranı belirleme kriterini oluşturmuştur. Ordu şamandırasına ait veriler Samsun şamandırasına ait verilere göre daha karmaşık (daha sık uç değerlerin olması) veri dağılımı göstermektedir. Bunun nedeni şamandıraların bulunduğu lokasyonlar arasındaki farklılıktan kaynaklandığı düşünülmektedir. Tez çalışmasında regresyon modellerinin performanslarının karşılaştırılmasının yanı sıra farklı lokasyonlardaki şamandıra verilerinde gerçekleştirilecek dalga gücü tahmininde hata değerinin düşük seviyede tutulabilmesi için yığınlama yaklaşımı kullanılarak farklı avantajlara sahip regresyon modellerinden hibrit bir makine öğrenimi modeli tasarlanmıştır. Geliştirilen hibrit modelde iki farklı şamandıraya ait veriler üzerinden dalga gücü tahmini gerçekleştirilirken regresyon algoritmalarının parametrelerinde herhangi bir değişiklik yapılmamıştır. Bu sayede geliştirilen modelin şamandıra verilerindeki karmaşıklığa karşı daha dayanıklı şekilde dalga gücü tahmini gerçekleştirebileceği düşünülmüştür. Tez çalışmasında Karadeniz bölgesinde iki farklı şamandıra verisi kullanılmasının nedeni modelin farklı şamandıralardaki performansı hakkında bilgi edinilmesidir.

Ordu şamandırasında dalga boyu yüksekliğinin tahmin edilmesinde ResNet ve XGB algoritmalarının performans metrik değerleri Tablo 7.1’de verilmiştir. RMSE verilerine göre 3 saatlik, 6 saatlik, 12 saatlik, 24 saatlik ve 72 saatlik tahmin verilerinde XGB algoritması ResNet algoritmasına göre daha iyi performans göstermesine karşın 1 saatlik tahmin değerlerinde ResNet algoritması XGB algoritmasına göre daha iyi performans göstermektedir. MAE metrik değerlerine göre 3 saatlik, 6 saatlik, 12 saatlik, 24 saatlik ve

72 saatlik tahmin verilerinde XGB algoritması ResNet algoritmasına göre daha iyi performans göstermesine karşın 1 saatlik tahmin değerlerinde ResNet algoritması XGB algoritmasına göre daha iyi performans göstermektedir. R^2 metrik değerlerine göre ResNet algoritması tüm saat aralıklarında XGB algoritmasından daha iyi performans göstermiştir. MSE metrik verilerine göre 3 saatlik, 6 saatlik, 12 saatlik, 24 saatlik ve 72 saatlik tahmin verilerinde XGB algoritması ResNet algoritmasına göre daha iyi performans göstermesine karşın 1 saatlik tahmin değerlerinde ResNet algoritması XGB algoritmasına göre daha iyi performans göstermektedir.

Tablo 7.1 Ordu şamandırası dalga yüksekliği tahmini için ResNet ve XGB algoritmalarının saat aralıklarına göre metrik değerleri

		RMSE	MAE	R^2	MSE
1H	<u>ResNet</u>	0,0106	0,006426	0,998193	0,000112
	<u>XGB</u>	0,017307	0,013508	0,994846	0,0003
3H	<u>ResNet</u>	0,030679	0,022436	0,997575	0,000941
	<u>XGB</u>	0,01796	0,014267	0,994712	0,000323
6H	<u>ResNet</u>	0,032634	0,022836	0,996594	0,001065
	<u>XGB</u>	0,019348	0,015913	0,994488	0,000374
12H	<u>ResNet</u>	0,038877	0,023249	0,995547	0,001511
	<u>XGB</u>	0,019498	0,01592	0,984436	0,00038
24H	<u>ResNet</u>	0,053308	0,029286	0,995186	0,002842
	<u>XGB</u>	0,026192	0,018071	0,931584	0,000686
72H	<u>ResNet</u>	0,055508	0,045202	0,988186	0,003081
	<u>XGB</u>	0,038649	0,023898	0,917878	0,001494

Ordu şamandırasında dalga yüksekliği tahmininde ResNet ve XGB modellerinin performansları karşılaştırıldığı zaman 1 saatlik zaman aralığında ResNet modeli XGB modelinde tüm metrik değerlerde üstünlük sağladığı gözlenmiştir. Ayrıca ResNet modeli tüm zaman aralıklarında R^2 değerinde de XGB modelinden daha iyi performans göstermiştir. ResNet ve XGB model performanslarındaki bu performans dağılımı incelendiği zaman;

- Yığınlama yaklaşımında kullanılan XGB algoritması direkt olarak şamandıra verileri ile değil temel regresyon modellerinin tahmin değerleri ile eğitilmiştir. 1 saatlik zaman aralığında ResNet algoritmasının XGB algoritmasından RMSE,

MAE, R^2 ve MSE metriklerinde daha iyi performans göstermesinin sebebi diğer temel regresyon modellerin ResNet algoritmasına göre daha düşük performanslı olarak tahmin değerleri yapmış olmaları ve 1 saatlik örneklem sayısında (50) XGB algoritmasının bu hatalı tahmin değerlerini minimize edememiş olması olarak düşünülmektedir.

- ResNet modelinin XGB modelinde her saat diliminde R^2 metriğinde daha iyi performans göstermiştir. Metrik değerlerinin performans odakları arasında bir tanımlama yapılması gerekirse; RMSE, MAE ve MSE metrik değerleri tahmin değerleri ile gerçek değerler arasındaki hata büyüklüğü ile ilgilenmektedir. R^2 metrik değeri ise tahmin değerleri ile gerçek değerler arasındaki varyansa, yani örüntünün takip edilmesine odaklıdır. Elde edilen değerlere göre Ordu şamandırasının dalga yüksekliği tahmininde ResNet algoritmasının veri varyansını (örüntüsünü) XGB algoritmasına göre daha iyi yakaladığını göstermektedir. Bunun temel sebebi; XGB algoritması hata metrik değerlerinde uç (aykırı) değerleri tahmin etmeye karşı daha duyarlı bir yapıya sahip olup tahmin hatalarını minimize edebilmesi için hiper parametre optimizasyonu yapması, ResNet algoritmasının özellik çıkartma ve öğrenme temelli bir makine öğrenimi algoritması olduğu için örüntü takip etme (tanıma) işlemlerinde güçlü bir yapıya sahip olması olarak düşünülmektedir. Ayrıca XGB modelinin temel regresyon modellerinin tahmin değerleri üzerinden dalga yüksekliğini örüntü olarak yaklaştırmaya çalışırken ResNet direkt olarak dalga yüksekliği değerleri üzerinden bu işlemi gerçekleştirmektedir.

Ordu şamandırasında dalga periyodu tahmin edilmesinde ResNet ve XGB algoritmalarının performans metrik değerleri Tablo 7.2’te verilmiştir. RMSE verilerine göre 72 saat haricinde tüm saat aralıklarında gerçekleştirilen tahmin verilerinde XGB algoritması ResNet algoritmasına göre daha iyi performans göstermesine karşın 72 saatlik tahminde ResNet algoritması XGB algoritmasından daha iyi performans göstermiştir. MAE metrik değerlerine göre 72 saat haricinde tüm saat aralıklarında gerçekleştirilen tahmin verilerinde XGB algoritması ResNet algoritmasına göre daha iyi performans göstermesine karşın 72 saatlik tahminde ResNet algoritması XGB algoritmasından daha iyi performans göstermiştir. R^2 metrik değerlerine göre 72 saat haricinde tüm saat aralıklarında gerçekleştirilen tahmin verilerinde XGB algoritması ResNet algoritmasına göre daha iyi performans göstermesine karşın 72 saatlik tahminde ResNet algoritması

XGB algoritmasından daha iyi performans göstermiştir. MSE metrik verilerine göre 72 saat haricinde tüm saat aralıklarında gerçekleştirilen tahmin verilerinde XGB algoritması ResNet algoritmasına göre daha iyi performans göstermesine karşın 72 saatlik tahminde ResNet algoritması XGB algoritmasından daha iyi performans göstermiştir

Tablo 7.2 Ordu şamandırası dalga periyodu için ResNet ve XGB algoritmalarının saat aralıklarına göre metrik değerleri

		RMSE	MAE	R ²	MSE
1H	<u>ResNet</u>	0,033254	0,026929	0,982226	0,001106
	<u>XGB</u>	0,028827	0,013846	0,99484	0,000831
3H	<u>ResNet</u>	0,050559	0,038486	0,97965	0,002556
	<u>XGB</u>	0,029762	0,013882	0,994265	0,000886
6H	<u>ResNet</u>	0,054543	0,041655	0,977666	0,002975
	<u>XGB</u>	0,040537	0,023686	0,993447	0,001643
12H	<u>ResNet</u>	0,057455	0,045031	0,971041	0,003301
	<u>XGB</u>	0,042378	0,027188	0,992563	0,001796
24H	<u>ResNet</u>	0,061464	0,049179	0,965608	0,003778
	<u>XGB</u>	0,049605	0,033911	0,992116	0,002461
72H	<u>ResNet</u>	0,064594	0,055699	0,95754	0,004172
	<u>XGB</u>	0,081537	0,076216	0,815655	0,006648

Ordu şamandırasında dalga periyodu tahmininde ResNet ve XGB modellerinin performansları karşılaştırıldığında XGB modelinin 72 saat dilimi haricinde kalan saat aralıklarında ResNet algoritmasına göre tüm metrik değerlerinde daha iyi performans göstermektedir. ResNet ve XGB model performanslarındaki bu performans dağılımı incelendiği zaman;

- Temel regresyon modellerinin Ordu şamandırasında dalga periyodu için gerçekleştirdikleri kötü tahmin değerlerini minimize etmekte güçlük çektiği gözlenmektedir. Bulgular başlığı altında Tablo 6.46 incelendiği zaman özellikle ELM ve SVM modellerinin 72 saatlik dilimde aniden performanslarının düştüğünü, hata değerlerinin yükseldiğini ve diğer modellerden oldukça geride kalmış oldukları görülmektedir. XGB modelinin bu tahmin değerlerinden kaynaklı olarak ResNet modelinden 72 saat zaman aralığında performans olarak metrik değerlerde geri kalmasına sebebiyet verdiği düşünülmektedir.

Samsun şamandırasında dalga boyu yüksekliğinin tahmin edilmesinde ResNet ve XGB algoritmalarının performans metrik değerleri Tablo 7.3'te verilmiştir. RMSE verilerine göre tüm saat aralıklarında gerçekleştirilen tahmin verilerinde XGB algoritması ResNet algoritmasına göre daha iyi performans göstermiştir. MAE metrik değerlerine göre tüm saat aralıklarında gerçekleştirilen tahmin verilerinde XGB algoritması ResNet algoritmasına göre daha iyi performans göstermiştir. R^2 metrik değerlerine göre tüm saat aralıklarında gerçekleştirilen tahmin verilerinde XGB algoritması tüm saat aralıklarında ResNet algoritmasından daha iyi performans göstermiştir. MSE metrik verilerine göre tüm saat aralıklarında gerçekleştirilen tahmin verilerinde XGB algoritması ResNet algoritmasına göre daha iyi performans göstermektedir.

Tablo 7.3 Samsun şamandırası dalga yüksekliği tahmini için ResNet ve XGB algoritmalarının saat aralıklarına göre metrik değerleri

		RMSE	MAE	R^2	MSE
1H	<u>ResNet</u>	0,034516	0,022081	0,99331	0,001191
	<u>XGB</u>	0,018975	0,015756	0,998061	0,00036
3H	<u>ResNet</u>	0,035642	0,022934	0,992754	0,00127
	<u>XGB</u>	0,019548	0,016084	0,997603	0,000382
6H	<u>ResNet</u>	0,038464	0,025874	0,990542	0,001479
	<u>XGB</u>	0,02099	0,016114	0,997	0,000441
12H	<u>ResNet</u>	0,038966	0,026555	0,988974	0,001518
	<u>XGB</u>	0,021088	0,016391	0,996864	0,000445
24H	<u>ResNet</u>	0,0462	0,027043	0,986547	0,002134
	<u>XGB</u>	0,022574	0,016588	0,9869	0,00051
72H	<u>ResNet</u>	0,047156	0,030349	0,984564	0,002224
	<u>XGB</u>	0,025189	0,01821	0,984364	0,000635

Samsun şamandırasında dalga boyu yüksekliği tahmini sonuçları incelendiği zaman XGB algoritmasının temel regresyon modelleri arasında en iyi performans gösteren ResNet algoritmasına göre daha tüm zaman aralıklarında ve metrik değerlerinde daha iyi performans gösterdiği görülmektedir. Samsun şamandırasına ait veriler Ordu şamandırasına göre daha yumuşak geçişlere sahip bir veri setine sahiptir. Buna bağlı olarak çalışmadan beklendiği şekilde yığınlama yaklaşımı sonucunda XGB algoritmasının tüm temel regresyon modellerinden daha iyi performans ortaya koymaktadır.

Samsun şamandırasında dalga periyodu tahmin edilmesinde ResNet ve XGB algoritmalarının performans metrik değerleri Tablo 7.4’te verilmiştir. RMSE verilerine göre tüm saat aralıklarında gerçekleştirilen tahmin verilerinde XGB algoritması ResNet algoritmasına göre daha iyi performans göstermiştir. MAE metrik değerlerine göre tüm saat aralıklarında gerçekleştirilen tahmin verilerinde XGB algoritması ResNet algoritmasına göre daha iyi performans göstermiştir. R^2 metrik değerlerine göre tüm saat aralıklarında gerçekleştirilen tahmin verilerinde XGB algoritması tüm saat aralıklarında ResNet algoritmasından daha iyi performans göstermiştir. MSE metrik verilerine göre tüm saat aralıklarında gerçekleştirilen tahmin verilerinde XGB algoritması ResNet algoritmasına göre daha iyi performans göstermektedir.

Tablo 7.4 Samsun şamandırası dalga periyodu için ResNet ve XGB algoritmalarının saat aralıklarına göre metrik değerleri

		RMSE	MAE	R^2	MSE
1H	<u>ResNet</u>	0,034937	0,025538	0,9854	0,001221
	<u>XGB</u>	0,007018	0,00515	0,999047	4,93E-05
3H	<u>ResNet</u>	0,036385	0,02894	0,983949	0,001324
	<u>XGB</u>	0,011524	0,009206	0,996998	0,000133
6H	<u>ResNet</u>	0,042132	0,032779	0,982868	0,001775
	<u>XGB</u>	0,018484	0,010123	0,99425	0,000342
12H	<u>ResNet</u>	0,042487	0,033137	0,980689	0,001805
	<u>XGB</u>	0,031327	0,01859	0,993882	0,000981
24H	<u>ResNet</u>	0,043073	0,034577	0,980607	0,001855
	<u>XGB</u>	0,032911	0,019175	0,987716	0,001083
72H	<u>ResNet</u>	0,068731	0,053925	0,962161	0,004724
	<u>XGB</u>	0,040469	0,022927	0,983139	0,001638

Samsun şamandırasında dalga periyodu tahmini sonuçları incelendiği zaman XGB algoritmasının temel regresyon modelleri arasında en iyi performans gösteren ResNet algoritmasına göre daha tüm zaman aralıklarında ve metrik değerlerinde daha iyi performans sağlamaktadır. Model performansları karşılaştırıldığı zaman çalışmanın başında beklenildiği gibi yığınlama yaklaşımı sonucunda XGB algoritmasının tüm temel regresyon modellerinden daha iyi performans ortaya koymaktadır.

Ordu ve Samsun şamandıraları için dalga gücünün tahmin edilmesinde XGB ve ResNet algoritmalarının performans metrikleri hesaplanmıştır ve Tablo 7.5'te gösterilmiştir. Ordu şamandırası için; RMSE değerleri incelendiği zaman XGB ve ResNet algoritmaları 1 saatlik tahmin için yakın değerlere sahiptir. Diğer saat aralıklarında XGB algoritması ResNet algoritmasına göre daha iyi performans göstermiştir. MAE değerleri incelendiği zaman tüm saat aralıkları için XGB algoritması ResNet algoritmasına göre daha iyi performans gösterdiği gözlenmiştir. R^2 değerleri incelendiği zaman tüm saat aralıkları için XGB algoritması ResNet algoritmasına göre daha iyi performans gösterdiği gözlenmiştir. MSE değeri incelendiği zaman XGB ve ResNet algoritmaları 1 saatlik tahmin için yakın değerlere sahiptir. Diğer saat aralıklarında XGB algoritması ResNet algoritmasına göre daha iyi performans göstermiştir.

Samsun şamandırası için; RMSE değerleri incelendiği zaman tüm saat aralıkları için XGB algoritması ResNet algoritmasına göre daha iyi performans gösterdiği gözlenmiştir. MAE değerleri incelendiği zaman tüm saat aralıkları için XGB algoritması ResNet algoritmasına göre daha iyi performans gösterdiği gözlenmiştir. R^2 değerleri incelendiği zaman tüm saat aralıkları için XGB algoritması ResNet algoritmasına göre daha iyi performans gösterdiği gözlenmiştir. MSE değeri incelendiği zaman XGB algoritması ResNet algoritmasına göre daha iyi performans gösterdiği gözlenmiştir.

Tablo 7.5 Ordu ve Samsun şamandırasının dalga gücü tahmini için ResNet ve XGB algoritmalarının saat aralıklarına göre metrik değerleri

			<u>RMSE</u>	<u>MAE</u>	<u>R^2</u>	<u>MSE</u>
Ordu	<u>XGB</u>	<u>1H</u>	0,0183	0,0094	0,9920	0,0003
		<u>3H</u>	0,0203	0,0100	0,9916	0,0004
		<u>6H</u>	0,0220	0,0151	0,9907	0,0005
		<u>12H</u>	0,0285	0,0164	0,9879	0,0008
		<u>24H</u>	0,0481	0,0377	0,9805	0,0023
		<u>72H</u>	0,1409	0,0540	0,9735	0,0198
	<u>ResNet</u>	<u>1H</u>	0,0186	0,0143	0,9892	0,0003
		<u>3H</u>	0,0857	0,0382	0,9855	0,0074
		<u>6H</u>	0,1100	0,0471	0,9840	0,0121
		<u>12H</u>	0,1479	0,0603	0,9814	0,0219
		<u>24H</u>	0,1908	0,0652	0,9775	0,0364
		<u>72H</u>	0,2735	0,0724	0,9123	0,0748
Samsun	<u>XGB</u>	<u>1H</u>	0,0104	0,0079	0,9942	0,0001
		<u>3H</u>	0,0157	0,0131	0,9919	0,0002
		<u>6H</u>	0,0340	0,0181	0,9888	0,0012

Tablo 7.5 Devamı

		<u>12H</u>	0,0784	0,0364	0,9877	0,0062
		<u>24H</u>	0,1182	0,0615	0,9876	0,0140
		<u>72H</u>	0,1229	0,0662	0,9492	0,0151
	<u>ResNet</u>	<u>1H</u>	0,0809	0,0491	0,9919	0,0065
		<u>3H</u>	0,1026	0,0523	0,9904	0,0105
		<u>6H</u>	0,1052	0,0553	0,9886	0,0111
		<u>12H</u>	0,1072	0,0565	0,9859	0,0115
		<u>24H</u>	0,1319	0,0654	0,9853	0,0174
		<u>72H</u>	0,3293	0,0703	0,9770	0,1085

Çalışmanın temel amacı dalga boyu yüksekliği ve periyodu tahmin edilmesinin sonucunda dalga gücünün hesaplanmasıdır. Şamandıra verilerinden direkt olarak dalga gücünün hesaplanması ve tahmin edilmesi bir yöntem olarak kabul edilebilir. Ancak burada temel problem dalga boyu yüksekliği ve periyodunun farklı parametrelere karşı duyarlılığının olmasıdır. Bu yüzden direkt olarak dalga gücü tahmini yapılması hata değerlerinin artmasına ve yığınlama yaklaşımı sonucunda elde edilecek performansı negatif yönde etkileyeceği düşünülmektedir. Ordu ve Samsun şamandıralarından nihai olarak tahmin edilen dalga gücü değerleri için ResNet ve XGB modellerini performansları karşılaştırılmıştır. Her iki şamandıra için dalga gücünün tahmin edilmesinde XGB modeli ResNet (temel regresyon) modeline göre genel olarak daha iyi performans göstermiştir.

Samsun şamandırasında dalga gücü tahminin de XGB modeli ile ResNet modelinin hata değerleri arasında fark yüksek olmasına karşın Ordu şamandırasında bu durum daha düşük farklılıklarla XGB modelinin daha iyi performans göstermesi ile tamamlanmıştır. İki şamandıra arasındaki bu hata farklılıkları dalga boyu yüksekliği ve periyodu tahmin eden temel regresyon modellerinin performanslarına bağlı olarak değişkenlik gösterdiği düşünülmektedir. Ayrıca Ordu şamandırasında XGB algoritması için görülen eksikliklerin düşük seviyelerde olduğu ve dalga gücü hesaplarına yansımadağı görülmektedir.

Literatürde Karadeniz bölgesinde dalga gücü analizi gerçekleştiren çalışmalar bulunmaktadır. Çalışmaların tamamında Karadeniz bölgesinde fiziksel tabanlı analiz yöntemi olan SWAN kullanılarak analizler gerçekleştirilmiştir (Akpınar vd., 2017; Islek vd., 2021; E. Rusu, 2009; L. Rusu, 2019, 2020). Ancak literatürde tez çalışmasında gerçekleştirildiği şekilde lokasyona ve gerçek verilere dayanarak Karadeniz bölgesinde dalga gücünden potansiyel elektrik enerjisi tahmini yapan bir çalışma bulunmamaktadır.

SWAN modellemesi ile tezde gerçekleştirilen tahmin modeli arasındaki farklılıklar tanımlanacak olursa;

- SWAN gibi fiziksel modellemeler rüzgar verilerini ve dalga dinamiklerini denklemlerle tanımlayarak simülasyonla dalga gücü hesabı yaparken, çalışmada gerçek şamandıra verileri kullanılarak makine öğrenimi ile dalga yüksekliği ve periyodu tahmin edilerek dalga gücü hesaplaması yapmaktadır.
- SWAN analizi genellikle kıyı mühendisliğinde kıyı koruma yapılarının tasarımında toplam enerji potansiyelini hesaplarken, çalışmada dalga gücünün direkt olarak enerji üretim potansiyelini analiz eden bir yaklaşım sunulmaktadır.
- SWAN analizi genellikle uzun periyotlarda (ay, mevsim, yıl vb.) periyotlarda genel güç analizi gerçekleştirirken çalışmada bu periyotlar daha kısa vadeli olacak şekilde gerçek zamanlı veya yakın zamanlı dalga enerjisinin tahmini gerçekleştirilebilmektedir.
- Bölgesel olarak SWAN analizi çok geniş bir alanda geniş ölçekli olarak güç analizi yaparken çalışmada Samsun ve Ordu gibi spesifik lokasyonlarda analiz gerçekleştirilerek Karadeniz’de yerel enerji potansiyellerinin hassas bir değerlendirmesini sunmaktadır.

Tez çalışmasında dalga boyu yüksekliğinin tahmini için girdi veri setinde kullanılan parametreler ile dalga periyodu için kullanılan parametreler farklılık göstermektedir. Bunun temel nedeni dalga boyu yüksekliği ve periyodunun farklı parametrelere bağımlılık göstermeleridir. Dalga boyu yüksekliğinde derinlik akıntılarından bazıları kullanılırken bu parametreler dalga periyodu tahmininde negatif etki yaptığı için girdi parametrelerinden çıkartılmıştır. Derinlik akıntılarının dalga yüksekliği tahmininde kullanım potansiyelini Karabulut ve Ozmen Koca, (2020) çalışmalarında göstermişlerdir. Karabulut ve Ozmen Koca, çalışmalarında 5m, 10m ve 15m derinlik akıntıları ile dalga boyu yüksekliğinin tahmini üzerine araştırma yapmışlardır. Farklı regresyon algoritmaları kullanmalarına karşın tahmin modellerinin performans değerlendirmesinde tez çalışmasındaki gibi RMSE, MAE, R^2 ve MSE metriklerini kullanmışlardır. Ayrıca çalışmada ilgili üç derinlik akıntısının bir arada dalga yüksekliği tahmininde performans metriklerinde en iyi sonucu verdiğini ancak işlem süresini arttırdığını ortaya koymuşlardır. Giriş parametrelerinin etkileri, analiz aşamasında benzer bir etki gösterdiği için üç derinlik akıntı hızı da dalga boyu yüksekliği tahmininde kullanılmıştır.

Literatürdeki potansiyelinin dalga gücünün değerlendirmesi üzerine gerçekleştirilen çalışmalarda dalga boyu yüksekliğini tahmin edilmesine ve regresyon modellerinin performans karşılaştırmalarına yer verilmiştir (Berbić vd., 2017; Fan vd., 2020; Sadeghifar vd., 2017; Tarwidi vd., 2023). Genel olarak çalışmalar yöntem aşamalarında farklı regresyon modellerinin performans karşılaştırılması ya da yeni algoritma kombinasyonları önerilerek performans değerlendirilmesi yapılmıştır. Fan ve arkadaşları diğer çalışmalardan farklı olarak 10 farklı şamandıra istasyonu verisinde algoritmaların karşılaştırılmasının yanı sıra 1 saatlik ve 6 saatlik zaman dilimlerinde tahmin modellerinin performans değerlendirmesini de incelemiştir. Ancak sadece belirgin dalga yüksekliği tahmini ile dalga gücü tahmini gerçekleştirmişlerdir. Dalga gücü, dalga yüksekliğinin karesi ile doğru orantılı olduğu bu yaklaşımlar doğru olmalarının yanı sıra hesaplamada dalga periyoduna dair bir bilgi olmadığı için eksik bir analiz sonucu vermektedir. Tez çalışmasında dalga boyu yüksekliği ile dalga periyodu tahmini gerçekleştirilerek dalga gücü hesaplaması gerçekleştirilerek bu çalışmalardaki önerilen yaklaşımın eksik yanlarının tamamlanması ve daha iyi bir dalga gücü analizi gerçekleştirilerek literatüre sunulmuştur.

8. SONUÇLAR VE ÖNERİLER

Yenilebilir enerji kaynaklarından enerji üretiminde en yaygın olarak kullanılan enerji kaynakları; güneş, rüzgar ve hidroelektrik olarak sıralanabilir. Daha az kurulu güce sahip biyokütle, jeotermal ve dalga gibi farklı yenilebilir enerji kaynaklarından da elektrik enerjisi üretimi gerçekleştirilmektedir. Yenilebilir enerji kaynakları arasında dalga enerjisi en yüksek potansiyele sahip alternatif enerji kaynağı olarak dikkat çekmektedir. Dalga enerjisi dönüşüm sistemleri maliyetli yapılar olduğu için sistemin kurulacağı bölgedeki dalga gücü potansiyelinin hesaplanması önem arz etmektedir. Dalga gücünün watt/metre cinsinden hesaplanmasında temel etkenler dalga yüksekliği ve periyodu olmasının yanı sıra güç değeri suyun özgül ağırlığına da bağlı olarak değişkenlik göstermektedir. Bu nedenle farklı deniz/okyanus kıyılarında üretilecek elektrik enerjisi potansiyeli aynı olmamaktadır. Dalga gücünün hesaplanması hem teknolojik hem de ekonomik açıdan önemli bilgiler sağlayarak dalga enerjisi dönüşüm projelerinin tasarımı ve uygulanabilirliğinin değerlendirilmesinde önem arz etmektedir.

Enerji kaynaklarından üretilen elektrik enerjisinin depolanması büyük bir maliyet gerektirmektedir. Bu nedenle elektrik enerjisi depolama yapılmadan direkt olarak şebekeye aktarılarak doğrudan müşterinin kullanımına sunulmaktadır. Şebekeye güvenli bir şekilde güç aktarılabilmesi için gücün belirli bir aralıkta olması, ani dalgalanmaların olmaması gerekmektedir. Fazla ya da az gücün şebekeye aktarılması elektronik cihazların bozulmasına sebebiyet vermektedir. Dalga gücünün yüksek potansiyeline rağmen az kullanılmasının temel nedenlerinden birisi olarak dalga enerji dönüşüm sisteminde üretilecek olan elektrik enerjisi gücünün hesaplanmasında karşılaşılan zorluk olarak görülmektedir. Dalga gücü birçok faktöre bağımlı olarak (rüzgar, akıntı hızı, basınç vb.) değişkenlik göstermesinden kaynaklı karmaşık bir yapıdadır. Dalga gücünün tahmin edilebilmesi büyük potansiyelli bu yenilenebilir enerji kaynağının kullanımına imkan sağlayacağı düşünülmektedir.

Açık denizlerde bulunan şamandıralarında ölçülen parametreler kullanılarak dalga gücünün tahmin edilmesi gerçekleştirilebilir. Tez çalışmasında Ordu ve Samsun illerinde yer alan deniz şamandıralarından veriler alınarak farklı zaman aralıklarında (1 saat, 3 saat, 6 saat, 12 saat, 24 saat ve 72 saat) dalga gücünün tahmin edilmesi amaçlanmıştır. Çalışmada kullanılması için Meteoroloji Genel Müdürlüğü'nden iki farklı lokasyonda yer alan şamandıralara ait 1'er yıllık ölçüm verileri talep edilerek alınmıştır. Dalga gücünün

tahmin edilmesi için ölçüm parametrelerinden dalga yüksekliği ve periyodu ayrı ayrı olarak tahmin edilmiştir. Ardından tahmin edilen dalga boyu yüksekliği ve periyodu kullanılarak dalga gücü hesaplanmıştır.

Şamandıra verilerinden dalga yüksekliği ve periyodu tahmini için kullanılan ölçüm parametreleri aynı değildir. Bu parametrelerin belirlenmesinde ölçümlerin kendi aralarında korelasyon analizi yapılarak değerlendirilmiştir. Yöntem aşamasında altı farklı temel regresyon algoritmaları ile tahmin gerçekleştirilip daha sonrasında yığınlama yaklaşımı kullanılarak tahmin değerlerinin iyileştirilmesi sağlanmıştır. Temel regresyon modelleri olarak LSTM, ELM, SVM, ResNet, Bayesian ve RNN algoritmaları kullanılmıştır. Temel regresyon algoritmalarının seçiminde farklı avantaja ve dezavantaja sahip algoritmaların seçilmesine dikkat edilmiştir. Yığınlama yaklaşımında ise XGB algoritması kullanılmıştır. Eğitilen tahmin modellerinin performans değerlendirmeleri için de MAE, RMSE, MSE ve R^2 metrik değerleri hesaplanmıştır. Temel regresyon modelleri arasında ResNet algoritması tüm zaman dilimlerinde en iyi performans gösteren model olarak gözlenmiştir.

Çalışma kapsamını geniş bir yelpazede gerçekleştirebilmek için 2 farklı şamandıra verisi, 6 farklı saat aralığında tahmin gerçekleştirilmiştir. Ordu ve Samsun şamandıra verileri ile eğitilen modellerin yapıları (gizli katman, gecikme sayısı, öğrenme oranı vb.) sabit tutularak geliştirilen modellerin çalışma performansları incelenmiştir. Dalga yüksekliğini ve periyodunu tahmin eden modellerin yapıları birbirlerine göre farklılık göstermektedir. Önerilen sistemin Karadeniz özelinde olmak üzere, farklı lokasyonlardaki dalga gücü tahminindeki potansiyelinin, avantajlarının ve geliştirilmesi gereken hususların tespit belirlenerek değerlendirilmesi için model yapıları sabit tutulmuştur. Genel sonuçlara bakıldığında zaman Samsun şamandırasına ait veriler Ordu şamandırasına göre daha yumuşak geçişlere ve düzenli bir yapıda olduğu için performans metrikleri arasında değişkenlikler gözlenmiştir. Ordu şamandırasına ait verilerin kısa zamanlara uç değerlere değişim göstermesi hem dalga yüksekliğinin hem de dalga periyodunun tahminin de ResNet ve XGB modellerinin performansları arasında yakın değer oluşmasına sebebiyet vermektedir. Bu durumun değerlendirilmesi Tartışma başlığı altında gerçekleştirilmiştir. Farklı saat aralıklarında tahminlerin yapılmasının amacı sistemin kısa ve uzun süreli olarak dalga gücü tahmini performanslarını değerlendirmek ve kullanılan modellerin bu zaman aralıklarında performanslarının değişimini incelemektir. Saat aralıkları modellerin

performans metriklerinde deęişkenlik göstermiř ve saat aralıęı arttıkça tahmin deęerlerinde daha büyük hatalar meydana gelmiřtir.

Temel regresyon modelleri ile yığınlama yaklařımında kullanılan XGB modelinin performans metrikleri arasında karřılařtırma yapılacak olursa XGB genel olarak daha iyi performans göstermektedir. Ancak burada temel regresyon modellerinin řamandıra verilerinden doęrudan tahmin yaparak XGB algoritmasına temel girdileri saęladıkları göz önünde bulundurulmalıdır. XGB modeli, yığınlama yaklařımı ile dięer 6 modelin (Bayesian, ELM, LSTM, ResNet, RNN, SVM) tahminlerini birleřtirerek tahmin yapmaktadır. Bu yaklařım sayesinde XGB modeli temel regresyon modellerinin güçlü yanlarını bir araya getirerek hata oranlarını düşürmekte ve R^2 deęerini artırmaktadır. Özellikle kısa süreli tahminlerde XGB düşük hata deęerlerine sahipken uzun vadeli tahminlerde daha yüksek belirsizlięe raęmen dięer modellerden daha düşük hata deęerine sahiptir. Temel regresyon modelleri arasında performans deęerlendirmesi yapılacak olursa; LSTM ve RNN zaman baęımlılıklarını modellemede güçlü algoritmalar, ancak genel performansları düşük olarak gözlenmiřtir. Özellikle kısa vadede (1H, 3H) hata oranları yüksektir. SVM ve ELM küçük veri setlerinde iyi sonuçlar verebilirler, ancak doęrusal olmayan řamandıra verilerinde, karmařık iliřkilerde performansları sınırlı kalabileceęi gözlenmiřtir. ResNet orta vadeli tahminlerde (6H, 12H) daha iyi performans göstermiř olup uzun vadede doęruluęu azalmaktadır. Temel regresyon modelleri arasında en iyi tahmin performansı saęlayan model olmuřtur. Bayesian genellikle olasılıksal belirsizlikleri modellemede avantajlıdır, ancak tahmin sonuçlarına bakıldıda zaman kesin doęruluk aęısından performansının sınırlı kalabileceęi gözlenmiřtir.

Temel regresyon modellerinde kullanılan her algoritmanın farklı avantajları ve dezavantajları vardır. LSTM algoritması zaman baęımlılıklarını yakalamada iyi performans gösterse de derin modellerde ezberleme yapmaya yatkındır. ELM, büyük veri setlerinde bile hızlı sonuçlar elde edebilirken zaman serilerinde LSTM ve ResNet kadar iyi genelleme yapamaz. SVM, doęrusal olmayan iliřkileri modelleme de başarılı bir performans gösterirken hiper parametre ayarlanması zaman almaktadır. ResNet, çok katmanlı yapısı gereęi karmařık ve uzun vadeli iliřkileri öğrenmede avantaj saęlarken model performansı için büyük veri setine ve uzun eęitim süresine ihtiyaę duymaktadır. Bayesian, belirsizlięi olasılıksal bir haritalama ile modelleyebilirken büyük veri setlerinde hesaplama maliyeti yüksektir. RNN, zaman serilerinin tahmin edilmesinde etkili bir algoritma olmasına raęmen uzun vadeli baęımlılıklarda zayıf kalabilmektedir.

Temel regresyon modellerinin avantaj ve dezavantajları göz önüne alındığı zaman en iyi performansın ResNet algoritmasında olması beklenmiştir. Bulgular başlığı altında verilen eğitim sonuçları da bu beklentinin doğru şekilde karşılandığını ortaya koymaktadır. Bu nedenle XGB algoritmasının dalga gücü tahmini üzerindeki etkisinin incelenmesi için algoritma tüm temel regresyon modelleri ile değil sadece ResNet algoritması ile karşılaştırılması bulgular başlığı altında verilmiştir. Samsun şamandırasına ait XGB ve ResNet modelleri Ordu şamandırasına göre daha iyi performans göstermiştir. XGB algoritması kısa süreli tahminlerde iki bölgede de güçlü bir performans göstermiştir. ResNet algoritması Ordu şamandırasında kısa süreli tahminlerde iyi sonuçlar verse de genle performansı XGB algoritmasının gerisinde kalmıştır.

Tez çalışmasında önerilen sistemin geliştirilmesi kısmında farklı işlemler gerçekleştirilebilir. Öncelikle çalışma alanı Karadeniz bölgesinde Samsun ve Ordu illeri özelinde gerçekleştirilmiştir. Geliştirilen sistemin yine Karadeniz bölgesinde yer alan ek şamandıra verileri üzerinde test edilerek performansı değerlendirilebilir. Ayrıca sisteme Karadeniz bölgesinde ek şamandıra verileri ile yapılacak güncelleme sonucunda sistemin genelleme performansına da katkı sağlayacaktır.

Şamandıraların birer yıllık verileri kullanılarak sisteme ait regresyon modelleri eğitilmiştir. Eğitilen modeller de 1 ile 72 saat arasında zaman aralıklarında tahmin gerçekleştirmektedir. Daha uzun periyotlarda yapılacak tahmin değerlerinin hatası giderek artacak ve kabul edilemeyecek seviyeye gelecektir. Şamandıralara ait 5-10 yıllık veriler ile sisteme ait alt modelleri eğitilirse uzun periyotlarda dalga gücünün mevsimsel veya yıllık incelenmesi araştırılabileceği düşünülmektedir.

Temel regresyon modellerinin hata değerlerinin giderilmesi kısmında yığınlama yaklaşımı kullanılmıştır. Yığınlama yaklaşımında XGB algoritması kullanılmıştır. Bu kısımda XGB algoritmasının yanı sıra LightGBM ve CatBoost gibi algoritmalar da kullanılarak sistem performansının değerlendirilmesi gerçekleştirilebilir. Yığınlama yaklaşımında kullanılacak algoritmanın hiper parametre optimizasyonu için de farklı yöntemler test edilerek değerlendirme yapılabilir.

Sistemin denizde meydana gelebilecek fırtına ve ekstrem hava koşullarına karşı dayanıklılığı bulunmamaktadır. Bu durumun çözülmesi için ekstrem hava koşullarında meydana gelen ölçümleri değerlerinin sisteme eğitim için verilmeli ve tanıtılması

gerekmektedir. Karadeniz’de ilgili hava koşullarının belirlenmesi aynı zamanda iklim değişikliğinin dalga gücü üzerindeki etkisinin değerlendirmesine de katkı sağlayabilir.

SWAN gibi fiziksel modelleme yapıları ile makine öğrenimi algoritmalarının tahmin yapısı entegre edilerek deniz/okyanus bölgelerinde dalga gücü yoğunluğunun geniş yelpazede değerlendirilmesi için yeni çalışmalar gerçekleştirilebilir. Geniş yelpazede bir değerlendirme yapılması kurulacak dalga enerjisi dönüştürücülerinin konumlarını belirlemeye olanak sağlayabilir.



KAYNAKLAR

- Abed-Elmdoust, A., & Kerachian, R. (2012). Wave height prediction using the rough set theory. *Ocean Engineering*, 54, 244-250. <https://doi.org/10.1016/j.oceaneng.2012.07.020>
- Afzal, M. S., Kumar, L., Chugh, V., Kumar, Y., & Zuhair, M. (2023). Prediction of significant wave height using machine learning and its application to extreme wave analysis. *Journal of Earth System Science*, 132(2), 51. <https://doi.org/10.1007/s12040-023-02058-5>
- Akpınar, A., Bingölbali, B., & Van Vledder, G. P. (2017). Long-term analysis of wave power potential in the Black Sea, based on 31-year SWAN simulations. *Ocean Engineering*, 130, 482-497.
- Akpınar, A., & Kömürcü, M. İ. (2012). Wave energy potential along the south-east coasts of the Black Sea. *Energy*, 42(1), 289-302.
- Akyüz, A., & Elcil, Ş. (2023). An Empirical Study on Consumer Attitudes Toward Renewable Energy in Turkey. İçinde *Renewable Energy Investments for Sustainable Business Projects* (ss. 191-203). Emerald Publishing Limited.
- Aljohani, H., Alshamrani, S., Aljoj, N., Tashkandi, A., & Alshafi, T. (2024). Predicting monthly gold prices in indian rupees using ARIMA, LSTM, GRU, and Simple Linear Regression models. *Romanian Journal of Information Technology and Automatic Control*, 34(2), 35-48.
- Aly, H. H. (2020). An intelligent hybrid model of neuro Wavelet, time series and Recurrent Kalman Filter for wind speed forecasting. *Sustainable Energy Technologies and Assessments*, 41, 100802.
- Ambach, D., & Schmid, W. (2017). A new high-dimensional time series approach for wind speed, wind direction and air pressure forecasting. *Energy*, 135, 833-850.
- Babarit, A. (2015). A database of capture width ratio of wave energy converters. *Renewable Energy*, 80, 610-628.
- Bai, Y., Xie, J., Liu, C., Tao, Y., Zeng, B., & Li, C. (2021). Regression modeling for enterprise electricity consumption: A comparison of recurrent neural network and its variants. *International Journal of Electrical Power & Energy Systems*, 126, 106612.
- Bento, P., Pombo, J., Mendes, R., Calado, M., & Mariano, S. (2021). Ocean wave energy forecasting using optimised deep learning neural networks. *Ocean Engineering*, 219, 108372.
- Berbić, J., Ocvirk, E., Carević, D., & Lončar, G. (2017). Application of neural networks and support vector machine for significant wave height prediction. *Oceanologia*, 59(3), 331-349.
- Bianchi, F. M., Maiorino, E., Kampffmeyer, M. C., Rizzi, A., & Jenssen, R. (2017). Recurrent Neural Network Architectures. İçinde F. M. Bianchi, E. Maiorino, M. C. Kampffmeyer, A. Rizzi, & R. Jenssen (Ed.), *Recurrent Neural Networks for Short-Term Load Forecasting: An Overview and Comparative Analysis* (ss. 23-29). Springer International Publishing. https://doi.org/10.1007/978-3-319-70338-1_3
- Bodhwani, V., Acharjya, D., & Bodhwani, U. (2019). Deep residual networks for plant identification. *Procedia Computer Science*, 152, 186-194.
- Chen, Y., Wang, Y., Dong, Z., Su, J., Han, Z., Zhou, D., Zhao, Y., & Bao, Y. (2021). 2-D regional short-term wind speed forecast based on CNN-LSTM deep learning model. *Energy Conversion and Management*, 244, 114451.

- Choi, H., Park, M., Son, G., Jeong, J., Park, J., Mo, K., & Kang, P. (2020). Real-time significant wave height estimation from raw ocean images based on 2D and 3D deep neural networks. *Ocean Engineering*, 201, 107129.
- Clemente, D., Teixeira-Duarte, F., Rosa-Santos, P., & Taveira-Pinto, F. (2023). Advancements on optimization algorithms applied to wave energy assessment: An overview on wave climate and energy resource. *Energies*, 16(12), 4660.
- Cuadra, L., Salcedo-Sanz, S., Nieto-Borge, J., Alexandre, E., & Rodríguez, G. (2016). Computational intelligence in wave energy: Comprehensive review and case study. *Renewable and Sustainable Energy Reviews*, 58, 1223-1246.
- Dash, R. K., Nguyen, T. N., Cengiz, K., & Sharma, A. (2023). Fine-tuned support vector regression model for stock predictions. *Neural Computing and Applications*, 35(32), 23295-23309. <https://doi.org/10.1007/s00521-021-05842-w>
- Deshmukh, M. K. G., Sameeroddin, M., Abdul, D., & Abdul Sattar, M. (2023). Renewable energy in the 21st century: A review. *SI:5 NANO* 2021, 80, 1756-1759. <https://doi.org/10.1016/j.matpr.2021.05.501>
- Dilaveroğlu, E. (2023). Electricity Production and Use From Renewable Energy Resources Within the Framework of Turkish Legal Legislation. İçinde H. Dinçer & S. Yüksel (Ed.), *Renewable Energy Investments for Sustainable Business Projects* (ss. 141-151). Emerald Publishing Limited. <https://doi.org/10.1108/978-1-80382-883-120231011>
- Ding, M., Zhou, H., Xie, H., Wu, M., Nakanishi, Y., & Yokoyama, R. (2019). A gated recurrent unit neural networks based wind speed error correction model for short-term wind power forecasting. *Neurocomputing*, 365, 54-61.
- Duarte, F. T., Clemente, D., Giannini, G., Santos, P. R., & Pinto, F. T. (2022). *Review on layout optimization strategies of offshore parks for wave energy converters*.
- Edenhofer, O., Pichs-Madruga, R., Sokona, Y., Seyboth, K., Kadner, S., Zwickel, T., Eickemeier, P., Hansen, G., Schlömer, S., & von Stechow, C. (2011). *Renewable energy sources and climate change mitigation: Special report of the intergovernmental panel on climate change*. Cambridge University Press.
- Enerji ve Tabi Kaynaklar Bakanlığı. (2022). *Enerji ve Tabi Kaynaklar Bakanlığı 2022 yılı Raporu*. <https://enerji.gov.tr/eigm-yenilenebilir-enerji-kaynaklar>
- ETKB, E. (2020). *Enerji ve Tabi Kaynaklar Bakanlığı 2020 yılı Raporu*.
- F. Anggraeni, D. Adytia, & A. W. Ramadhan. (2021). Forecasting of Wave Height Time Series Using AdaBoost and XGBoost, Case Study in Pangandaran, Indonesia. *2021 International Conference on Data Science and Its Applications (ICoDSA)*, 97-101. <https://doi.org/10.1109/ICoDSA53588.2021.9617524>
- Fan, S., Xiao, N., & Dong, S. (2020). A novel model to predict significant wave height based on long short-term memory network. *Ocean Engineering*, 205, 107298. <https://doi.org/10.1016/j.oceaneng.2020.107298>
- Ghafoorian, M., Karssemeijer, N., Heskes, T., Bergkamp, M., Wissink, J., Obels, J., Keizer, K., de Leeuw, F.-E., Van Ginneken, B., & Marchiori, E. (2017). Deep multi-scale location-aware 3D convolutional neural networks for automated detection of lacunes of presumed vascular origin. *NeuroImage: Clinical*, 14, 391-399.
- Graves, A. (2012). Long Short-Term Memory. İçinde A. Graves (Ed.), *Supervised Sequence Labelling with Recurrent Neural Networks* (ss. 37-45). Springer Berlin Heidelberg. https://doi.org/10.1007/978-3-642-24797-2_4
- Guang-Bin Huang, Qin-Yu Zhu, & Chee-Kheong Siew. (2004). Extreme learning machine: A new learning scheme of feedforward neural networks. *2004 IEEE International Joint*

- Conference on Neural Networks (IEEE Cat. No.04CH37541)*, 2, 985-990 c.2.
<https://doi.org/10.1109/IJCNN.2004.1380068>
- H. Kulasekara & V. Seynulahdeen. (2019). A Review of Geothermal Energy for Future Power Generation. *2019 5th International Conference on Advances in Electrical Engineering (ICAEE)*, 223-228. <https://doi.org/10.1109/ICAEE48663.2019.8975470>
- Hajihosseini, M., Maghsoudi, A., & Ghezelbash, R. (2024). Stacking: A novel data-driven ensemble machine learning strategy for prediction and mapping of Pb-Zn prospectivity in Varcheh district, west Iran. *Expert Systems with Applications*, 237, 121668. <https://doi.org/10.1016/j.eswa.2023.121668>
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). *Deep residual learning for image recognition*. 770-778.
- Hong, Y.-Y., & Rioflorida, C. L. P. P. (2019). A hybrid deep learning-based neural network for 24-h ahead wind power forecasting. *Applied Energy*, 250, 530-539.
- Hu, H., van der Westhuysen, A. J., Chu, P., & Fujisaki-Manome, A. (2021). Predicting Lake Erie wave heights and periods using XGBoost and LSTM. *Ocean Modelling*, 164, 101832. <https://doi.org/10.1016/j.ocemod.2021.101832>
- Hu, J., Heng, J., Wen, J., & Zhao, W. (2020). Deterministic and probabilistic wind speed forecasting with de-noising-reconstruction strategy and quantile regression based algorithm. *Renewable Energy*, 162, 1208-1226.
- Hu, Y.-L., & Chen, L. (2018). A nonlinear hybrid wind speed forecasting model using LSTM network, hysteretic ELM and Differential Evolution algorithm. *Energy conversion and management*, 173, 123-142.
- Huang, G.-B., Zhu, Q.-Y., & Siew, C.-K. (2006). Extreme learning machine: Theory and applications. *Neural Networks*, 70(1), 489-501. <https://doi.org/10.1016/j.neucom.2005.12.126>
- Islek, F., Yuksel, Y., Sahin, C., & Guner, H. A. A. (2021). Long-term analysis of extreme wave characteristics based on the SWAN hindcasts over the Black Sea using two different wind fields. *Dynamics of Atmospheres and Oceans*, 94, 101165.
- Jones, A. M., Lomas, J., Moore, P. T., & Rice, N. (2016). A Quasi-Monte-Carlo Comparison of Parametric and Semiparametric Regression Methods for Heavy-tailed and Non-normal Data: An Application to Healthcare Costs. *Journal of the Royal Statistical Society Series A: Statistics in Society*, 179(4), 951-974. <https://doi.org/10.1111/rssa.12141>
- Karabulut, N., & Ozmen Koca, G. (2020). Wave height prediction with single input parameter by using regression methods. *Energy Sources, Part A: Recovery, Utilization, and Environmental Effects*, 42(24), 2972-2989. <https://doi.org/10.1080/15567036.2020.1733711>
- Koç, E., & Şenel, M. C. (2013). Dünyada ve Türkiye’de enerji durumu-genel değerlendirme. *Mühendis ve Makina*, 54(639), 32-44.
- Kulkarni, S. A., Gurupur, V. P., & King, C. (2022). *Impact Analysis of Stacked Machine Learning Algorithms Based Feature Selections for Deep Learning Algorithm Applied to Regression Analysis*. 269-275.
- Kumar, N. K., Savitha, R., & Mamun, A. A. (2017). Regional ocean wave height prediction using sequential learning neural networks. *Ocean Engineering*, 129, 605-612. <https://doi.org/10.1016/j.oceaneng.2016.10.033>
- Langhamer, O., Haikonen, K., & Sundberg, J. (2010). Wave power—Sustainable energy or environmentally costly? A review with special emphasis on linear wave energy converters. *Renewable and Sustainable Energy Reviews*, 14(4), 1329-1335.

- Lipton, Z. C., Berkowitz, J., & Elkan, C. (2015). A critical review of recurrent neural networks for sequence learning. *arXiv preprint arXiv:1506.00019*.
- López, I., Andreu, J., Ceballos, S., De Alegría, I. M., & Kortabarria, I. (2013). Review of wave energy technologies and the necessary power-equipment. *Renewable and sustainable energy reviews*, 27, 413-434.
- M. Umair, M. A. Hashmani, & M. H. B. Hasan. (2019). Survey of Sea Wave Parameters Classification and Prediction using Machine Learning Models. *2019 1st International Conference on Artificial Intelligence and Data Sciences (AiDAS)*, 1-6. <https://doi.org/10.1109/AiDAS47888.2019.8970706>
- Mahdavi-Meymand, A., & Sulisz, W. (2023). Application of nested artificial neural network for the prediction of significant wave height. *Renewable Energy*, 209, 157-168. <https://doi.org/10.1016/j.renene.2023.03.118>
- Mahjoobi, J., & Etemad-Shahidi, A. (2008). An alternative approach for the prediction of significant wave heights based on classification and regression trees. *Applied Ocean Research*, 30(3), 172-177. <https://doi.org/10.1016/j.apor.2008.11.001>
- Mahmoodi, K., Ghassemi, H., & Nowruzi, H. (2017). Data mining models to predict ocean wave energy flux in the absence of wave records. *Zeszyty Naukowe Akademii Morskiej w Szczecinie*.
- Massaoudi, M., Refaat, S. S., Chihi, I., Trabelsi, M., Oueslati, F. S., & Abu-Rub, H. (2021). A novel stacked generalization ensemble-based hybrid LGBM-XGB-MLP model for Short-Term Load Forecasting. *Energy*, 214, 118874. <https://doi.org/10.1016/j.energy.2020.118874>
- Meharie, M. G., Mengesha, W. J., Gariy, Z. A., & Mutuku, R. N. (2022). Application of stacking ensemble machine learning algorithm in predicting the cost of highway construction projects. *Engineering, Construction and Architectural Management*, 29(7), 2836-2853.
- Moe, S. J., Wolf, R., Xie, L., Landis, W. G., Kotamäki, N., & Tollefsen, K. E. (2021). Quantification of an Adverse Outcome Pathway Network by Bayesian Regression and Bayesian Network Modeling. *Integrated Environmental Assessment and Management*, 17(1), 147-164. <https://doi.org/10.1002/ieam.4348>
- Mohan, A. T., & Gaitonde, D. V. (2018). A deep learning based approach to reduced order modeling for turbulent flow control using LSTM neural networks. *arXiv preprint arXiv:1804.09269*.
- Mork, G., Barstow, S., Kabuth, A., & Pontes, M. T. (2010). Assessing the global wave energy potential. *49118*, 447-454.
- Mousavi, S. M., Ghasemi, M., Dehghan Manshadi, M., & Mosavi, A. (2021). Deep learning for wave energy converter modeling using long short-term memory. *Mathematics*, 9(8), 871.
- Müller, K.-R., Smola, A. J., Rätsch, G., Schölkopf, B., Kohlmorgen, J., & Vapnik, V. (1998). *Using support vector machines for time series prediction*.
- Nam, K., Hwangbo, S., & Yoo, C. (2020). A deep learning-based forecasting model for renewable energy scenarios to guide sustainable energy policy: A case study of Korea. *Renewable and Sustainable Energy Reviews*, 122, 109725.
- Özdamar, A. (2000). Dalga enerjisinden elektrik enerjisi eldesi üzerine bir araştırma: Çeşme örneği. *Su Ürünleri Dergisi*, 17(1-2), 201-213.
- Özhan, E., & Abdalla, S. (2002). *Türkiye kıyıları rüzgar ve derin deniz dalga atlası*. MEDCOAST, ODTÜ.
- Özkop, E. (2012). *An intelligent controlled novel power conditioning for wave energy converter systems*.

- P. Abhigna, S. Jerritta, R. Srinivasan, & V. Rajendran. (2017). Analysis of feed forward and recurrent neural networks in predicting the significant wave height at the moored buoys in Bay of Bengal. *2017 International Conference on Communication and Signal Processing (ICCSP)*, 1856-1860. <https://doi.org/10.1109/ICCSP.2017.8286717>
- Panwar, N. L., Kaushik, S. C., & Kothari, S. (2011). Role of renewable energy sources in environmental protection: A review. *Renewable and sustainable energy reviews*, 15(3), 1513-1524.
- Patanè, L., Iuppa, C., Faraci, C., & Xibilia, M. G. (2024). A deep hybrid network for significant wave height estimation. *Ocean Modelling*, 189, 102363. <https://doi.org/10.1016/j.ocemod.2024.102363>
- Pirhooshyaran, M., & Snyder, L. V. (2019). Multivariate, multistep forecasting, reconstruction and feature selection of ocean waves via recurrent and sequence-to-sequence networks. *arXiv preprint arXiv:1906.00195*.
- Reikard, G., Robertson, B., & Bidlot, J.-R. (2015). Combining wave energy with wind and solar: Short-term forecasting. *Renewable Energy*, 81, 442-456.
- Ruehl, K., & Bull, D. (2012). *Wave energy development roadmap: Design to commercialization*. 1-10.
- Rusu, E. (2009). Wave energy assessments in the Black Sea. *Journal of marine science and technology*, 14, 359-372.
- Rusu, L. (2019). The wave and wind power potential in the western Black Sea. *Renewable energy*, 139, 1146-1158.
- Rusu, L. (2020). A projection of the expected wave power in the Black Sea until the end of the 21st century. *Renewable Energy*, 160, 136-147.
- S. Hochreiter & J. Schmidhuber. (1997). Long Short-Term Memory. *Neural Computation*, 9(8), 1735-1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- S. Nie, M. Zheng, & Q. Ji. (2018). The Deep Regression Bayesian Network and Its Applications: Probabilistic Deep Learning for Computer Vision. *IEEE Signal Processing Magazine*, 35(1), 101-111. <https://doi.org/10.1109/MSP.2017.2763440>
- Sadeghifar, T., Nouri Motlagh, M., Torabi Azad, M., & Mohammad Mahdizadeh, M. (2017). Coastal wave height prediction using Recurrent Neural Networks (RNNs) in the south Caspian Sea. *Marine Geodesy*, 40(6), 454-465.
- Sağlam, M., Sulukan, E., & Uyar, T. S. (2010). Wave energy and technical potential of Turkey. *Journal of Naval Sciences and Engineering*, 6(2), 34-50.
- Serre, D. (2002). *Matrices: Theory and Applications*.
- Smola, A. J., & Schölkopf, B. (2004). A tutorial on support vector regression. *Statistics and computing*, 14, 199-222.
- Tarwidi, D., Pudjaprasetya, S. R., Adytia, D., & Apri, M. (2023). An optimized XGBoost-based machine learning method for predicting wave run-up on a sloping beach. *MethodsX*, 10, 102119. <https://doi.org/10.1016/j.mex.2023.102119>
- Teixeira-Duarte, F., Clemente, D., Giannini, G., Rosa-Santos, P., & Taveira-Pinto, F. (2022). Review on layout optimization strategies of offshore parks for wave energy converters. *Renewable and Sustainable Energy Reviews*, 163, 112513.
- Tsoi, A. C. (1998). Recurrent neural network architectures: An overview. İçinde C. L. Giles & M. Gori (Ed.), *Adaptive Processing of Sequences and Data Structures: International Summer School on Neural Networks "E.R. Caianiello" Vietri sul Mare, Salerno, Italy September 6–13, 1997 Tutorial Lectures* (ss. 1-26). Springer Berlin Heidelberg. <https://doi.org/10.1007/BFb0053993>

- Uygur, İ., Demirci, R., Saruhan, H., Özkan, A., & Belenli, İ. (2006). BATI KARADENİZ BÖLGESİNDEKİ DALGA ENERJİSİ POTANSİYELİNİN ARAŞTIRILMASI. *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 12(1), 7-13.
- Vapnik, V. (1995). *The Nature of Statistical Learning Theory*. Springer-Verlag.
- Vicinanza, D., Contestabile, P., & Ferrante, V. (2013). Wave energy potential in the north-west of Sardinia (Italy). *Renewable Energy*, 50, 506-521.
- Vinayak, R. K., & Gilad-Bachrach, R. (2015). *Dart: Dropouts meet multiple additive regression trees*. 489-497.
- Wang, J., Zhang, L., Wang, C., & Liu, Z. (2021). A regional pretraining-classification-selection forecasting system for wind power point forecasting and interval forecasting. *Applied Soft Computing*, 113, 107941.
- Wang, L., Durante, D., Jung, R. E., & Dunson, D. B. (2017). Bayesian network–response regression. *Bioinformatics*, 33(12), 1859-1866.
- Wang, Y., Zou, R., Liu, F., Zhang, L., & Liu, Q. (2021). A review of wind speed and wind power forecasting with deep neural networks. *Applied Energy*, 304, 117766.
- Wei, C.-C., & Chang, H.-C. (2021). Forecasting of typhoon-induced wind-wave by using convolutional deep learning on fused data of remote sensing and ground measurements. *Sensors*, 21(15), 5234.
- X. Guan. (2020). Wave height prediction based on CNN-LSTM. *2020 2nd International Conference on Machine Learning, Big Data and Business Intelligence (MLBDBI)*, 10-17. <https://doi.org/10.1109/MLBDBI51377.2020.00009>
- Xiao, J., & Lu, P. (2024). A Hybrid Model of Conformer and LSTM for Ocean Wave Height Prediction. *Applied Sciences*, 14(14). <https://doi.org/10.3390/app14146139>
- Yang, H.-F., & Chen, Y.-P. P. (2019). Hybrid deep learning and empirical mode decomposition model for time series applications. *Expert Systems with Applications*, 120, 128-138.
- Yao, J., & Wu, W. (2022). Wave height forecast method with multi-step training set extension LSTM neural network. *Ocean Engineering*, 263, 112432. <https://doi.org/10.1016/j.oceaneng.2022.112432>
- Yesilyurt, M. K., Öner, İ. V., Ömeroğlu, G., & Yilmaz, E. Ç. (2017). A scrutiny study on wave energy potential and policy in TURKEY. *Periodicals of Engineering and Natural Sciences (PEN)*, 5(3).
- Zhang, X., & Dai, H. (2019). Significant Wave Height Prediction with the CRBM-DBN Model. *Journal of Atmospheric and Oceanic Technology*, 36(3), 333-351. <https://doi.org/10.1175/JTECH-D-18-0141.1>
- Zhao, R., Yan, R., Chen, Z., Mao, K., Wang, P., & Gao, R. X. (2019). Deep learning and its applications to machine health monitoring. *Mechanical Systems and Signal Processing*, 115, 213-237.

ÖZGEÇMİŞ

Adı Soyadı : Duygu SAYDAM İRİM

Yabancı Dili : İngilizce

Eğitim Durumu

Lise : Mehmet Kemal Tuncel, 2013

Lisans : Akdeniz Üniversitesi, 2019

Yüksek Lisans : Sinop Üniversitesi