

DEPREM VERİLERİNİN ZAMANSAL VE MEKANSAL ANALİZİ

Mehmet Barış ŞEN
191450103

DOKTORA TEZİ

Bilgisayar Mühendisliği Anabilim Dalı
Bilgisayar Mühendisliği Doktora Programı
Danışman: Doç. Dr. Volkan TUNALI

İstanbul
T.C. Maltepe Üniversitesi
Lisansüstü Eğitim Enstitüsü
Temmuz, 2025

DEPREM VERİLERİNİN ZAMANSAL VE MEKANSAL ANALİZİ

Mehmet Barış ŞEN

191450103

ORCID: 0000-0003-2252-6460

DOKTORA TEZİ

Bilgisayar Mühendisliği Anabilim Dalı
Bilgisayar Mühendisliği Doktora Programı
Danışman: Doç. Dr. Volkan TUNALI

İstanbul

T.C. Maltepe Üniversitesi

Lisansüstü Eğitim Enstitüsü

Temmuz, 2025



JÜRİ VE ENSTİTÜ ONAYI

MEHMET BARIŞ ŞEN'in "Deprem Verilerinin Zamansal ve Mekansal Analizi" başlıklı tezi 04.07.2025 tarihinde aşağıdaki jüri tarafından değerlendirilerek "Maltepe Üniversitesi Lisansüstü Eğitim ve Öğretim Yönetmeliği" nin ilgili maddeleri uyarınca Bilgisayar Mühendisliği Anabilim Dalı Yüksek Lisans/Doktora/Sanatta Yeterlik tezi oy birliğiyle/oy çokluğuyla, başarılı/başarısız olarak kabul edilmiştir.

	Unvanı, Adı ve Soyadı	İmza
Üye (Tez Danışmanı)	Doç.Dr. Volkan TUNALI (Danışman) Maltepe Üniversitesi	
Üye	Doç.Dr.Sibel ERSAN Maltepe Üniversitesi	
Üye	Dr.Öğr.Üyesi Erdal GÜVENOĞLU Maltepe Üniversitesi	
Üye	Dr.Öğr.Üyesi Emir KIZILIRMAK Antalya Belek Üniversitesi	
Üye	Dr.Öğr.Üyesi Sinan TATLIGİL İstanbul Sağlık ve Teknoloji Üniversitesi	

Prof. Dr. Selva ERSÖZ
KARAKULAKOĞLU
Enstitü Müdürü

ETİK İLKE VE KURALLARA UYUM BEYANI

Bu belge, Yükseköğretim Kurulu tarafından 19.01.2021 tarihli “Lisansüstü Tezlerin Elektronik Ortamda Toplanması, Düzenlenmesi ve Erişime Açılmasına İlişkin Yönerge” ile bildirilen 6698 Sayılı Kişisel Verilerin Korunması Kanunu kapsamında gizlenmiştir.



TEŞEKKÜR

Bu doktora tezinin hazırlanmasında katkıda bulunan, destek veren ve yanımda olan herkese en içten teşekkürlerimi sunarım. Öncelikle, akademik hayatım boyunca bana rehberlik eden, değerli bilgi ve deneyimlerini paylaşan danışmanım Doç. Dr. Volkan TUNALI' ya en derin teşekkürlerimi sunarım. Kendisinin bilimsel rehberliği, eleştirel bakış açısı, sabrı ve desteği olmadan bu çalışma tamamlanamazdı. Bana kazandırdığı akademik perspektif ve vizyon için kendisine minnettarım. Ayrıca, akademik gelişimime katkıda bulunan Maltepe Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı Bilgisayar Mühendisliği Doktora Programı'ndaki tüm hocalarıma teşekkür ederim. Bu çalışmanın temelini oluşturan veri ve kaynakların sağlanmasında destek olan Afet ve Acil Durum Yönetimi Başkanlığı (AFAD)'a teşekkür ederim. AFAD'ın sağladığı veri setleri ve kaynaklar, araştırmamın bilimsel altyapısını oluşturmuş ve çalışmalarımın daha sağlıklı ilerlemesine olanak tanımıştır.

Son olarak, akademik yolculuğum boyunca her zaman yanımda olan, bana sabır ve destek gösteren sevgili aileme en içten şükranlarımı sunarım. Özellikle, her zaman yanımda olan, motivasyon kaynağım ve en büyük destekçilerimden biri olan kardeşime ve özel olarak Yağmur'a teşekkür etmek isterim. Onun varlığı, bana güç ve ilham vermiş, bu süreci daha kolay aşmamı sağlamıştır.

Bu çalışmanın bilim dünyasına katkı sağlamasını temenni eder, emeği geçen herkese bir kez daha teşekkür ederim.

Mehmet Barış ŞEN

Temmuz, 2025

ÖZET

DEPREM VERİLERİNİN ZAMANSAL VE MEKANSAL ANALİZİ

Mehmet Barış Şen

Doktora Tezi

Bilgisayar Mühendisliği Anabilim Dalı

Bilgisayar Mühendisliği Doktora Programı

Danışman: Doç. Dr. Volkan Tunalı

Maltepe Üniversitesi Lisansüstü Eğitim Enstitüsü, 2025

Bu çalışma, deprem verilerinin öğrenme zamansal ve konumsal örüntülerini analiz etme ve ayrıntılı yöntemlerin deprem tahminindeki işlemlerini değerlendirmeyi sağlar. Araştırmada, son 30 yıl içerisinde Marmara ve Kahramanmaraş bölgelerinde meydana gelen depremlerden elde edilen veriler kullanılarak LSTM, GRU, Bi-LSTM, Stacked LSTM ve CNN-LSTM modelleri geliştirilmiştir. Veri ön işleme sürecinde eksik veriler temizlenmiş; zamansal ve mekansal analizler gerçekleştirilmiştir. Deprem büyüklüğünün zaman ve gelişmelere bağlı olarak sismik etkisi (görüntü, b-değeri ve enerji salınımı) hesaplanarak görselleştirilmiştir. Elde edilen bulgular, Stacked LSTM modelinin diğer modellere kıyasla daha düşük hata oranlarıyla üstün performans sergilediğini ortaya koymaktadır. Bu sonuçlar, derin öğrenme temelli yapıların deprem tahmininde etkili araçların olma potansiyelini vurgulamaktadır. Çalışma, tahmin başarısını artırmaya yönelik model artışı katkı sağlamayı hedeflemektedir.

Anahtar Sözcükler: Deprem Tahmini, Derin Öğrenme, Zamansal ve Mekansal Analiz, Sismik Parametreler

ABSTRACT

TEMPORAL AND SPATIAL ANALYSIS OF EARTHQUAKE DATA

Mehmet Barış Şen

PhD Thesis

Department of Computer Engineering

PhD Program in Computer Engineering

Thesis Advisor: Assoc. Prof. Dr., Volkan Tunalı

Maltepe University Graduate School, 2025

This study aims to analyze the spatiotemporal patterns of earthquake data and evaluate the effectiveness of deep learning methods in earthquake prediction. In the research, data obtained from earthquakes that occurred in the Marmara and Kahramanmaraş regions over the past 30 years were used to implement LSTM, GRU, Bi-LSTM, Stacked LSTM and CNN-LSTM models. During the data preprocessing phase, missing values were cleaned, and spatiotemporal analyzes were conducted. The distribution of earthquake magnitudes by time and location, along with seismic parameters (e.g., b-value and energy release), were calculated and visualized. The findings reveal that the Stacked LSTM model outperformed the others with lower error rates. These results highlight the potential of deep learning-based approaches as effective tools for earthquake prediction. The study aims to contribute to future model development efforts that seek to enhance prediction accuracy.

Keywords: Earthquake Prediction, Deep Learning, Spatiotemporal Analysis, Seismic Parameters

İÇİNDEKİLER

JÜRİ VE ENSTİTÜ ONAYI	ii
ETİK İLKE VE KURALLARA UYUM BEYANI	iii
TEŞEKKÜR.....	iv
ÖZET	v
ABSTRACT.....	vi
İÇİNDEKİLER	vii
TABLolar LİSTESİ.....	xii
ŞEKİLLER LİSTESİ	xiii
KISALTMALAR.....	xvi
1. GİRİŞ.....	1
1.1 Problem.....	1
1.2 Amaç.....	2
1.3 Önem.....	2
1.4 Varsayımlar.....	2
1.5 Sınırlıklar	3
1.6 Tanımlar.....	3
2. GENEL BİLGİLER	7
2.1 Türkiye'nin Sismotektonik Yapısı ve Depremselliği	7

2.1.1	Marmara bölgesi deprem ve sismik aktivitesi	9
2.1.2	Kahramanmaraş bölgesi deprem ve sismik aktivitesi.....	11
2.2	Derin Öğrenme ile Yapılan Tahmin Çalışmaları.....	14
2.3	Derin Öğrenme Tabanlı Model Tasarım.....	18
2.3.1	Model mimarileri	19
2.3.1.1	Basit tekrarlayan sinir ağı (Simple RNN).....	19
2.3.1.2	Uzun kısa süreli bellek (LSTM)	20
2.3.1.3	Kapılı tekrarlayan birim (GRU).....	24
2.3.1.4	Çift yönlü uzun kısa süreli bellek (BiLSTM)	26
2.3.1.5	Katmanlı LSTM (Stacked LSTM).....	28
2.3.1.6	Kıvrımlı sinir ağı – uzun kısa süreli bellek modeli (CNN-LSTM).....	30
2.3.2	Model katmanları	32
2.3.2.1	Giriş katmanı.....	32
2.3.2.2	Gizli katmanlar	33
2.3.2.3	Yoğun katman (Dense layer)	33
2.3.2.4	Dropout katmanı	33
2.3.2.5	Çıkış katmanı	34
2.4	Kullanılan Hiperparametreler	34
2.4.1	Dropout yöntemi	34
2.4.2	Adam optimizasyon algoritması	35
2.4.3	Kayıp fonksiyonu (loss).....	35

2.4.3.1	Huber kayıp fonksiyonu (Huber Loss)	35
2.4.3.2	Ağırlıklı ortalama kare hata (Weighted MSE).....	37
2.4.4	Öğrenme oranı (learning rate).....	39
2.4.5	Yığın boyutu (batch size).....	40
2.4.6	Gizli katman nöron sayısı (hidden state size)	40
2.4.7	Epoch sayısı	41
2.4.8	Aktivasyon fonksiyonları.....	41
2.4.8.1	Lineer aktivasyon fonksiyonu.....	42
2.4.8.2	Rectified linear unit (ReLU) aktivasyon fonksiyonu.....	43
2.5	Model Değerlendirme Metrikleri.....	44
2.5.1.1	Ortalama mutlak hata (mae)	45
2.5.1.2	Ortalama kare hata (mse)	45
2.5.1.3	Kök ortalama kare hata (rmse).....	46
2.5.1.4	Belirleme katsayısı (R^2)	46
3.	YÖNTEM	47
3.1	Araştırma Modeli	47
3.2	Veri Toplama	49
3.2.1	Veri kaynakları	49
3.2.1.1	Kullanılan veri setleri.....	50
3.2.1.2	Marmara Bölgesi deprem veri seti.....	50
3.2.1.3	Kahramanmaraş Bölgesi deprem veri seti	57

3.2.1.4	Fay hattı veri seti.....	63
3.3	Evren ve Örneklem	67
3.4	Veri İşlem	68
3.5	Veri Ön İşleme Süreci.....	69
3.5.1	Eksik veri yönetimi	70
3.5.2	Deprem büyüklük dönüşümleri	71
3.6	Özellikler (Feature) Mühendisliği	72
3.6.1	Sismik parametreler	73
3.6.2	Mekansal yayılım parametreleri (dispersion)	80
3.6.2.1	Merkezi eğilim (ortalama konum)	81
3.6.2.2	Mekansal yayılma ölçütleri (Standart sapma ve aralık hesaplama)....	81
3.6.2.3	Jeodezik mesafe hesaplamaları (depremler arasındaki uzaklık).....	82
3.6.2.4	Merkezi noktaya olan uzaklıklar.....	84
3.6.3	Depremlerin zaman ve mekansal farklılıkların hesaplanması	89
3.7	Veri Normalizasyonu	95
3.8	Veri Ayırma	96
3.9	Model Eğitimi	96
3.10	Kullanılan Yazılım ve Donanım Altyapısı	99
3.10.1	Sistem donanım özellikleri	99
3.10.2	Çalışma ortamı bilgileri	99
3.10.3	Kullanılan kütüphaneler.....	100

4. BULGULAR VE TARTIŞMA.....	102
4.1 Kahramanmaraş Huber Modelleri	102
4.2 Kahramanmaraş Ağırlık Modelleri	105
4.3 Marmara Huber Modelleri	108
4.4 Marmara Ağırlık Modelleri	111
4.5 Tartışma	115
5. SONUÇ VE ÖNERİLER.....	119
KAYNAKÇA.....	121
ÖZ GEÇMİŞ.....	135

TABLÖLAR LİSTESİ

Tablo 1. Marmara Bölgesi büyüklük sınıflarına göre deprem sayıları	53
Tablo 2. Marmara Bölgesi 1994-2024 yılları arasındaki 5,0 ve üzeri büyüklükteki depremler	54
Tablo 3. Kahramanmaraş Bölgesi büyüklük sınıflarına göre deprem sayıları.....	59
Tablo 4. Kahramanmaraş Bölgesi 1994-2024 yılları arasındaki 5,0 ve üzeri büyüklükteki depremler	60
Tablo 5. Marmara Bölgesi Deprem Verilerinde Kullanılan M_l ve M_d Büyüklüklerinin Moment Büyüklüğüne (M_w) Dönüştürülme Sayıları.....	72
Tablo 6. Kahramanmaraş Bölgesi Deprem Verilerinde Kullanılan M_l ve M_d Büyüklüklerinin Moment Büyüklüğüne (M_w) Dönüştürülme Sayıları.....	72
Tablo 7. Derin öğrenme algoritmaları mimarileri ve hiperparametreleri.	97
Tablo 8. Öğrenme oranı, yığın boyutu ve gizli katman boyutlarına göre yapılandırılan modellerin hiperparametre kombinasyonları tablosu.	98
Tablo 9. Farklı derin öğrenme mimarilerinin RMSE performanslarının literatürde raporlanan sonuçlarla karşılaştırmalı değerlendirilmesi.	116

ŞEKİLLER LİSTESİ

Şekil 1. KAF'a ait tarihsel deprem haritası.	10
Şekil 2. Marmara bölgesi tarihsel deprem haritası ve kırılan fay parçalarının gösterilmiştir. Kırmızı daire ile gösterilen yapılar fay parçalarının birleştiği ve en zayıf bölgelerdir.	10
Şekil 3. Kuzey Anadolu Fay sistemi GPS hızları.	11
Şekil 4. Kahramanmaraş bölgesi sismotektonik özellikleri.	13
Şekil 5. RNN akış diyagramı.	19
Şekil 6. LSTM akış mimarisi.	22
Şekil 7. Giriş hatası ile kayıp değeri arasındaki ilişkiye göre tanımlanan Huber fonksiyonunun grafiksel gösterimi.	37
Şekil 8. Deprem Büyüklüğüne göre Ağırlıklı Ortalama Kare Hata (Weighted MSE) Değişimi.	39
Şekil 9. Lineer aktivasyon fonksiyonunun giriş ve çıkış değerleri arasındaki doğrusal ilişkiyi gösteren grafik.	43
Şekil 10. ReLU aktivasyon fonksiyonu: negatif girişleri sıfırlar, pozitifleri doğrusal geçirir.	44
Şekil 11. Marmara bölgesi deprem merkez noktalarının gösterimi. Deprem Richter büyüklükleri renk ölçeği olarak tanımlanmıştır.	52
Şekil 12. 1990–2024 yılları arasında Marmara Bölgesi deprem katalog verisi grafikleri.	56
Şekil 13. Türkiye'nin doğusunda, büyüklüklere göre renklendirilmiş ve ölçeklendirilmiş deprem haritası.	58

Şekil 14. 1990–2025 yılları arasında Kahramanmaraş Bölgesi deprem katalog verisi grafikleri.....	62
Şekil 15. Türkiye geneli fay hatları haritası.	63
Şekil 16. Marmara bölgesinde $M > 4,5$ depremlerin fay hatlarına olan uzaklıklarına göre mekansal dağılımı.	65
Şekil 17. Kahramanmaraş bölgesinde $M > 4,5$ depremlerin fay hatlarına olan uzaklıklarına göre mekansal dağılımı.	66
Şekil 18. Makine öğrenmesi sürecinde uygulanan genel veri işleme adımları	68
Şekil 19. Spyder programı ekran görüntüsü	70
Şekil 20. Marmara Bölgesi temel sismik parametreler-zaman değişimleri.	77
Şekil 21. Kahramanmaraş Bölgesi temel sismik parametreler-zaman değişimleri.	79
Şekil 22. Marmara Bölgesi 1990–2024 yılları arası deprem mekansal yayılım parametrelerinin zamansal değişim grafikleri.....	86
Şekil 23. Kahramanmaraş Bölgesi 1990–2024 yılları arası deprem mekansal yayılım parametrelerinin zamansal değişim grafikleri.....	88
Şekil 24. Marmara Bölgesi 1990–2024 yılları depremler arasında büyüklük sınıflarına göre hesaplanan zaman ve konum farklarının zamansal değişimi.....	92
Şekil 25. Kahramanmaraş Bölgesi 1990–2024 yılları depremler arasında büyüklük sınıflarına göre hesaplanan zaman ve konum farklarının zamansal değişimi.	94
Şekil 26. Kahramanmaraş bölgesi Huber Loss fonksiyonu kullanılarak eğitilen modellerin RMSE değerlerinin karşılaştırılması.	102
Şekil 27. Kahramanmaraş Huber model 9 (LR=0.001, BS=32, HS=256) ait Stacked LSTM modelinin eğitim ve tahmin performansı.	103

Şekil 28. Kahramanmaraş Huber model 9 ($LR=0.001$, $BS=32$, $HS=256$) eğitilen modellerinin performanslarının karşılaştırılması.....	104
Şekil 29. Kahramanmaraş bölgesinde ağırlıklı ortalama kare hata (Weighted MSE) fonksiyonu kullanılarak eğitilen modellerin RMSE değerlerinin karşılaştırılması.	105
Şekil 30. Kahramanmaraş Ağırlıklı MSE Model 9 ($LR=0.001$, $BS=32$, $HS=256$) ait Stacked LSTM modelinin eğitim ve tahmin performansı.	106
Şekil 31. Kahramanmaraş Ağırlıklı MSE model 9 ($LR=0.001$, $BS=32$, $HS=256$) eğitilen modellerinin performanslarının karşılaştırılması.....	107
Şekil 32. Marmara bölgesine ait modellerde Huber Loss fonksiyonu kullanılarak elde edilen RMSE değerlerinin karşılaştırılması.....	108
Şekil 33. Marmara Huber 9 ($LR=0.001$, $BS=32$, $HS=256$) ait CNN-LSTM modelinin eğitim ve tahmin performansı.....	109
Şekil 34. Marmara Huber model 9 ($LR=0.001$, $BS=32$, $HS=256$) eğitilen modellerinin performanslarının karşılaştırılması.....	110
Şekil 35. Marmara bölgesine ait modellerde Ağırlıklı Ortalama Kare Hata (Weighted MSE) fonksiyonu kullanılarak elde edilen WMSE değerlerinin karşılaştırılması.	111
Şekil 36. Marmara Ağırlıklı MSE Model 9 ($LR=0.001$, $BS=32$, $HS=256$) ait Stacked LSTM modelinin eğitim ve tahmin performansı.....	112
Şekil 37. Marmara Ağırlıklı MSE model 9 ($LR=0.001$, $BS=32$, $HS=256$) eğitilen modellerinin performanslarının karşılaştırılması.....	114

KISALTMALAR

AFAD	: T.C Afet ve Acil Durum Yönetimi Başkanlığı
MTA	: Maden Tetkik ve Arama Genel Müdürlüğü
KAFZ	: Kuzey Anadolu Fay Zonu
DAFZ	: Doğu Anadolu Fay Zonu
LSTM	: Long-Short Term Memory
GRU	: Gated Recurrent Unit
Stacked LSTM	: Stacked Long-Short Term Memory
MSE	: Mean Squared Error
RMSE	: Root Mean Squared Error
MAE	: Mean Absolute Error
R²	: R Square – R Kare
CNN	: Convolutional Neural Network – Konvolüsyonel Sinir Ağı
BiLSTM	: Bidirectional Long Short-Term Memory – Çift Yönlü LSTM
RNN	: Recurrent Neural Network – Tekrarlayan Sinir Ağı

1. GİRİŞ

1.1 Problem

Depremler, tarih boyunca önemli insan ve ekonomik kayıplara neden olan en yıkıcı doğal afetlerden biri olmuştur. Yerbilim ve teknolojiadaki ilerlemelere rağmen, yer kabuğunda gerçekleşen karmaşık ve dinamik süreçler nedeniyle deprem tahmini, günümüzde hala çözümlenememiş bir bilimsel zorluk olarak karşımıza çıkmaktadır. Marmara Bölgesi gibi yoğun nüfuslu ve ekonomik olarak kritik alanlarda, sismik tehlikelerin analizi ve öngörüsü, afet risk yönetimi açısından büyük önem taşımaktadır. Son yıllarda yapay zeka, özellikle derin öğrenme alanındaki gelişmelerle, sismik verilerdeki karmaşık örüntülerin analiz edilmesi ve yorumlanması için yeni olanaklar sunarak bu zorluğun aşılmasına katkıda bulunmaktadır.

Marmara Bölgesi, yaklaşık 25 milyon kişilik nüfusuyla Türkiye nüfusunun %30'unu barındırmakta ve İstanbul başta olmak üzere Bursa, Kocaeli ve Tekirdağ gibi çevre şehirlerle ülkenin GSYİH'sine %31 oranında katkıda bulunmaktadır (OECD, 2021). Türkiye'nin sanayi üretiminin %40'ından fazlasını sağlayan bu bölge, aynı zamanda İstanbul Boğazı ile Karadeniz ve Akdeniz'i birbirine bağlayan önemli bir ticaret yoluna sahiptir. Kuzey Anadolu Fayı boyunca biriken gerilimler, bölgenin sismik risklerini artırırken, enerji altyapısı ve sanayi yoğunluğu, büyük bir depremin ulusal ve küresel ölçekte ekonomik etkiler doğurma potansiyeline işaret etmektedir (Stein, Aykut A Barka ve Dieterich 1997; Erdik, Durukal, ve Fahjan 2004). 1999 İzmit Depremi, Türkiye'nin ihracat kapasitesinde %15'lik bir düşüşe ve 16 milyar dolarlık ekonomik zarara yol açmıştır (Parsons, Toda, Stein, Barka ve Dieterich, 2000b). Bölgenin turistik cazibesi de dikkat çekicidir; İstanbul, 2023'te 15 milyon turist ağırlayarak Türkiye'nin turizm gelirlerinin %50'sini sağlamıştır (T.C. Kültür ve Turizm Bakanlığı, 2023). Tüm bu nedenlerle, Marmara Bölgesi gibi yüksek sismik risk taşıyan ve ekonomik açıdan stratejik alanlarda, büyük ölçekli afetlerin erken öngörülmesi ve bu doğrultuda önleyici stratejilerin geliştirilmesi, yalnızca yerel değil, aynı zamanda ulusal ve küresel ölçekte sürdürülebilir kalkınma ve afet yönetimi açısından kritik bir gereklilik haline gelmiştir.

1.2 Amaç

Bu çalışmanın temel amacı, derin öğrenme yöntemleri kullanarak Marmara ve Kahramanmaraş bölgelerindeki depremleri tahmin edebilmek ve zamansal-mekansal örüntüleri analiz etmektir. Geleneksel deprem tahmin yöntemlerinin doğruluk açısından kısıtlı olduğu göz önünde bulundurulduğunda, yapay sinir ağları tabanlı modellerin kullanılması, tahmin performansını artırabilecek bir yöntem olarak öne çıkmaktadır. Çalışmada, Basit RNN, LSTM, GRU, Yığılmış LSTM, CNN-LSTM ve BiLSTM gibi farklı derin öğrenme modelleri karşılaştırılarak, en uygun modelin belirlenmesi hedeflenmektedir. Elde edilen bulguların, deprem tahmini süreçlerine katkı sağlaması ve afet yönetimi açısından daha güvenilir öngörüler sunması beklenmektedir.

1.3 Önem

Depremler, büyük ölçekte insan kaybına ve ekonomik zarara neden olan afetlerdir. Marmara ve Kahramanmaraş gibi aktif fay hatları üzerinde bulunan bölgelerde, erken uyarı sistemlerinin geliştirilmesi hayati önem taşımaktadır. Bu çalışma, derin öğrenme yöntemlerinin deprem tahmini üzerindeki etkisini değerlendirerek, mevcut tahmin sistemlerine bilimsel bir katkı sunmayı amaçlamaktadır. Özellikle farklı derin öğrenme modellerinin performanslarının analiz edilmesi, gelecekte uygulanabilecek yapay zeka tabanlı tahmin sistemlerinin geliştirilmesine zemin hazırlayacaktır. Ayrıca, bu çalışmanın sonuçları, afet yönetimi ve risk azaltma stratejilerinde karar alıcılara yol gösterici bir kaynak olabilir.

1.4 Varsayımlar

Çalışmada kullanılan deprem verilerinin güvenilir ve eksiksiz olduğu kabul edilmektedir. Bu veri setlerinin, sensör hataları veya eksik ölçümler içermediği varsayılmaktadır. Ayrıca, kullanılan derin öğrenme modellerinin belirlenen hiper parametreler ve eğitim stratejileri ile optimal şekilde çalıştığı düşünülmektedir. Marmara ve Kahramanmaraş bölgelerinde geçmiş yıllarda meydana gelen depremlerin, gelecekteki sismik hareketleri öngörmek için yeterli bilgi sunduğu varsayılmaktadır. Veri ön işleme süreçlerinin model performansını olumlu yönde etkilediği ve normalizasyon, eksik veri yönetimi gibi adımların tahmin başarısını artıracakları öngörülmektedir. Kullanılan performans

metriklerinin (MSE, RMSE, MAE, R^2) model doğruluğunu değerlendirmek için yeterli olduğu kabul edilmektedir.

1.5 Sınırlıklar

Bu çalışmanın sınırlamaları bulunmaktadır. Kullanılan deprem verileri yalnızca belirli zaman aralıklarında toplanmış olup, eksik veya hatalı kayıtlar içerebilir. Verilerin doğruluğu, ölçüm cihazlarının hassasiyeti ve veri toplama yöntemlerinden etkilenebilir. Ayrıca, yalnızca Marmara ve Kahramanmaraş bölgeleri için geliştirilen modellerin, farklı coğrafi bölgeler için genelleme yapabilme kapasitesi sınırlı olabilir. Çalışmada kullanılan derin öğrenme modelleri, belirli parametreler doğrultusunda optimize edildiğinden, farklı veri setleriyle aynı başarıyı göstermeyebilir. Kullanılan performans metrikleri model başarısını ölçmek için yeterli görülse de gerçek dünya uygulamaları açısından ek doğrulamalar gerektirebilir. Jeolojik ve fiziksel süreçlerin tam anlamıyla modellenememesi, tahminlerin belirli bir hata payı taşımasına neden olmaktadır.

1.6 Tanımlar

Deprem: Yer kabuğundaki ani kırılmalarla ortaya çıkan sismik dalgalardır. Genellikle tektonik hareketlerle ilişkilidir ve büyüklüğü logaritmik ölçekle ölçülür.

Fay Hattı: Yer kabuğundaki kırık zonlarıdır ve depremlerin çoğunluğu bu yapılar boyunca gerçekleşir. Enerji birikimi ve boşalması bu bölgelerde yoğunlaşır.

Sismik Aktivite: Bir bölgedeki depremlerin frekans, büyüklük ve dağılım özelliklerini ifade eder. Sismik tehlike analizleri için temel belirleyicidir.

Deprem Büyüklüğü: Depremin açığa çıkardığı toplam enerjiyi temsil eder; genellikle moment büyüklüğüyle ifade edilir. Logaritmik ölçeklerde değerlendirilir.

Sismotektonik: Tektonik yapıların sismik aktiviteyle ilişkisini inceleyen bilimsel disiplindir. Fay dinamikleri ve deprem üretme potansiyeli bu kapsamda analiz edilir.

Sismik Enerji (Joule): Depremle açığa çıkan fiziksel enerji miktarıdır; büyüklükle doğrudan ilişkilidir. Genellikle moment magnitudünden türetilerek hesaplanır.

B-Değeri: Küçük ve büyük depremler oranını gösteren istatistiksel parametredir. Düşük b-değeri, büyük depremlerin oluşma olasılığının daha yüksek olduğunu gösterir.

Haversine Formülü: İki koordinat noktası arasındaki jeodezik mesafeyi hesaplamak için kullanılır. Depremler arası mekansal ilişkilerin belirlenmesinde kullanılır.

Elapsed Days: İki ardışık depremin oluş tarihleri arasındaki süredir. Zaman tabanlı örüntü analizlerinde kullanılır.

Zaman-Mekan Örüntüsü: Depremlerin hem zamansal hem de mekansal olarak tekrar eden dağılımlarını ifade eder. Derin öğrenme modelleri bu örüntüleri öğrenerek geleceğe yönelik tahmin yapabilir.

Zaman Serisi Verisi: Olayların zaman sırasına göre düzenlendiği veri tipidir. Deprem tahmin modelleri bu tür verilerle eğitilir.

Sliding Window: Zaman serilerini sabit uzunluktaki kesitlere ayırarak modele giriş sağlayan tekniktir. Geçmiş veri ile geleceğe yönelik tahmin yapılmasına olanak tanır.

Zaman Penceresi (Time Window): Modele giriş olarak verilen geçmiş veri aralığıdır. Modelin ardışık örüntüleri öğrenmesini sağlar.

Derin Öğrenme: Çok katmanlı yapay sinir ağları ile karmaşık örüntüleri öğrenmeye olanak tanıyan makine öğrenmesi alt dalıdır. Deprem tahmini gibi büyük veri problemlerinde yaygın olarak kullanılır.

RNN (Recurrent Neural Network): Geri besleme yapısıyla zaman bağıntılarını modelleyen tekrarlayan sinir ağıdır. Önceki zaman adımlarındaki bilgiyi belleğinde tutarak tahmin üretir.

LSTM (Long Short-Term Memory): Uzun süreli bağımlılıkları öğrenebilen kapı mekanizmaları içeren bir RNN çeşididir. Zaman serisi verilerindeki örüntüleri daha kararlı biçimde öğrenir.

GRU (Gated Recurrent Unit): LSTM'e benzer çalışır ancak daha az parametreye sahip

olduğu için daha hızlı ve verimlidir. Özellikle kısa vadeli bağımlılıkları modellemede avantajlıdır.

Stacked LSTM: Birden çok LSTM katmanının üst üste yerleştirildiği derin model yapısıdır. Daha karmaşık ve hiyerarşik örüntülerin öğrenilmesini sağlar.

CNN-LSTM: Konvolüsyonel ağ ile LSTM mimarisinin birleşimidir. CNN mekansal, LSTM ise zamansal örüntüleri öğrenir.

BiLSTM (Bidirectional LSTM): Zaman serisini hem ileri hem geri yönde analiz edebilen çift yönlü LSTM modelidir. Bağlam bilgisini artırarak daha doğru tahminler yapılmasını sağlar.

Özellik Mühendisliği: Model performansını artırmak için anlamlı girdilerin seçilmesi ve dönüştürülmesi sürecidir. Deprem tahmininde büyüklük, derinlik ve konum gibi parametreler önceliklidir.

Veri Normalizasyonu: Verilerin farklı ölçeklerini ortak bir aralığa indirgemek için yapılan dönüşüm işlemidir. Modelin daha hızlı ve stabil öğrenmesini sağlar.

Epoch: Modelin tüm eğitim verisi üzerinde tamamladığı bir tam eğitim döngüsüdür. Genellikle birden fazla epoch süresince öğrenme gerçekleşir.

Batch Size: Her ağırlık güncellemesinden önce modele verilen veri örneği sayısıdır. Eğitim sürecinin verimliliğini ve hızı üzerinde doğrudan etkilidir.

Öğrenme Oranı (Learning Rate): Ağırlık güncellemelerinin adım büyüklüğünü belirleyen hiperparametredir. Düşük değerler yavaş, yüksek değerler kararsız öğrenmeye yol açabilir.

Dropout: Aşırı öğrenmeyi önlemek için bazı nöronların eğitim sırasında rastgele devre dışı bırakılması yöntemidir. Modelin genelleme yeteneğini artırır.

Aktivasyon Fonksiyonu: Nöron çıktılarının hesaplanmasını sağlayan matematiksel işlemdir. ReLU, Sigmoid ve Tanh gibi türleri derin ağlarda yaygındır.

Hiperparametre: Model eğitimi öncesinde dışarıdan belirlenen ve öğrenme sürecini yöneten parametrelerdir. Örneğin epoch sayısı, öğrenme oranı ve batch size gibi.

Loss Fonksiyonu: Modelin tahmini ile gerçek değer arasındaki farkı ölçen matematiksel fonksiyondur. Eğitim sürecinde bu farkı minimize etmek amaçlanır.

MSE (Mean Squared Error): Tahmin ve gerçek değer farklarının karelerinin ortalamasıdır. Büyük hatalara daha yüksek ağırlık verir ve regresyon problemlerinde sıkça kullanılır.



2. GENEL BİLGİLER

Bu bölüm, derin öğrenmeye dayalı deprem tahmin modellerinin geliştirilmesine temel teşkil eden sismotektonik yapı, literatürdeki benzer yaklaşımlar ve modelleme sürecine ilişkin teknik detayların bütüncül bir çerçevede sunulmasını amaçlamaktadır. İlk olarak, Türkiye'nin aktif tektonik rejimi ile bu rejimin etkisinde kalan Marmara ve Kahramanmaraş bölgelerine odaklanılarak, bu alanların yüksek sismik potansiyelleri ve geçmiş deprem aktivitesi bağlamında neden modelleme için seçildiği açıklanmaktadır. Ardından, deprem tahmini konusunda derin öğrenme algoritmalarıyla gerçekleştirilen önceki çalışmalar incelenmiş; bu çalışmaların veri ön işleme süreçleri, model yapılandırılmaları ve parametre ayarları karşılaştırmalı olarak ele alınmıştır. Devamında, çalışmada kullanılan derin öğrenme modellerinin mimari özellikleri, katman düzenlemeleri ve hiperparametreleri ayrıntılı biçimde tanımlanmıştır. Bu kapsamda dropout, öğrenme oranı, yığın boyutu ve gizli katman nöron sayısı gibi temel yapılandırma bileşenlerinin modele etkisi teorik ve uygulamalı bağlamda değerlendirilmiştir. Son olarak, modellerin tahmin başarımının nesnel biçimde ölçülebilmesi amacıyla kullanılan hata metrikleri (MAE, MSE, RMSE) tanımlanarak, bu metriklerin model doğrulama sürecindeki işlevi açıklanmıştır. Bu bölüm, tez kapsamında yürütülen modelleme sürecinin hem bilimsel altyapısını hem de uygulama düzeyindeki teknik gerekçelerini ortaya koymaktadır.

2.1 Türkiye'nin Sismotektonik Yapısı ve Depremselliği

Türkiye, Alp-Himalaya orojenik kuşağının etkin bir parçası olarak dünya üzerindeki en aktif deprem kuşaklarından biri üzerinde yer almaktadır. Bu bölge, Afrika, Avrasya ve Arap levhalarının çarpışma zonunda yer alan Anadolu levhasının farklı yönlerle zorlanması sonucu meydana gelen karmaşık bir deformasyon rejimine sahiptir (McKenzie 1972; Dewey ve Şengör 1979). Bu tektonik çerçevede, Anadolu levhası batıya doğru hareket etmekte ve bu hareket, özellikle sağ yanal doğrultu atımlı Kuzey Anadolu Fay Zonu (KAFZ) ve sol yanal doğrultulu Doğu Anadolu Fay Zonu (DAFZ) ile yansımaktadır (Şengör vd. 2005; Aykut Barka ve Kadinsky-Cade 1988). Aynı zamanda Ege Bölgesi'nde ve Batı Anadolu'da yer alan graben sistemleri, Afrika levhasının

dalmasıyla ortaya çıkan kabuk incelmeleri ve genişlemeli tektonik rejimin bir sonucu olarak şekillenmektedir (Bozkurt, 2001).

Türkiye'nin bu karmaşık yapısı, tarihsel ve aletsel dönem depremleri açısından oldukça zengin bir geçmişe sahiptir. Özellikle KAFZ üzerinde meydana gelen 1939 Erzincan, 1943 Tosya, 1967 Mudurnu ve 1999 Gölcük depremleri, bu zonun periyodik olarak büyük ölçekli depremler ürettiğini ortaya koymuştur (Stein, A A Barka ve Dieterich, 1997; Parsons, Toda, Stein, A. A. Barka ve diğerleri, 2000). DAFZ üzerinde ise 2020 Elazığ ve 2023 Kahramanmaraş depremleri gibi büyük sismik olaylar, bu fay zonunun da oldukça aktif olduğunu kanıtlamaktadır (Kayabali, K., ve Akin, M. ,2003.; Yan, K., vd. ,2024). Sadece bu iki fay zonu değil, aynı zamanda Batı Anadolu'daki Gediz, Büyük Menderes ve Bakırçay grabenleri boyunca uzanan normal faylar da yıkıcı depremlere neden olabilmektedir (Bozkurt, 2001).


Depremsellik açısından bakıldığında, Türkiye'nin büyük bir bölümü aktif fay hatlarıyla kesilmiş durumdadır. Maden Tetkik ve Arama Genel Müdürlüğü (MTA) tarafından hazırlanan aktif fay haritasına göre Türkiye genelinde 15.000'i aşkın segment fay hattı bulunmaktadır (Şaroğlu, Emre ve Kuşçu 1992). Bu fayların büyük bir kısmı 6 ve üzeri büyüklükte deprem üretme potansiyeline sahiptir. Türkiye'de meydana gelen depremlerin büyük bölümü sığ odaklı olup (10–20 km derinlikte), yüzeyde geniş yıkım alanlarına neden olmaktadır (Gutenberg ve Richter 1954; Kalafat, Horasan, Gök ve diğerleri, 2011). Ayrıca, yapılan sismik boşluk analizleri, özellikle Marmara Denizi içi ve çevresi ile Doğu Anadolu'nun güney bölgelerinin gelecekte büyük depremlere aday olduğunu göstermektedir (Le Pichon vd., 2001; Robert Reilinger ve diğerleri, 2006).

Tüm bu veriler, Türkiye'nin sadece tektonik açıdan değil, sismik tehlike ve risk bakımından da kritik bir coğrafyada yer aldığını ortaya koymaktadır. Gerek şehirleşme gerekse altyapı planlamalarında bu sismik gerçekliğin göz önünde bulundurulması, depreme dayanıklı yapılaşma politikalarının bilimsel zemin üzerinde şekillendirilmesi büyük önem taşımaktadır. İlerleyen bölümlerde, bu genel çerçeve içinde Marmara Bölgesi ve Kahramanmaraş civarındaki aktif tektonik sistemler detaylı olarak ele alınacaktır.

2.1.1 Marmara bölgesi deprem ve sismik aktivitesi


Dünyanın en aktif deprem bölgelerinden birinde yer alan Türkiye, depremlere karşı oldukça savunmasızdır. Özellikle Marmara Bölgesi, çok sayıda yıkıcı depreme neden olan önemli bir sağ yanal doğrultu atımlı fay sistemi olan Kuzey Anadolu Fayı (KAF) boyunca uzanmaktadır. Bu bölgedeki depremlerin zamansal ve mekansal örüntülerinin anlaşılması, afet hazırlığı ve zarar azaltma açısından kritik öneme sahiptir. 1999 İzmit Depremi, can kayıplarına yol açmasının yanı sıra, büyük çaplı depremlerin ulusal düzeyde ekonomik kırılganlıkları nasıl derinleştirebileceğini de açıkça ortaya koymuş, Türkiye ekonomisinin başlıca üretim ve finans merkezlerinden biri olan İstanbul'u etkilemiştir. Örneğin, 1999 İzmit Depremi sadece büyük bir can kaybına yol açmakla kalmamış, aynı zamanda İstanbul'un Türkiye'nin GSYİH'sine ve sanayi üretimine önemli katkı sağlaması nedeniyle büyük ölçekli sismik olayların ekonomik kırılganlıklarını da gözler önüne sermiştir.

Tarihsel veriler bu bölge üzerinde çok sayıda yıkıcı deprem olduğunu göstermektedir. Bölgedeki yıkıcı depremlerin bulunduğu ana fay Kuzey Anadolu Fay (KAF) hattıdır (Ketin, 1976). KAF birçok parçadan oluşmaktadır. Bu parçalar her biri farklı bir fay olarak davranmakta ve kırıldıktan sonra stresi diğerine aktarmaktadır. Önceki çalışmalarda depremin katalog verileri üzerinde olasılık hesapları ile her bir parçanın kendine ait ortalama periyodu olduğu bildirilmiştir. Bu periyod değişiklik gösterse de ~250 yıl olarak belirtilmiştir. Parçalar arasındaki dinamik süreçler KAF'ın karmaşık yapısından dolayı hala açıklık kazanmamıştır. Fay üzerindeki stresin doğudan batıya doğru aktarıldığı bilinmekle birlikte depremler zamansal olarak bu forma uymamaktadır. Genel yapıya bakıldığında bir düzene ve zamansal kurallara uyarken, bu kurallara uymaksızın büyük depremler de üretebilmektedir. Şekil 1'de gösterilen tarihsel deprem haritası bu karmaşık yapıyı destekler niteliktedir (Pondard, Armijo, King, Meyer ve Flerit, 2007).




Şekil 1. KAF'a ait tarihsel deprem haritası.

Özel olarak muhtemel deprem üretmesi beklenen İstanbul ve Marmara parçasında da aynı karmaşık deprem zamanı problemi yaşanmaktadır. Şekil 2'de Marmara bölgesindeki meydana gelen tarihte büyük etkileri olmuş depremleri göstermektedir (Pondard ve diğerleri, 2007).



Şekil 2. Marmara bölgesi tarihsel deprem haritası ve kırılan fay parçalarının gösterilmiştir. Kırmızı daire ile gösterilen yapılar fay parçalarının birleştiği ve en zayıf bölgelerdir.

Bu fay sistemi yaklaşık olarak 13 milyon yaşındadır (Aykut Barka ve Kadinsky-Cade 1988). Bu sistem Erzincan ilimizden başlayıp Marmara denizine ve sonrasında ise Yunanistan'a kadar uzanmaktadır. Şekil 3'de gösterildiği üzere KAF, yaklaşık uzunluğu 1500 km ve ortalama olarak yılda 2 cm yakın GPS hızı ile hareket etmekte olan dünyanın en önemli sağ yanal faylarından biridir (Tatar ve diğerleri, 2012).



Şekil 3. Kuzey Anadolu Fay sistemi GPS hızları.

Bilgisayar bilimlerindeki son gelişmelerin ışında büyük veri setlerinin ve farklı kaynaklardan gelen verilerin anlamlı bir sonuca dönüştürülmesi mümkün olmuştur. Yapay sinir ağları çeşitli algoritmalar ile bu karmaşık yapının çözülmesinde ve insan gözünün göremediği önemli bağlantıları ortaya çıkarmada önemli rol oynayacaktır.

Marmara Bölgesi, Kuzey Anadolu Fayı'nın Marmara Denizi segmenti boyunca büyük depremlerin gözlendiği aktif bir fay hattına sahiptir ve bu depremler genellikle yüksek kayma hızı (~20-25 mm/yıl) ve sığ odak derinliği (~10-20 km) ile karakterize edilir (Ebel, 1998). Tarihsel ve paleosismolojik kayıtlar, bölgedeki depremlerin yaklaşık 250-300 yıllık bir tekrarlama periyoduna sahip olduğunu göstermektedir. 1509 yılında gerçekleşen ve "Küçük Kıyamet" olarak adlandırılan Mw 7,2-7,6 büyüklüğündeki deprem, İstanbul'da büyük yıkıma neden olmuş ve tsunami yaratmıştır (Ebel, 1998). 1766 yılında ardışık iki büyük deprem (Mw 7,4 ve Mw 7,2) çoklu segment kırılmasıyla gerçekleşmiş ve bölgeyi derinden etkilemiştir. 1894 İstanbul Depremi (Mw 7,0), Marmara Fayı'nın batı segmentinde kırılmaya yol açmış ve tsunami etkileri gözlemlenmiştir (Ebel, 1998). 1999 İzmit Depremi (Mw 7,4), Marmara Denizi'nin doğusundan başlayarak ciddi yıkıma neden olmuş ve fay boyunca stresin batıya transfer edilmesiyle bölgedeki "sismik boşluk" nedeniyle yeni bir büyük deprem beklentisini artırmıştır (Stein ve diğerleri, 1997a). Bu depremlerin özellikleri, Marmara Fayı boyunca enerji birikiminin kritik seviyelere ulaşmasıyla ilişkili olup gelecekteki olası büyük depremler için önemli ipuçları sunmaktadır (Le Pichon, Şengör ve Demirbağ 2001).


2.1.2 Kahramanmaraş bölgesi deprem ve sismik aktivitesi

Kahramanmaraş bölgesi, Türkiye'nin en karmaşık ve aktif tektonik alanlarından birinde

yer almakta olup hem bölgesel levha etkileşimlerinin merkezi hem de tarihsel olarak birçok yıkıcı depreme sahne olmuş bir coğrafyadır. Bölge, Afrika, Arap ve Anadolu levhalarının etkileşim zonunda, özellikle Arap Levhasının kuzeye doğru olan hareketiyle şekillenmektedir (Reilinger ve diğerleri, 2006; McKenzie 1972). Bu hareket, Anadolu levhasının batıya kaçışına neden olurken, Doğu Anadolu Fay Zonu (DAFZ) boyunca büyük deformasyonlara ve sismik aktiviteye yol açmaktadır (Bozkurt 2001).

DAFZ, Karlıova'dan Hatay'a kadar uzanan yaklaşık 600 km uzunluğundaki aktif bir sol yanal doğrultu atımlı fay zonudur. Bu zon, farklı segmentlere ayrılarak çeşitli bölgelerde farklı sismik karakteristikler sergilemektedir. Kahramanmaraş civarında DAFZ; Pazarcık, Türkoğlu, Göksun ve Çardak segmentleriyle temsil edilir ve bu segmentlerin her biri tarihsel ve aletsel dönemde büyük depremler üretmiştir (Duman ve Emre 2013; Bulut vd. 2012).

6 Şubat 2023 tarihinde art arda meydana gelen Mw 7,8 ve 7,5 büyüklüğündeki iki deprem, Pazarcık ve Erkenek segmentlerinde çoklu segment kırılmalarıyla gerçekleşmiş ve toplamda 400 km'ye yakın yüzey kırığı oluşturmuştur (Kobayashi ve Fujiwara 2023; Ding, H., vd. ,2023). Şekil 4'te görüldüğü gibi bu durum, DAFZ'nin kompleks bir fay sistemine sahip olduğunu ve segmentler arası etkileşimlerin domino etkisiyle çoklu kırılmalara yol açabileceğini göstermektedir (Eraslan, S., Hatipoğlu, İ. K., Ocak, F., Işık, F., ve Zeybek, H. İ., 2023). Ayrıca, bu olaylar neticesinde meydana gelen yüzey deformasyonları Sentinel-1 InSAR verileri ile ayrıntılı biçimde belgelenmiş, yer yer 7 metreye varan yanal atımlar ölçülmüştür.



Şekil 4. Kahramanmaraş bölgesi sismotektonik özellikleri.

Kahramanmaraş bölgesi, yalnızca aktif fay hatları nedeniyle değil, aynı zamanda tarihsel sismik aktivitesi bakımından da kritik bir öneme sahiptir. Şekil 4'te görüldüğü gibi bölgede belgelenen 1114, 1513, 1795 ve 1893 depremleri, özellikle Pazarcık ve Türkoğlu segmentlerinin periyodik olarak kırıldığını göstermektedir. Yapılan paleosismolojik kazılar, Pazarcık segmentinde son 2000 yıl içinde birçok yüzey kırıklı depremin meydana geldiğini ortaya koymuştur (Emre ve diğerleri, 2016).

Jeodezik veriler de bölgedeki deformasyon hızlarını açıkça ortaya koymaktadır. Türkiye Ulusal GPS Ağı (TUTGA) ve bölgesel GPS ölçümleri, Arap Levhasının Anadolu Levhasına göre yılda yaklaşık 8–10 mm hızla hareket ettiğini ve bu hareketin DAFZ üzerinde birikmiş gerinimle sismik enerjiye dönüştüğünü göstermektedir (Aktuğ vd. 2009; (Reilinger ve diğerleri, 2006) . Bu veriler, bölgedeki gerinimin hem segmentler

özelinde hem de bölgesel ölçekte modellenebilmesini sağlamış ve 2023 depremleri öncesi biriken enerjiye dair tahminleri doğrulamıştır (Akgün, E., ve İnceöz, M. 2021).

Bölgedeki faylar yalnızca doğrultu atımlı değildir; aynı zamanda normal ve ters bileşenli karma faylanma da gözlenmektedir. Kahramanmaraş batısında bulunan Çardak ve Sürgü fayları hem doğrultu atımlı hem de dikey bileşenli faylanmalar göstermekte olup, bu durum bölgenin karmaşık tektonik yapısını daha da pekiştirmektedir (Akgün, E., ve İnceöz, M., 2021). Ayrıca, fayların sismik segmentasyon özelliklerinin belirlenmesi adına yapılan mikro-deprem katalogları ve lokal ağlar aracılığıyla analiz edilen b değerleri, segmentlerin sismik boşluk (seismic gap) niteliği taşıdığını ortaya koymuştur (Bulut vd. 2012).

Kahramanmaraş'ın aktif tektonik yapısı yalnızca fay karakteristikleriyle sınırlı olmayıp, paleosismoloji, jeodezi, mikrosismisite ve InSAR analizleri gibi çok disiplinli yöntemlerle bütüncül olarak incelenmelidir. Bu çerçevede hem deprem tekrarlama periyotlarının belirlenmesi hem de sismik tehlike modellemeleri için segment bazlı senaryolar oluşturulmalı, bu senaryolarda çok segmentli kırılma ihtimali de göz önünde bulundurulmalıdır (Eraslan, S., Hatipoğlu, İ. K., Ocak, F., Işık, F., ve Zeybek, H. İ., 2023).

2.2 Derin Öğrenme ile Yapılan Tahmin Çalışmaları

Literatürde farklı veri türlerini zamansal ve mekansal olarak inceleyen birçok çalışma mevcuttur. Bu çalışmalar genellikle yapay zeka, makine öğrenmesi ve derin öğrenme tabanlı olup, bilgisayar bilimindeki gelişmelerle şekil almıştır. Bu yöntemler kullanılarak deprem verilerinin analiz edildiği çalışmalar da mevcuttur. Zhu, Chen, Zhu, Duan ve Liu (2018), rüzgar verileri kullanılarak spatio-temporal korelasyon ve PDCNN (predictive deep convolutional neural network) yöntemleriyle hız tahmini problemine açıklık getirmeye çalışmışlardır. Mahmud, Kaiser, McGinnity ve Hussain (2021), biyolojik verilerde yapılan veri madenciliği metotlarını derin öğrenme ile incelemiş ve uygulamalar geliştirmiştir. Li, X., ve Lee, Y. S. (2024), pazarlama stratejilerini kümeleme yaklaşımıyla modellemeye çalışmış, Yahaya, Lotfi ve Mahmud (2021) ise günlük hayattaki anomalileri yapay zeka ve derin öğrenme kullanarak tespit etmeyi hedeflemiştir.

Deprem tahmini alanında dünya genelinde yapılan çalışmalar, yapay zeka ve makine

öğrenmesi tabanlı yöntemlerin, sismik verilerin işlenmesi ve anlamlandırılmasında önemli bir potansiyele sahip olduğunu göstermektedir. Özellikle yapay sinir ağları, evrimsel algoritmalar ve derin öğrenme mimarileri, zaman serisi tahminleri için yaygın biçimde tercih edilmiştir. Mignan ve Broccardo (2020), yapay sinir ağlarının genel performansını değerlendirerek, klasik istatistiksel yöntemlere kıyasla nöral ağ tabanlı modellerin esnekliğini ve adaptasyon yeteneklerini vurgulamıştır. Zhang, Q., ve Wang, C. (2008), yapay sinir ağlarını genetik algoritmalarla optimize ederek deprem büyüklüğü tahminine yönelik hibrit modeller önermiştir. Benzer şekilde, Lin, J. W., Chao, C. T., ve Chiou, J. S. (2018), geri yayılım algoritmasına dayanan BPNN yaklaşımını kullanarak zaman serisi özelliklerini modellemiş; C. Li ve Liu (2016) ise Parçacık Sürü Optimizasyonu (PSO) ile BPNN yapısını birleştirerek daha iyi sonuçlar elde edildiğini bildirmiştir. Çam, H., ve Duman, O. (2016), Türkiye verilerini kullanarak yapay sinir ağlarının sismik tahminde uygulanabilirliğini test etmiştir.

Derin öğrenme teknikleriyle yapılan çalışmalarda ise özellikle LSTM (Uzun Kısa Süreli Bellek) yapısının zamansal bağımlılıkları öğrenme kapasitesi nedeniyle ön plana çıktığı görülmektedir. Örneğin, Berhich, Belouadha ve Kabbaj (2020), LSTM modelini doğrudan deprem büyüklüğü tahmini için uygulayarak zaman serilerindeki örüntüleri başarıyla öğrenebildiğini göstermiştir. Panakkat ve Adeli, (2007a), sekiz farklı sismik belirteci tanımlayarak bu göstergelerin RBFNN, BPNN ve RNN modelleri üzerindeki etkilerini karşılaştırmış, özellikle RNN modellerinin daha tutarlı sonuçlar ürettiğini ifade etmiştir.

Bölgesel çalışmalara bakıldığında, Zhang, Q., ve Wang, C. (2008) Asya kıtası için LSTM modelini kullanarak bölgesel farklılıkların modele etkisini analiz etmiş, R Kumar ve Singh (2020), Hindistan'da GRU (Gated Recurrent Unit) modeli ile yapılan tahminlerin zamanlama açısından başarılı olduğunu ortaya koymuştur. Siامي-Namini, S., Tavakoli, N., ve Namin, A. S. (2019) Pakistan verilerini kullanarak BiLSTM (Çift Yönlü LSTM) modellerinin ileri ve geri akış verilerindeki korelasyonu yakalamada daha etkili olduğunu belirtmiştir. Benzer şekilde, J. Lee ve Cho (2021), Güney Kore için GRU tabanlı bir sistem önererek deprem tahmini doğruluğunu iyileştirmeyi amaçlamıştır.

Türkiye özelinde yapılan araştırmalar, son yıllarda derin öğrenme tabanlı tahmin

modellerine yoğunlaşmıştır. Çelik, Çelik ve Çelik (2016), farklı makine öğrenmesi sınıflayıcıları (örneğin karar ağaçları, destek vektör makineleri) kullanarak deprem büyüklüğü tahmini üzerine çalışmalar yürütmüştür. Q. Wang, Guo, Yu ve Li (2020) ile Cai, Shyu, Tu, Teng ve Hu (2019), Türkiye verileri üzerinde LSTM temelli zaman serisi modellemeleri önererek, klasik RNN yapılarına göre daha kararlı sonuçlar elde ettiklerini belirtmişlerdir. Ringer, H. J. (2020), tarihsel hasar kayıtlarını kullanarak Bayes sınıflayıcısı ve LSTM modellerini karşılaştırmalı şekilde test etmiş ve LSTM'nin özellikle veri örüntülerini öğrenmede daha başarılı olduğunu göstermiştir. Kail, Burnaev ve Zaytsev (2022), LSTM ile CNN mimarisini entegre ederek farklı uzamsal özelliklerin model performansına etkisini incelemiş; karmaşık olay dizilerini daha verimli şekilde tahmin etmeyi amaçlamışlardır. Ayrıca Bhandarkar ve diğerleri (2019), LSTM ile FFNN (Feed Forward Neural Network) yapılarını karşılaştırarak, özellikle çok değişkenli sismik girdilerde LSTM'in daha istikrarlı sonuçlar sunduğunu raporlamıştır.

Marmara bölgesi özelinde yapılan çalışmalar, bu bölgenin karmaşık fay ağı, çoklu fay segmentleri ve yüksek sismotektonik riski nedeniyle literatürde ayrı bir öneme sahiptir. Özellikle Kuzey Anadolu Fayı'nın batı segmentinin deniz altından geçmesi, bu bölgedeki tahmin modellerini daha zorlu ancak bilimsel açıdan kritik hale getirmiştir. Kas, O. (2023), Marmara Denizi çevresindeki aktif fay zonlarına odaklanarak LSTM tabanlı zaman serisi modelleri ile deprem büyüklüğü tahmini gerçekleştirmiş, model performansını farklı pencere uzunlukları ile test etmiştir. Tekin, A. ve Sari, C. (2024) CNN-LSTM yapısını kullanarak yer hareketi ivmesi ve yer değiştirme gibi parametrelerin örüntüsünü öğrenmiş; bu mimarinin özellikle kısa vadeli tahminlerde ve ani değişimlerde daha başarılı sonuçlar verdiğini belirtmiştir. Öncel Çekim ve diğerleri (2023), Marmara'daki mikro-deprem kümelenmelerini analiz ederek Stacked LSTM mimarisıyla ardışık zaman dilimlerinde oluşan örüntüleri daha hassas biçimde modellemiş, farklı dropout oranlarının sonuçlara etkisini değerlendirmiştir. Bölgedeki yüksek nüfus yoğunluğu ve sanayi merkezlerinin varlığı nedeniyle, hata toleranslarının minimize edilmesi gerektiği sıklıkla vurgulanmıştır Habek ve Örnek (2024). Ayrıca, Marmara bölgesi için GRU tabanlı modeller önererek, bu mimarinin hem eğitim süresi hem de hesaplama maliyeti açısından avantaj sunduğunu ifade etmiştir. Yine benzer şekilde, Kavianpour, P., Kavianpour, M., Jahani, E., ve Ramezani, A. (2021), çok değişkenli zaman serilerini kullanarak BiLSTM modelleriyle hem büyüklük hem de zaman tahmini

üzerine çalışmış, bölgesel kümelenmelere göre veri segmentasyonu uygulamıştır. Son olarak Uyar, R., ve Özdemir, D. (2025), farklı kayıp fonksiyonları (MSE, MAE, Huber Loss) kullanarak model başarımını karşılaştırmalı şekilde analiz etmiş; özellikle Huber Loss'un uç değerler karşısında daha stabil sonuçlar verdiğini ortaya koymuştur. Bu doğrultuda, Marmara bölgesinde gerçekleştirilen tahmin modelleri, yalnızca algoritma performansına değil; aynı zamanda sismotektonik yapıların, veri çeşitliliğinin ve mekansal çözünürlüğün modele etkisine de odaklanan bütüncül bir yaklaşım sunmaktadır. Giderek daha karmaşık mimariler ve daha geniş veri kümeleriyle çalışan bu modeller, Marmara'da meydana gelebilecek büyük depremlere karşı erken uyarı ve risk azaltma stratejileri için bilimsel temel oluşturmaktadır.

Kahramanmaraş bölgesi, 6 Şubat 2023'te meydana gelen ardışık iki büyük depremin ardından sismolojik araştırmaların ve modelleme çalışmalarının merkezinde yer almaya başlamıştır. Bu depremler sonrası, hem bölgedeki sismotektonik yapının yeniden modellenmesi hem de artçı dizilerin mekansal ve zamansal davranışlarının analiz edilmesine yönelik çok sayıda akademik ve kurumsal araştırma gerçekleştirilmiştir. Özellikle fay hatlarının karmaşık geometrisi, kırılma mekanizmalarının farklılığı ve yıkıcılığın geniş bir alana yayılmış olması, bu bölgeyi hem derin öğrenme modelleri hem de afet senaryoları açısından kritik bir inceleme sahasına dönüştürmüştür. Karcı, M., ve Şahin, İ. (2022) bölgedeki tarihsel depremleri baz alarak LSTM mimarisiyle bir zaman serisi tahmin modeli geliştirmiş, orta büyüklükteki depremler ile büyük magnitudlü depremler arasındaki örüntüleri analiz etmişlerdir. Modelleme sürecinde zamansal pencere uzunlukları ve veri kayma oranları değiştirilerek LSTM'in tahmin kararlılığı test edilmiştir. CNN-LSTM mimarisi ile derin odaklı depremlerin mekansal dağılımını sınıflandırmış; modelin hem büyüklük hem de zaman tahmin performansını afet öncesi ve sonrası dönemde karşılaştırmalı olarak ele almıştır. Bu çalışma, özellikle yer altı kaynaklı sismik enerji dağılımı ile yüzey etkileri arasındaki ilişkilerin modellenmesine katkı sunmuştur.

Bölgeye yönelik yürütülen birçok çalışmanın ana odak noktası, Kahramanmaraş merkezli artçı dizilerin davranışsal analizidir. Tekin, A. ve Sari, C. (2024), artçı depremlerin zaman içindeki enerji birikim ve boşalım desenlerini inceleyerek, GRU tabanlı modeller ile enerjilerine göre kümelenmelerini öğrenen bir sistem önermiştir. Bu çalışmada

özellikle GRU'nun LSTM'ye göre daha hızlı öğrenme kapasitesi ve parametre sayısının düşük olması nedeniyle tercih edildiği belirtilmiştir. Öte yandan, Harish, M., Kumar, H., Banupriya, S., Gowtham, R., ve Rahul, M. V. (2025), Kahramanmaraş verileri üzerinden BiLSTM mimarisiyle yapılan bir çalışmada, çift yönlü örüntü tanımanın artçıların sıralı ilişkilerini anlamada avantaj sunduğunu göstermiştir. Özellikle sığ odaklı ve yıkıcı potansiyeli yüksek depremler için, konum bilgileri, enerji parametreleri, magnitüt aralığı ve zaman farkları gibi çok sayıda değişkenin modele dahil edilmesi önerilmiştir (Solak vd., 2025). Bununla birlikte, modellerde bölgedeki sismik yoğunluk, derinlik zonları ve artçı dağılımlarına göre bölgelere ayrılarak alt modelleme stratejileri uygulanmıştır.

Son dönem çalışmalar, bu bölgedeki modellere yalnızca doğruluk ve hata oranları üzerinden yaklaşmamakta, aynı zamanda model çıktılarının açıklanabilirliğini de hedeflemektedir. Örneğin, Şahin, ve Yayla, (2024), Kahramanmaraş için geliştirilen LSTM ve GRU modellerine SHAP (SHapley Additive exPlanations) analizi entegre ederek, model karar mekanizmalarının hangi değişkenlerden ne ölçüde etkilendiğini görselleştirmiştir. Bu sayede, modelin yalnızca tahmin yapması değil; aynı zamanda hangi fiziksel parametrelerin bu tahminlerde belirleyici olduğu da belirlenmiştir. Tüm bu çalışmalar, Kahramanmaraş bölgesinde derin öğrenme modellerinin sadece akademik başarıya odaklı değil; aynı zamanda gerçek zamanlı tahmin sistemleri, erken uyarı altyapıları ve afet yönetimi stratejilerine entegre edilebilir nitelikte tasarlandığını ortaya koymaktadır. Giderek gelişen sensör teknolojileri, artan veri hacmi ve yüksek çözünürlüklü coğrafi bilgi sistemleri sayesinde, bu modellerin sahaya uygulanabilirliği gün geçtikçe artmakta, bölgesel risk azaltma politikalarına bilimsel zemin oluşturmaktadır.

2.3 Derin Öğrenme Tabanlı Model Tasarım

Deprem tahmini amacıyla kullanılan derin öğrenme modellerinin yapısal özellikleri ele alınmaktadır. Kullanılan model mimarileri, katman dizilimleri ve aktivasyon fonksiyonları gibi temel bileşenler ayrıntılı olarak tanıtılmıştır. Farklı model yapılarına ait mimari kararlar, zaman serisi verilerinin doğasına uygunluk ve tahmin başarımı göz önünde bulundurularak belirlenmiştir. Ayrıca, çıkış katmanında tercih edilen aktivasyon fonksiyonu gibi unsurların modelin çıktısını nasıl şekillendirdiği de bu kapsamda


değerlendirilmiştir.

2.3.1 Model mimarileri

Derin öğrenme modelleri, karmaşık ve yüksek boyutlu verilerden örüntü çıkarmada güçlü temsil yetenekleri sayesinde son yıllarda özellikle zaman serisi ve uzamsal veri analizinde yaygın olarak kullanılmaktadır. Deprem tahmini gibi doğrusal olmayan ve dinamik yapıya sahip problemlerde, geleneksel yöntemlerin sınırlılıklarını aşmak amacıyla yapay sinir ağı tabanlı mimariler tercih edilmektedir. Bu bağlamda, sıralı verilerin modellenmesine uygun olan Simple RNN, LSTM, GRU, BiLSTM, Stacked LSTM ve uzamsal-temporal ilişkileri yakalamada etkili olan CNN-LSTM gibi farklı derin öğrenme yapıları geliştirilmiştir. Söz konusu modeller, öğrenme kapasitesi, parametre paylaşımı ve bellek mekanizmaları gibi özellikleri bakımından birbirinden ayrılmakta ve farklı veri türlerine göre avantajlar sunmaktadır.

2.3.1.1 Basit tekrarlayan sinir ağı (Simple RNN)

RNN (recurrent neural network- tekrarlayan sinir ağı) sıralı verileri işlemek için tasarlanmıştır. Tekrarlayan sinir ağlarının çıktıları sıranın önceki elemanlarına bağlıdır (Williams ve Zipser, 1989) Önceki bilgi gizli katmanlardan geçerek algoritmada kullanılır. Şekil 5'te RNN çalışma adımları gösterilmiştir.



Şekil 5. RNN akış diyagramı.

$$h_t = \text{RNN}(x_t, h_{t-1}; W^{\text{RNN}}) \quad (1.1)$$

Denklem 1.1’de h_{t-1} bir önceki zamandaki gizli state, W^{RNN} ağırlık fonksiyonunu, x_t girdiyi tanımlamaktadır.

2.3.1.2 Uzun kısa süreli bellek (LSTM)

LSTM modeli, uzun sekanslardaki bağımlılıkları öğrenme konusunda geleneksel tekrarlayan sinir ağlarının (RNN) yaşadığı gradyan kaybolma (vanishing gradient) ve gradyan patlaması (exploding gradient) sorunlarını aşmak için geliştirilmiştir. Bu model, özellikle uzun vadeli bilgi depolama ve gerektiğinde unutma yeteneği sayesinde, zaman serisi analizi, doğal dil işleme (NLP), konuşma tanıma ve biyomedikal sinyal işleme gibi birçok alanda başarılı sonuçlar elde etmiştir. LSTM’nin temel farkı, geleneksel RNN yapılarından farklı olarak kapı mekanizmaları kullanmasıdır. Bu kapılar, modelin belirli bilgileri saklamasına, güncellemesine veya unutmasına olanak tanır ve böylece uzun vadeli bağımlılıkların daha verimli bir şekilde öğrenilmesini sağlar.


LSTM modelinin tarihçesi, gelişim süreci ve teorik temelleri ele alınarak modelin nasıl çalıştığı detaylı bir şekilde incelenecektir. Öncelikle, LSTM’nin geliştirilmesine yol açan temel problemler ve çözüm yöntemleri ele alınacak, ardından modelin matematiksel tanımı açıklanacaktır. Son olarak, LSTM’nin çeşitli alanlardaki uygulamaları ve kullanım avantajları üzerinde durulacaktır.

Uzun Kısa Süreli Bellek (Long Short-Term Memory- LSTM) algoritması, uzun vadeli bağımlılıkları öğrenebilen bir tekrarlayan sinir ağı (RNN) türüdür. Geleneksel RNN modelleri, zaman içinde önceki girdilere olan duyarlılığını kaybetme eğilimindedir. Bu durum, özellikle uzun sekanslı veri işleme süreçlerinde geri yayılımda kaybolan gradyan (vanishing gradient) sorunu olarak adlandırılan bir probleme yol açmaktadır (Hochreiter, 1991). Bu problem nedeniyle, model eski bilgileri unutarak yalnızca en son girişlere odaklanma eğilimi gösterir. LSTM, bu tür sorunları gidermek amacıyla geliştirilmiş bir

model olup, öğrenme sürecinde bilgiyi saklama, güncelleme ve unutma yeteneğine sahiptir (Hochreiter ve Schmidhuber, 1997). LSTM'nin temel farkı, geleneksel RNN modellerinden farklı olarak kapı mekanizmaları kullanmasıdır. Bu mekanizmalar, modelin bilgiyi seçici bir şekilde unutmasını, yeni bilgileri öğrenmesini ve uzun vadeli bağımlılıkları korumasını sağlar. LSTM modeli, tekrarlayan yapısını sürdüren özel bir hücre tasarımına sahiptir ve her hücrede unutma kapısı (forget gate), girdi kapısı (input gate), hücre durumu (cell state) ve çıktı kapısı (output gate) olmak üzere dört bileşen bulunmaktadır. LSTM'nin etkinliği, özellikle zaman serisi tahmini ve doğal dil işleme alanlarında yapılan çalışmalarla kanıtlanmıştır. Örneğin, Graves A. ve Hinton (2013) tarafından yapılan çalışmalarda LSTM, konuşma tanıma alanında geleneksel RNN'lere kıyasla önemli ölçüde daha yüksek performans göstermiştir. Benzer şekilde, Sutskever, Vinyals ve Le (2014) tarafından yapılan araştırmalar, LSTM'nin makine çevirisinde uzun mesafeli bağımlılıkları öğrenme yeteneğinin güçlü olduğunu ortaya koymuştur.

LSTM, ayrıca biyomedikal sinyal işleme alanında da yaygın olarak kullanılmaktadır. Özellikle ECG ve EEG sinyallerinin sınıflandırılması gibi alanlarda, modelin uzun vadeli bağımlılıkları öğrenme kabiliyeti sayesinde başarılı sonuçlar elde edilmiştir (Schirmer ve diğerleri, 2017; Hannun ve diğerleri, 2019). Bu yapı sayesinde, model belirli zaman adımlarında hangi bilgilerin korunması veya güncellenmesi gerektiğini belirleyerek öğrenme sürecini optimize eder. Bu özellikleri nedeniyle LSTM, doğal dil işleme (NLP), zaman serisi tahmini, konuşma tanıma, biyomedikal sinyal analizi gibi birçok alanda yaygın olarak kullanılmaktadır (Greff, Srivastava, Koutník, Steunebrink ve Schmidhuber, 2017). Uzun süreli bağımlılıkları öğrenme kapasitesiyle dikkat çeken LSTM (Long Short-Term Memory) ağı, geleneksel RNN yapılarının sınırlılıklarını aşmak amacıyla geliştirilmiştir. Bu model Şekil 6'da gösterildiği üzere dört adet kapıdan oluşmaktadır. Sırasıyla, unutma kapısı (forget gate), girdi kapısı (input gate), hücre durumu (cell state), ve çıktı kapısıdır (output gate). Algoritmanın birincil adımı hangi giriş verisinin LSTM bölümünden geçirileceğinden karar vermektir. Bu aşama unutma kapısı olarak adlandırılan sigmoid katman tarafından gerçekleştirilir. $\sigma(x)$, Sigmoid aktivasyon fonksiyonu her bir bileşenden ne kadarının geçmesi gerektiğini tanımlayan 0 ile 1 arasında sayılar verir. x_t ve h_{t-1} değerlerine bakılarak C_{t-1} parçası her sayı için 0 ile 1 arasında bir çıkış değeri verir. 1 değeri 'tamamen kurtul' anlamına gelirken 0 değeri

‘tamamen tut’ anlamına gelmektedir.



Şekil 6. LSTM akış mimarisi.

$$f_t = \sigma ([h_{t-1}, x_t] W^f + b^f) \quad (2.1)$$

İkincil adımda yeni bilgilerin belirleneceği girdi kapısı devreye girer ve öncelikle i_t Denklem 2.1’de kullanılarak sigmoid fonksiyonu ile bilgiler yenilenir.

$$i_t = \sigma ([h_{t-1}, x_t] W^i + b^i) \quad (2.2)$$

Daha sonraki adımda Denklem 2.2 ile yeni veriyi hesaplayacak öncül bilgiler $\tanh(x)$, hiperbolik tanjant fonksiyonu Denklem 2.3 ile belirlenir.

$$\hat{C}_t = \tanh ([h_{t-1}, x_t] W^C + b^C) \quad (2.3)$$

Denklem 2.4 tarafından C_{t-1} sonrasında C_t durumuna yenilenir.

$$C_t = f_t * C_{t-1} + i_t * \hat{C}_t \quad (2.4)$$

Algoritmanın son adımında çıktı verilerin elde edilmesi için sigmoid fonksiyondan yararlanılır (Denklem 2.5). Sigmoid kapı çıktısı ile tanh fonksiyonu çarpımı yapılarak çıktı elde edilir (Denklem 2.6).

$$o_t = \sigma ([h_{t-1}, x_t] W^{out} + b^{out}) \quad (2.5)$$

$$h_t = o_t * \tanh(C_t) \quad (2.6)$$

Bu adımlar tekrarlanarak süreç devam eder. Girdi verisi kalmayana kadar algoritma çalışmaya devam eder. Ağırlık parametreleri (W) ve Bias parametreleri (b) gerçek eğitim

değerleri ile LSTM çıktı değerleri arasındaki farkı azaltmak için model tarafına öğrenilmektedir.

$$\text{sigmoid}(x) = \frac{1}{1+e^{-x}} \quad (2.7)$$

$$\text{tanh}(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2.8)$$

2.3.1.3 Kapılı tekrarlayan birim (GRU)

Gated Recurrent Unit (GRU), tekrarlayan sinir ağları (Recurrent Neural Networks- RNN) ailesine ait bir model olup, zaman serisi verileri ve sıralı veri işleme görevlerinde yaygın olarak kullanılmaktadır. GRU, RNN'lerde sıklıkla karşılaşılan kaybolan gradyan (vanishing gradient) problemini azaltmak amacıyla geliştirilmiş ve Uzun Kısa Süreli Bellek (Long Short-Term Memory- LSTM) ağına alternatif bir yapı olarak önerilmiştir (Cho ve diğerleri, 2014). GRU modeli, geleneksel RNN yapılarından farklı olarak kapı (gate) mekanizmaları aracılığıyla bilgi akışını kontrol etme yeteneğine sahiptir. Bu yapı hem önceki bilgilerin korunmasını hem de yeni bilgilerin etkin bir şekilde entegre edilmesini mümkün kılar. LSTM'ye kıyasla daha az parametreye sahip olması, GRU'nun hesaplamalı olarak daha verimli olmasına katkı sağlamaktadır. GRU'nun temel bileşenleri güncelleme kapısı z_t , sıfırlama kapısı r_t ve geçici gizli durum $\tilde{h}_t$ üzerinden şekillenir.

İlk olarak, güncelleme kapısı aşağıdaki gibi tanımlanır:

$$Z_t = \sigma(W_z x_t + U_z h_{t-1} + b_z) \quad (2.9)$$

Bu kapı, bir önceki gizli durumun h_{t-1} ne kadarının korunacağına karar verir. Ardından sıfırlama kapısı hesaplanır:

$$r_t = \sigma(W_r x_t + U_r h_{t-1} + b_r) \quad (2.10)$$

Sıfırlama kapısı, önceki bilgilerin ne ölçüde unutulacağını belirler. Bu iki kapının çıktıları kullanılarak geçici (aday) gizli durum hesaplanır:

$$\tilde{h}_t = \tanh(W_h x_t + U_h (r_t * h_{t-1}) + b_h) \quad (2.11)$$

Son olarak, yeni gizli durum (güncellenmiş çıktı) şu şekilde tanımlanır:

$$h_t = (1 - z_t) * h_{t-1} + z_t * \tilde{h}_t \quad (2.12)$$

GRU'nun bu kapı temelli yapısı, hem önceki bilgilerin unutulması gereken durumları kontrol etmeye hem de yeni bilgilerin ne ölçüde sisteme dahil edileceğini belirlemeye olanak tanır. Bu yönüyle hem kısa hem de orta vadeli bağımlılıkları etkili bir biçimde öğrenebilir.

GRU ile LSTM modelleri, her ikisi de uzun süreli bağımlılıkları öğrenme kapasitesine sahip olmalarına rağmen temel farklılıklar barındırır. GRU'nun daha az parametre içermesi, veri kümelerinde daha hızlı eğitim süresi ve daha düşük hesaplama maliyeti sunmasına olanak tanımaktadır. Yapılan çalışmalarda, özellikle doğal dil işleme ve zaman serisi tahmini gibi görevlerde GRU'nun LSTM ile benzer performans gösterdiği bildirilmiştir (Chung J. ve Bengio, 2014). Bununla birlikte, daha uzun sekans bağımlılıklarını öğrenme konusunda LSTM'nin çoğu durumda daha başarılı olduğu vurgulanmıştır (Greff, Srivastava, Koutn'k, Steunebrink ve Schmidhuber, 2017).

Sonuç olarak, GRU, zaman serisi ve ardışık veri modelleme gibi görevler için güçlü ve hesaplamalı olarak uygun bir seçenektir. Parametre sayısının LSTM'ye göre daha düşük olması, uygulamalarda daha hızlı öğrenme ve daha az aşırı öğrenme (overfitting) riski doğurur. Ancak, model seçimi yapılırken veri yapısı, problem tipi ve öğrenme hedefleri dikkate alınarak GRU ve LSTM modelleri arasında karşılaştırmalı değerlendirme yapılması önerilmektedir.

2.3.1.4 Çift yönlü uzun kısa süreli bellek (BiLSTM)

BiLSTM (Bidirectional Long Short-Term Memory) modeli, zaman serisi verilerindeki hem geçmiş (geçmişten bugüne) hem de geleceğe yönelik (bugünden geçmişe) bağımlılıkları aynı anda öğrenme kapasitesi sayesinde, özellikle deprem tahmini gibi dinamik ve doğrusal olmayan problemlerde giderek daha fazla tercih edilmektedir. Geleneksel LSTM mimarisi yalnızca geçmiş zaman adımlarına yönelik öngörülerde

bulunabilirken, BiLSTM çift yönlü bilgi akışı sağlayarak her bir zaman adımı için daha zengin bir bağlamsal temsil sunar (Graves ve Schmidhuber, 2005). Bu yapı, özellikle ardışık sismik olaylar arasındaki karmaşık ilişkilerin modellenmesinde anlamlı avantajlar sağlamaktadır.

Son dönem literatürde, BiLSTM mimarisinin deprem zaman ve büyüklük tahmini gibi görevlerde yüksek performans gösterdiği görülmektedir. Tayvan'da meydana gelen depremlerin zaman serilerini kullanarak BiLSTM ile büyüklük tahmini gerçekleştirmiş; modelin klasik LSTM ve GRU mimarilerine göre daha düşük hata oranlarına ulaştığını rapor etmiştir (Kavianpour, P., Kavianpour, M., Jahani, E., ve Ramezani, A. ,2021). Türkiye özelinde yapılan çalışmalarda da benzer sonuçlara ulaşılmıştır. Türkiye meydana gelen depremlerin, AFAD katalog verilerini kullanarak BiLSTM mimarisi ile hem deprem aralık sürelerini hem de büyüklük eğilimlerini başarıyla modellemiştir (Duygu Kaya ve Şahin, 2022). BiLSTM mimarisinde, giriş zaman serileri hem ileri hem de geri yönde ayrı LSTM katmanlarından geçirilir. Bu katmanların çıktıları genellikle birleştirilerek (concatenation) nihai özellik vektörü oluşturulur. BiLSTM'in matematiksel gösterimi aşağıdaki gibi özetlenebilir:

$$\vec{h}_t = \text{LSTM}(x_t, \vec{h}_{t-1}) \quad (2.13)$$

$$\bar{h}_t = \text{LSTM}(x_t, \bar{h}_{t-1}) \quad (2.14)$$

$$h_t = [\vec{h}_t; \bar{h}_t] \quad (2.15)$$

Burada $\vec{h}_t$ ileri yöndeki LSTM çıktısını, $\vec{h}_t$ ise geri yöndeki çıktıyı ifade etmektedir. Bu iki vektörün birleştirilmesiyle elde edilen h_t , her bir zaman adımı için çift yönlü bağlamsal bilgiyi temsil eder.

Bu yapı, özellikle sismik sinyallerin hem geçmiş hem de geleceğe dair ipuçları taşıdığı durumlarda daha sağlam öngörüler yapılmasına olanak tanır. Çin'in Sichuan bölgesindeki deprem dizileri üzerinde BiLSTM mimarisinin uygulandığı bir çalışmada, modelin hem kısa vadeli hem de uzun vadeli tahminlerde yüksek kararlılık sergilediği gösterilmiştir (Kavianpour vd. ,2021).

2.3.1.5 Katmanlı LSTM (Stacked LSTM)

Stacked LSTM modeli, zaman serisi verilerindeki karmaşık bağımlılıkları çok katmanlı olarak öğrenebilme kapasitesi sayesinde, özellikle deprem tahmini gibi çok boyutlu, dinamik ve zamana duyarlı uygulamalarda sıkça tercih edilmektedir. Bu model, klasik Uzun Kısa Süreli Bellek (Long Short-Term Memory- LSTM) yapısının dikey olarak istiflenmesiyle oluşturulmuştur. Her bir LSTM katmanı, bir önceki katmandan aldığı çıktıyı girdi olarak kullanarak daha yüksek soyutlama seviyelerinde zaman içi ilişkileri öğrenir. Bu yapı, özellikle yüksek değişkenlik içeren sismik zaman serilerinde hem kısa hem de uzun dönemli bağımlılıkların aynı anda yakalanmasına olanak sağlar (Ye Zhang ve Wallace, 2017).

Son yıllarda yapılan araştırmalar, Stacked LSTM mimarisinin deprem verilerinin işlenmesinde tek katmanlı yapılara kıyasla daha yüksek doğruluk ve genelleme başarısı sunduğunu göstermektedir. Örneğin, Çin'in aktif fay zonlarında meydana gelen deprem dizilerini kullanarak çok katmanlı LSTM yapısıyla hem büyüklük hem de oluş zamanı tahmininde başarı elde edildiği bildirilmiştir (Bilal, M. A., Wang, Y., Ji, Y., Akhter, M. P., ve Liu, H., 2023). Türkiye özelinde yapılan çalışmalarda ise, Kandilli Rasathanesi verileriyle Stacked LSTM mimarisi karşılaştırmalı olarak test edilmiş ve bu yapının, klasik LSTM modellerine kıyasla ortalama hata oranlarını belirgin şekilde azalttığı ortaya konmuştur (Subramaniaswamy, V., Kshetri, N., Ravi, L., Revathy, G., ve Thillaiarasu, N., 2025). Stacked LSTM modelinin her bir katmanında, girdi verisi aşağıdaki temel mekanizmalardan geçer:

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (2.16)$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (2.17)$$

$$\hat{c}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (2.18)$$

$$C_t = f_t \odot C_{t-1} + i_t \odot \hat{c}_t \quad (2.19)$$

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (2.20)$$

$$h_t = o_t \odot \tanh(C_t) \quad (2.21)$$

Bu denklemler, her bir zaman adımı için unutma (f_t), giriş (i_t) ve çıkış (o_t) kapılarının işlevini ve hücre durumu güncellemelerini göstermektedir. Stacked yapıda bu işlemler katmanlar arasında ardışık olarak gerçekleştiğinden, modelin öğrenme kapasitesi ciddi şekilde artmaktadır. Deprem tahmini bağlamında, Stacked LSTM modelleri özellikle

artçı ve öncü depremler arasındaki örüntüleri, mevsimsel döngüleri ve ardışık enerji boşalımını yakalama konusunda güçlü bir yapı sunmaktadır. Örneğin, Marmara bölgesindeki geçmiş deprem serilerini kullanarak eğitilen üç katmanlı Stacked LSTM modelinde hem zamanlama hem de büyüklük tahmininde yüksek korelasyon değerleri elde edilmiştir (Wu, Y. H. , 2022). Ayrıca literatürde, farklı katman sayıları ve hücre boyutları ile yapılandırılmış Stacked LSTM modellerinin performansını karşılaştıran çalışmalar da yer almaktadır. Hiperparametre optimizasyonu ile eğitilen Stacked LSTM modelinin, derinliği artırıldıkça belirli bir seviyeye kadar daha iyi genelleme sağladığı ancak çok fazla katman eklenmesinin aşırı öğrenmeye (overfitting) neden olabileceği belirtilmiştir (Kaushal, A., Gupta, A. K., ve Sehgal, V. K., 2025).

2.3.1.6 Kıvrımlı sinir ağı – uzun kısa süreli bellek modeli (CNN-LSTM)

CNN-LSTM modeli, uzamsal ve zamansal ilişkileri eş zamanlı olarak işleyebilme yeteneği sayesinde, deprem tahmini gibi karmaşık ve çok boyutlu veri gerektiren problemlerde sıkça tercih edilmektedir. Bu hibrit yapı, Kıvrımlı Sinir Ağları (Convolutional Neural Networks- CNN) ile Uzun Kısa Süreli Bellek (Long Short-Term Memory- LSTM) ağlarının birleştirilmesiyle oluşturulmuştur. CNN, verideki yerel örüntüleri çıkararak önemli özellikleri öne çıkarırken; LSTM, bu öznitelikleri zamansal olarak analiz ederek uzun dönem bağımlılıkları öğrenir. Bu özellik, özellikle sismik aktivite gibi hem uzamsal hem de zamansal bileşenler içeren veri kümelerinde önemli avantajlar sunmaktadır (Shi ve diğerleri (2015); Ordoñez ve Roggen (2016) .)

Son yıllarda yapılan çalışmalar, CNN-LSTM mimarisinin deprem verilerinin modellenmesinde başarılı sonuçlar verdiğini göstermektedir. Örneğin, K. Gencer, ve İ. H. Cizmeci, Çin'in sismik bölgelerinde geçmiş deprem dizilerini kullanarak CNN-LSTM ile büyüklük tahmin modelleri geliştirmiştir. Öncel Çekim ve diğerleri (2023), Türkiye'de AFAD ve Kandilli veri setlerini kullanarak CNN tabanlı özellik çıkarımı sonrası LSTM ile deprem büyüklüğü ve zamanı öngörüsünü modellemiş ve klasik istatistiksel yöntemlere kıyasla daha yüksek doğruluk elde etmişlerdir. Benzer şekilde, Zhang, Z., ve Wang, Y. (2023), İran sismotektonik zonlarında uzamsal konum bilgilerini CNN ile öznitelik düzeyinde işleyip LSTM aracılığıyla zaman-mekan bağımlılıklarını modellemişlerdir. Bu bölümde, CNN-LSTM modelinin bileşenleri detaylı şekilde

incelenecek, matematiksel açıklamaları sunulacak ve özellikle deprem tahmini bağlamındaki uygulama örnekleri değerlendirilecektir. Ayrıca, modelin çeşitli jeodinamik ortamlarda ne tür avantajlar sağladığı da vurgulanacaktır. Modelin ilk aşamasında CNN katmanları, giriş sinyallerindeki lokal örüntüleri öğrenerek gürültüyü bastırmakta ve daha belirgin yapısal ilişkileri ortaya çıkarmaktadır. Bu işlem, zaman serilerinin sabit uzunlukta pencereleme yöntemleriyle dönüştürülmesiyle gerçekleştirilir. Her pencere segmenti üzerinde konvolüsyon uygulanır:

$$f_t = \text{ReLU}(W_f * \chi_{t:t+k-1} + b_f) \quad (2.22)$$

CNN katmanlarında kullanılan konvolüsyon işlemini temsil etmektedir. Burada $\chi_{t:t+k-1}$ zaman adımından itibaren alınan k uzunluğundaki giriş vektörünü, W_f filtre ağırlıklarını ve b_f bias terimini ifade eder. ReLU aktivasyon fonksiyonu ile doğrusal olmayan kazandırılan bu işlem, giriş verisinden anlamlı özniteliklerin çıkarılmasını sağlar. CNN katmanlarının çıkışı, sıralı bir biçimde LSTM katmanına aktarılır ve burada her bir zaman adımı için çıkarılan öznitelikler üzerinde bağımlılık öğrenimi sağlanır. Bu adımda, önceki LSTM denklemlerinde tanımlanan mekanizmalar kullanılarak çıktı hesaplanır.

CNN-LSTM modeli, deprem tahmini uygulamalarında hem geçmiş sismik olaylardan öğrenme hem de çok değişkenli zaman serisi yapılarını işleme açısından güçlü bir yapı sunmaktadır. Nicolis, O., Plaza, F., ve Salas, R. (2021), Japonya’da meydana gelen büyük ölçekli depremler için CNN-LSTM tabanlı büyüklük ve enerji tahmin modelleri geliştirmiştir.

Literatürde ayrıca, CNN-LSTM mimarisinin farklı varyasyonları da önerilmiştir. Lin ve diğerleri (2018), BiLSTM-CNN yapısını ters sırada kullanarak geçmiş ve gelecekteki zaman adımları arasındaki ilişkileri iki yönlü olarak modellemiş, bu yaklaşımın özellikle

artçı ve öncü depremler arasındaki ilişkiyi modellemede etkili olduğunu göstermiştir. Bu yapılar sayesinde hem derin uzamsal temsiller hem de zaman içindeki sekans ilişkileri aynı anda değerlendirilerek, daha dengeli ve güvenilir deprem öngörü sistemleri geliştirilebilmektedir.

2.3.2 Model katmanları

Derin öğrenme modelleri, çok katmanlı yapıları sayesinde verinin farklı düzeylerde temsil edilmesini sağlar. Bu katmanlar, her biri farklı işlevler üstlenen yapısal birimler olarak modelin öğrenme kapasitesini ve genelleme yeteneğini belirler. Giriş katmanı, verinin modele ilk aktarımını sağlarken; gizli katmanlar, verinin örüntülerini öğrenme ve dönüştürme işlemlerini gerçekleştirir. Bu süreçte, tekrarlayan katmanlar (LSTM, GRU), evrimsel katmanlar (CNN) ve yoğun bağlantılı (dense) katmanlar farklı veri türleri ve amaçlar için kullanılır. Ayrıca, öğrenme sürecinin dengelenmesi için dropout gibi düzenleme katmanları, çıktı üretimi için ise aktivasyon fonksiyonlarıyla donatılmış çıkış katmanları yer alır. Bu bölümde, modelin öğrenme yapısına katkı sağlayan tüm katman türleri sırayla tanıtılarak, görevleri ve uygulama bağlamındaki işlevleri açıklanacaktır.

2.3.2.1 Giriş katmanı

Giriş katmanı, verinin sinir ağına ilk kez sunulduğu yapısal bileşeni temsil eder. Bu katman, veri kümesinin boyutlarını ve biçimini modele tanıtarak, sonraki katmanlara doğru biçimde aktarılmasını sağlar. Zaman serisi temelli derin öğrenme modellerinde, giriş katmanı genellikle çok boyutlu diziler (örneğin zaman $\times$ özellik sayısı) şeklinde yapılandırılır. Bu yapıda, her zaman adımında birden fazla girdi özelliği modele sunulur. Kullanılan model mimarisine göre giriş boyutu sabitlenmiş pencere uzunluklarıyla belirlenmekte ve özellikle tekrarlayan (RNN, LSTM, GRU) ya da hibrit (CNN-LSTM) yapılarda bu pencere yapısı, zaman içindeki örüntülerin öğrenilmesini kolaylaştırmaktadır. Büyük veri işleme bağlamında giriş verisinin yapısal organizasyonu, modelin genel performansı üzerinde belirleyici bir etkiye sahiptir (Zhang, Q., ve Wang, C. , 2008).

2.3.2.2 Gizli katmanlar

Gizli katmanlar, yapay sinir ağlarının öğrenme sürecinde temel bilgi işleme görevini üstlenen katmanlardır. Bu katmanlarda yer alan nöronlar, giriş katmanından alınan verileri ağırlıklı bağlantılar ve aktivasyon fonksiyonları aracılığıyla dönüştürerek, daha soyut ve anlamlı temsillere dönüştürür. Kullanılan model mimarisine bağlı olarak gizli katmanlar farklı yapılarda olabilir. Örneğin, LSTM, GRU veya BiLSTM gibi tekrarlayan katmanlar zaman bağımlı örüntüleri öğrenirken; CNN katmanları uzamsal filtreleme ile lokal öznitelikleri çıkarmada görev alır. Ancak bu süreçte gradyanların uzun zaman bağımlılıklarında zayıflaması gibi zorluklarla karşılaşılabilir (Bengio, Simard ve Frasconi, 1994). Bu nedenle gizli katmanların sayısı, türü ve aktivasyon yapıları dikkatli biçimde tasarlanmalıdır.

2.3.2.3 Yoğun katman (Dense layer)

Yoğun (dense) katmanlar, sinir ağı katmanları arasında tam bağlantı sağlayarak öğrenilen temsillerin birleştirilmesini ve çıktıya aktarılmasını sağlar. Her bir nöron, bir önceki katmandaki tüm nöronlarla bağlantılıdır ve bu bağlantılar aracılığıyla ağırlıklı toplamlar hesaplanarak aktivasyon fonksiyonu ile işlenir. Dense katmanlar genellikle modelin son aşamalarında yer alır ve yüksek boyutlu özniteliklerin daha düşük boyutlara indirgenmesinde rol oynar. Özellikle regresyon tabanlı problemler için, dense katmanlardan sonra tek nöronlu bir çıkış katmanı ile nihai tahmin yapılır. Derin yapılarla birlikte kullanıldığında, öğrenmeyi dengelemek amacıyla Batch Normalization gibi katmanlar da sıkça entegre edilir (Ioffe ve Szegedy, 2015).

2.3.2.4 Dropout katmanı

Dropout katmanı, modelin genelleme kabiliyetini artırmak ve aşırı öğrenmeyi (overfitting) önlemek amacıyla kullanılan düzenleme katmanlarından biridir. Eğitim süreci boyunca belirli oranlarda nöronların rastgele devre dışı bırakılması prensibine dayanır. Bu mekanizma sayesinde ağ, belirli nöronlara veya bağlantılara aşırı bağımlı hale gelmeden daha sağlam temsiller öğrenir. Dropout'un etkili kullanımının, ağların test verilerindeki başarı oranını önemli ölçüde artırdığı birçok çalışmada gösterilmiştir (Glorot, Bordes ve Bengio, 2011). Özellikle çok katmanlı yapılarda, dropout kullanımı

parametre sayısına bağılı olarak modelin öğrenme kapasitesine denge getirir.

2.3.2.5 Çıkış katmanı

Çıkış katmanı, modelin tahmin çıktısını ürettiği son katmandır. Problem türüne bağılı olarak bu katmanda kullanılan aktivasyon fonksiyonu değişebilir. Sürekli değer tahmini gerektiren regresyon problemlerinde, genellikle lineer aktivasyon fonksiyonu tercih edilir. Bu çalışmada da tüm modellerin çıkış katmanında tek nöron ve lineer aktivasyon yapısı kullanılmıştır. Özellikle ReLU, sigmoid veya softmax gibi doğrusal olmayan aktivasyon fonksiyonlarının uygun olmadığı senaryolarda, lineer yapının esnekliği modelleme açısından avantaj sağlar (He, Zhang, Ren ve Sun, 2015). Doğru yapılandırılmış bir çıkış katmanı, modelin yorumlanabilirliğini ve doğruluğunu doğrudan etkiler.

2.4 Kullanılan Hiperparametreler

Derin öğrenme modellerinin başarımı, büyük ölçüde doğru seçilmiş hiperparametrelere bağılıdır. Bu bölümde, modelin eğitimi sürecinde kullanılan başlıca hiperparametreler ve düzenleme yöntemleri detaylı biçimde sunulmuştur. Öğrenme oranı, optimizasyon algoritması, batch size gibi parametreler modelin öğrenme sürecini doğrudan etkilerken; Dropout gibi düzenleme teknikleri modelin genellenebilirliğini artırmak için kullanılmıştır. Ayrıca, modelin tahmin doğruluğunu belirleyen kayıp fonksiyonunun rolü de kapsamlı şekilde ele alınmıştır.

2.4.1 Dropout yöntemi

Dropout, derin öğrenme modellerinde aşırı öğrenmeyi (overfitting) azaltmak amacıyla kullanılan bir düzenleme (regularization) yöntemidir. Bu yöntem, eğitim süreci sırasında yapay sinir ağındaki belirli oranlarda nöronların rastgele devre dışı bırakılması prensibine dayanır (Srivastava, Hinton, Krizhevsky, Sutskever ve Salakhutdinov, 2014). Böylece modelin, belirli nöronlara veya bağlantılara olan bağımlılığı azaltılarak daha genel ve sağlam temsiller öğrenmesi hedeflenir. Dropout uygulandığında, her eğitim adımında farklı bir alt ağ öğrenme sürecine katılır; bu durum, modelin genelleme kabiliyetini artırmaya yardımcı olur (Baldi ve Sadowski, 2014). Yöntem, özellikle büyük ve karmaşık

derin öğrenme yapılarında yaygın olarak kullanılmaktadır.

2.4.2 Adam optimizasyon algoritması

Adam (Adaptive Moment Estimation), derin öğrenme modellerinin eğitiminde sıkça tercih edilen, gradyan tabanlı bir optimizasyon algoritmasıdır. Bu algoritma, klasik Stokastik Gradyan İnişi (SGD) yöntemine kıyasla her parametre için ayrı öğrenme oranı belirleyerek eğitim sürecini hızlandırmayı ve daha kararlı hale getirmeyi amaçlar. Adam algoritması, birinci dereceden momentum (gradyanların üstel hareketli ortalaması) ile ikinci dereceden momentumu (gradyanların karesinin üstel ortalaması) birleştirerek adaptif bir güncelleme mekanizması oluşturur (Kingma ve Ba, 2015). Bu özellik, öğrenme oranlarının dinamik olarak ayarlanmasını sağladığı için, özellikle karmaşık ve gürültülü veri setlerinde daha hızlı yakınsama ve daha düşük doğrulama hatası elde edilmesine katkıda bulunur. Literatürde yapılan karşılaştırmalı çalışmalar, Adam algoritmasının birçok derin öğrenme uygulamasında varsayılan optimizasyon algoritması olarak etkili biçimde kullanılabildiğini göstermektedir (Ruder, 2016).

2.4.3 Kayıp fonksiyonu (loss)

Makine öğrenmesi ve derin öğrenme modellerinin performansını değerlendirmek için kayıp fonksiyonu kullanılır. Kayıp fonksiyonu, modelin tahmin ettiği değerler ($\hat{y}_i$) ile gerçek değerler ($\bar{y}_i$) arasındaki farkı ölçerek modelin ne kadar hatalı olduğunu belirler.

Kayıp fonksiyonunun değeri, modelin eğitim ve test süreçlerinde minimize edilmeye çalışılır. Derin öğrenme modellerinde sırasıyla; Ortalama Kare Hata (MSE), Huber Kayıp Fonksiyonu ve Ağırlıklı Ortalama Kare Hata (Weighted MSE) kullanılmıştır.

2.4.3.1 Huber kayıp fonksiyonu (Huber Loss)

Kayıp fonksiyonları, makine öğrenmesi ve derin öğrenme modellerinin eğitim sürecinde önemli bir rol oynar. Huber kaybı (Huber Loss), klasik Ortalama Kare Hata (MSE) ve Ortalama Mutlak Hata (MAE) fonksiyonlarının avantajlarını birleştiren bir kayıp fonksiyonudur. Büyük hatalara karşı daha dayanıklı olması nedeniyle, özellikle aykırı değerlere duyarlı regresyon problemlerinde sıkça kullanılır. Huber kaybı, hata küçük olduğunda MSE gibi davranırken, hata büyük olduğunda MAE gibi davranarak aşırı


büyük hataların etkisini azaltır. Fonksiyon şu şekilde tanımlanır:

$$L_{\delta}(y, \hat{y}) = \begin{cases} \frac{1}{2}(y_i - \hat{y}_i)^2, & \text{eğer } |y_i - \hat{y}_i| < \delta \\ \delta(|y_i - \hat{y}_i|) - \frac{1}{2}\delta, & \text{eğer } |y_i - \hat{y}_i| > \delta \end{cases} \quad (2.23)$$

Bu denklemde:

- y : Gerçek değer
- $\hat{y}$: Modelin tahmin ettiği değer
- δ : Hata eşiği (genellikle 1,0 veya 1,35 gibi bir değer alınır)
- Küçük hatalar için MSE (hata karesi) kullanılır,
- Büyük hatalar için MAE (mutlak hata) kullanılır.

Huber kaybı, aykırı değerlerden kaynaklanan büyük hataları MSE gibi kare alma işlemiyle büyütmez. Bunun yerine, belirlenen δ eşiğinden büyük hatalar için MAE gibi doğrusal bir azalma sağlar. Bu özellik, hataların aşırı büyümesini engelleyerek modelin daha dengeli bir şekilde öğrenmesini sağlar.



Şekil 7. Giriş hatası ile kayıp değeri arasındaki ilişkiye göre tanımlanan Huber fonksiyonunun grafiksel gösterimi.

Şekil 7’de görselleştirildiği üzere Huber kayıp fonksiyonu, hata değeri δ eşik değerinden küçükse karesel; büyükse doğrusal artan bir yapı gösterir. Bu özellik, regresyon modellerinde hem küçük hatalara karşı duyarlılık hem de uç değerlere karşı dayanıklılık sağlar.

2.4.3.2 Ağırlıklı ortalama kare hata (Weighted MSE)

Makine öğrenmesi ve derin öğrenme modellerinin kayıp fonksiyonları, modelin öğrenme sürecinde optimizasyonunu belirleyen temel unsurlardan biridir. Klasik Ortalama Kare Hata (Mean Squared Error - MSE), tüm hata değerlerini eşit ağırlıklandırırken, belirli veri noktalarına daha fazla önem vermek amacıyla Ağırlıklı Ortalama Kare Hata (Weighted MSE) kullanılır.

Bu çalışmada, modelin daha büyük depremleri (örneğin $M \geq 5,0$) daha hassas tahmin edebilmesini sağlamak amacıyla, büyük depremlere daha yüksek ağırlık atayan özel bir ağırlıklı MSE kayıp fonksiyonu geliştirilmiştir. Ancak, büyük depremleri daha fazla önemseyen bir hata metriği oluşturmak için, her veri noktasına büyüklüğüne bağlı bir ağırlık katsayısı uygulanmıştır. Büyük depremler için hata değeri daha fazla

ağırlıklandırılarak modelin bu olaylara daha fazla odaklanması sağlanmıştır.

Ağırlıklı MSE şu şekilde tanımlanır:


$$\text{Weighted MSE} = \frac{1}{n} \sum_{i=1}^n w_i (y_i - \hat{y}_i)^2 \quad (2.24)$$

Bu denklemde:

w_i : Ağırlık katsayısı, gerçek deprem büyüklüğüne bağlı olarak belirlenir.

Bu çalışmada kullanılan ağırlık katsayısı:

- $M \geq 5,0$ olan depremler için $w_i=2$ (daha fazla önem verilir).
- $M < 5,0$ olan depremler için $w_i=1$ (standart ağırlık kullanılır).



Şekil 8. Deprem Büyüklüğüne göre Ağırlıklı Ortalama Kare Hata (Weighted MSE) Değişimi.

Deprem büyüklüğüne göre modelin hata duyarlılığını artırmak amacıyla ağırlıklı kayıp fonksiyonu kullanılmıştır. Şekil 8’de, farklı büyüklük eşiklerine göre tanımlanan ağırlıkların, tahmin hatası üzerindeki etkisi görselleştirilmiştir. $M \geq 5,0$ büyüklüğündeki depremler için daha yüksek ağırlık ($w = 2$) atanarak, modelin bu kritik olaylara karşı daha hassas olması hedeflenmiştir.

2.4.4 Öğrenme oranı (learning rate)

Öğrenme oranı (learning rate), derin öğrenme modellerinin eğitim sürecinde optimizasyon algoritmalarının ağırlıkları ne kadar güncelleyeceğini belirleyen temel bir hiperparametredir. Bu parametre, kayıp fonksiyonundan elde edilen gradyan değerlerine göre modelin ağırlıklarının ne büyüklükte değişeceğini tanımlar. Çok yüksek bir öğrenme oranı, modelin optimum noktaya ulaşmadan dalgalanmasına ve kararsız bir öğrenme sürecine neden olabilirken; çok düşük bir oran, öğrenmenin yavaşlamasına ve yerel

minimumlara takılmasına yol açabilir.

Bu çalışmada öğrenme oranının model performansı üzerindeki etkisini değerlendirmek amacıyla 0,01, 0,001, 0,0001 ve 0,00001 olmak üzere dört farklı değer denenmiştir. Eğitim süreci boyunca kullanılan optimizasyon algoritması olan Adam, bu oranlara göre ağırlık güncellemelerini gerçekleştirmiştir. Elde edilen sonuçlar, öğrenme oranı değerinin modelin doğruluk, hata ve genellenebilirlik performansı üzerinde önemli ölçüde etkili olduğunu göstermiştir. En iyi sonuçlar genellikle orta düzey öğrenme oranlarında elde edilmiştir.

2.4.5 Yığın boyutu (batch size)

Batch size, modelin her eğitim adımında kaç örneklik veri ile ağırlık güncellemesi yapacağını belirleyen önemli bir hiperparametredir. Derin öğrenme modellerinde yığın boyutu hem modelin bellek kullanımı hem de eğitimin kararlılığı açısından kritik bir rol oynar. Küçük batch size değerleri genellikle daha sık güncelleme yapılmasını sağladığından daha genel bir öğrenmeye katkıda bulunabilirken; büyük yığınlar daha kararlı gradyanlar üretebilir, ancak overfitting riskini artırabilir.

Bu çalışmada, eğitim sürecinde iki farklı batch size değeri denenmiştir: 32 ve 64. Daha küçük yığın boyutu, modelin daha sık güncellenmesine olanak sağlarken; daha büyük yığın boyutu ile daha az gürültülü, stabil bir öğrenme süreci elde edilmeye çalışılmıştır. Farklı yığın boyutları kullanılarak yapılan denemeler sonucunda, model mimarisine ve öğrenme oranına bağlı olarak her iki değerin de farklı senaryolarda avantaj sağladığı gözlemlenmiştir.

2.4.6 Gizli katman nöron sayısı (hidden state size)

Gizli katman nöron sayısı (hidden state size), özellikle tekrarlayan sinir ağı (RNN) temelli mimarilerde modelin belleğini ve öğrenme kapasitesini belirleyen önemli bir hiperparametredir. Her bir zaman adımında modelin taşıdığı içsel bilgi miktarını ifade eden bu değer, ağın geçmiş bilgiyi ne kadar etkili hatırlayıp işleyebileceğini doğrudan etkiler. Daha yüksek nöron sayıları, modelin daha karmaşık yapıları öğrenmesini sağlar; ancak bu durum eğitim süresini uzatabilir ve aşırı öğrenme (overfitting) riskini artırabilir.

Bu çalışmada, farklı mimari yapıların öğrenme kapasitesini karşılaştırmak amacıyla 64, 128 ve 256 nöron sayısı içeren gizli katman konfigürasyonları kullanılmıştır. Deneyler sonucunda, daha düşük nöron sayıları daha hızlı eğitime olanak sağlarken, daha yüksek nöron sayılarının uzun dönemli bağımlılıkları modelleme konusunda avantaj sağladığı gözlemlenmiştir. Optimal performans, genellikle modelin karmaşıklığı ile veri miktarı arasında kurulan denge ile elde edilmiştir.

2.4.7 Epoch sayısı

Epoch, tüm eğitim verisinin model tarafından bir kez baştan sona işlenmesini ifade eden temel bir hiperparametredir. Derin öğrenme modellerinde birden fazla epoch boyunca eğitim yapılması, modelin veriden genellenebilir örüntüler öğrenmesini sağlar. Ancak çok sayıda epoch, modelin eğitim verisine fazla uyum sağlamasına ve aşırı öğrenmeye (overfitting) yol açabilirken; yetersiz epoch sayısı ise öğrenmenin tamamlanamamasına neden olabilir. Bu çalışmada, eğitim süresini ve doğruluk oranlarını dengelemek amacıyla epoch sayısı farklı model mimarileri için optimum değerler denenmiş ve 50 olarak belirlenmiştir. Eğitim sürecinde doğrulama kaybı (validation loss) yakından takip edilmiş ve gerekli durumlarda erken durdurma (early stopping) mekanizması kullanılarak modelin gereksiz yere daha fazla eğitilmesi önlenmiştir. Bu yaklaşım hem hesaplama maliyetini azaltmış hem de modelin genellenebilirliğini artırmıştır.

2.4.8 Aktivasyon fonksiyonları


Lineer ve ReLU (Rectified Linear Unit) aktivasyon fonksiyonları, derin öğrenme modellerinde farklı işlevler üstlenen temel yapı taşlarıdır. Lineer aktivasyon, özellikle regresyon problemlerinde çıktı katmanında tercih edilmekte olup, sinyali doğrudan geçtiği için ara katmanlarda kullanıldığında modelin doğrusal kalmasına ve dolayısıyla sınırlı öğrenme kapasitesine yol açmaktadır (Goodfellow lan, Bengio Yoshua, 2016). Buna karşılık ReLU, negatif girişleri sıfıra indirirken pozitif değerleri doğrudan ileterek modele doğrusal olmayan bir yapı kazandırır; bu özellik, derin sinir ağlarının karmaşık ve yüksek boyutlu veri örüntülerini daha etkili biçimde öğrenmesine olanak tanır. Her iki fonksiyon da modelin mimarisine ve problem türüne göre farklı avantajlar sunar.

2.4.8.1 Lineer aktivasyon fonksiyonu

Lineer aktivasyon fonksiyonu, yapay sinir ağlarında genellikle regresyon problemlerinde çıktı katmanında kullanılan temel bir fonksiyondur. Bu fonksiyon, girdiyi herhangi bir dönüştürmeye tabi tutmadan doğrudan çıktıya aktaran bir yapıdadır ve matematiksel olarak aşağıdaki formül ile ifade edilir:

$$f(x) = x \quad (2.25)$$

Lineer aktivasyon fonksiyonu, doğrusal ilişkilerin korunmasını sağladığı için sürekli değer tahmini gereken durumlarda tercih edilir. Ancak, bu fonksiyonun katmanlar arasında kullanılması durumunda modelin öğrenme kapasitesi sınırlı kalır, çünkü katmanlar arasındaki bileşim yine doğrusal olur ve derin ağın temsil gücü düşer (Goodfellow Ian, Bengio Yoshua, 2016). Bu nedenle, lineer aktivasyon fonksiyonu genellikle yalnızca çıktı katmanında yer alırken, ara katmanlarda doğrusal olmayan fonksiyonlar kullanılarak modelin öğrenme kapasitesi artırılır (Wilamowski, B. M., 2018). Şekil 9’da Lineer aktivasyon fonksiyonunun, giriş değerini dönüşüme uğratmadan çıktı olarak ileten bir fonksiyon olduğu gösterilmiştir.



Şekil 9. Lineer aktivasyon fonksiyonunun giriş ve çıkış değerleri arasındaki doğrusal ilişkiyi gösteren grafik.


2.4.8.2 Rectified linear unit (ReLU) aktivasyon fonksiyonu

Yapay sinir ağlarında doğrusal olmayan dönüşümler gerçekleştiren aktivasyon fonksiyonları, modellerin girdiler ile çıktılar arasındaki karmaşık ilişkileri öğrenmesini sağlamaktadır. Bu kapsamda, Rectified Linear Unit (ReLU) fonksiyonu geniş bir kullanım alanına sahiptir. ReLU, matematiksel olarak

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2.26)$$

şeklinde tanımlanmakta olup, giriş değeri sıfırın altında olduğunda çıktı olarak sıfır, sıfır veya üzerinde ise giriş değerinin kendisini vermektedir. Fonksiyonun türevi ise şu şekilde ifade edilmektedir:

$$f'(x) = \begin{cases} 1, & \text{eğer } x > 0 \\ 0, & \text{eğer } x \leq 0 \end{cases} \quad (2.27)$$



Şekil 10. ReLU aktivasyon fonksiyonu: negatif girişleri sıfırlar, pozitifleri doğrusal geçirir.

Şekil 10’da pozitif girişler için gradyanın korunmasını sağlayarak özellikle vanishing gradient problemine karşı avantaj sunmaktadır (Nair ve Hinton, 2010; Glorot, Bordes ve Bengio, 2011) . Ayrıca, negatif girdilere sıfır çıktılar verilmesi, ağıın nöronlarının etkin olmamasına (sparsity) yol açarak hesaplama maliyetini düşürebilmektedir (Lecun, Bengio ve Hinton, 2015; Goodfellow lan ve Bengio Yoshua, 2016). Söz konusu özellikleri nedeniyle ReLU, derin öğrenme modellerinde sıkça tercih edilen bir aktivasyon fonksiyonu olmuştur.

2.5 Model Değerlendirme Metrikleri

Modelin tahmin performansını değerlendirmek amacıyla çeşitli hata ölçütleri hesaplanmıştır. Bu bağlamda, Ortalama Mutlak Hata (MAE), Ortalama Kare Hata (MSE), Kök Ortalama Kare Hata (RMSE), Belirleme Katsayısı (R^2) ve Ortalama Mutlak Yüzde

Hata (MAPE) gibi metrikler kullanılmıştır. Ayrıca, modelin bellek kullanımı da değerlendirilmiştir. Aşağıda kullanılan metriklerin matematiksel tanımları verilmiştir:

2.5.1.1 Ortalama mutlak hata (mae)

Ortalama Mutlak Hata (MAE), modelin tahmin ettiği değerler ile gerçek değerler arasındaki farkların mutlak değerlerinin ortalamasını ifade eder. MAE, tüm tahmin hatalarını aynı ölçüde değerlendirerek modelin hata seviyesini yorumlamaya yardımcı olur. Matematiksel olarak şu şekilde ifade edilir:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (2.28)$$

Burada y_i , gerçek değerleri, $\hat{y}_i$ tahmin edilen değerleri ve n veri noktalarının toplam sayısını temsil etmektedir.

2.5.1.2 Ortalama kare hata (mse)

Ortalama Kare Hata (MSE), tahmin edilen değerler ile gerçek değerler arasındaki farkların karelerinin ortalamasıdır. MSE, matematiksel olarak şu şekilde ifade edilir:

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (2.29)$$

2.5.1.3 Kök ortalama kare hata (rmse)

Kök Ortalama Kare Hata (RMSE), MSE'nin karekökü alınarak elde edilir. RMSE, hataların ortalama büyüklüğünü yorumlamayı kolaylaştıran bir ölçüt olarak kullanılır. Şu şekilde tanımlanır:

$$RMSE = \sqrt{MSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (2.30)$$

2.5.1.4 Belirleme katsayısı (R^2)

Belirleme katsayısı (R^2), modeli açıklayan bir metriktir ve bağımsız değişkenlerin bağımlı değişken üzerindeki açıklama gücünü ölçer. R^2 değeri 0 ile 1 arasında değişir ve şu şekilde hesaplanır:

$$R^2 = 1 - \frac{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}{\frac{1}{n} \sum_{i=1}^n (y_i - \bar{y}_i)^2} \quad (2.31)$$

Burada $\bar{y}_i$, gerçek değerlerin ortalamasıdır. R^2 değeri 1'e yaklaştıkça modelin tahmin başarısının arttığı yorumu yapılabilir.

3. YÖNTEM

Bu bölümde, çalışmada kullanılan araştırma modeli, kullanılan derin öğrenme algoritmaları, veri setleri ve ön işleme süreçleri, model eğitimi ve değerlendirme yöntemleri, kullanılan yazılım ve donanım altyapısı gibi temel bileşenler ele alınmıştır. Çalışma, deprem tahmini için zamansal ve mekansal analizlerin derin öğrenme modelleri ile gerçekleştirilmesini amaçlamaktadır.

Bu kapsamda:

- Araştırma modeli, çalışmanın amacına uygun olarak nasıl yapılandırıldığı ve nasıl bir deneysel model kullanıldığı detaylandırılmıştır.
- Veri setleri ve veri ön işleme süreci, kullanılan deprem verilerinin kaynakları, işlenmesi ve dönüştürülmesi açıklanmıştır.
- Kullanılan derin öğrenme modelleri, Simple RNN, LSTM, GRU, CNN-LSTM, BiLSTM ve Stacked LSTM ve modellerinin matematiksel açıklamaları ile ele alınmıştır.
- Model eğitimi ve değerlendirme yöntemleri, model doğruluklarını ölçmek için kullanılan performans metrikleri detaylandırılmıştır.
- Kullanılan yazılım ve donanım altyapısı, veri işleme ve model eğitimi için kullanılan teknolojiler belirtilmiştir.

Bu bölümde sunulan yöntemsel çerçeve, çalışmanın tekrar edilebilir olmasını sağlayacak şekilde tasarlanmıştır. Çalışmada kullanılan tüm süreçler, veri kaynağından model değerlendirmesine kadar açık ve sistematik bir şekilde sunulmuştur.

3.1 Araştırma Modeli

Araştırma modeli, çalışmanın amacına uygun olarak verilerin toplanması, işlenmesi ve değerlendirilmesi için belirlenen metodolojik çerçeveyi ifade etmektedir. Bu çalışmada, Marmara ve Kahramanmaraş bölgelerindeki depremleri zamansal ve mekansal bağlamda analiz edebilmek amacıyla veri odaklı bir araştırma modeli benimsenmiştir. Çalışmada,

zamansal tahmin ve mekansal analiz yapabilen derin öğrenme modellerinin kullanılması nedeniyle, deneysel (experimental) model yaklaşımı benimsenmiştir. Bu çerçevede, farklı derin öğrenme yöntemleri kullanılarak modellerin deprem tahmini üzerindeki başarısı karşılaştırılmıştır. Kullanılan modelleme yaklaşımı, deprem verilerinin analiz edilmesini ve sonuçların istatistiksel olarak değerlendirilmesini içermektedir.

Bu bağlamda çalışmanın yöntemi, makine öğrenmesi ve derin öğrenme tabanlı deneysel modelleme süreci ile ele alınmaktadır. Çalışmada öncelikle veri setleri derlenmiş, ardından veri ön işleme adımları uygulanarak modelin eğitimi için uygun hale getirilmiştir. Eğitim sürecinde Basit RNN, LSTM, GRU, Yığılmış LSTM, CNN LSTM ve BiLSTM gibi farklı modeller kullanılmış ve performansları karşılaştırılmıştır.

Araştırma modelinde kullanılan temel aşamalar şu şekildedir:

- Veri Toplama ve Hazırlık: AFAD ve MTA kurumlarından elde edilen veri kayıtlarının temizlenmesi, eksik verilerin yönetilmesi ve normalizasyon işlemlerinin gerçekleştirilmesi.
- Özellik Mühendisliği ve Veri Dönüştürme: Zaman serisi analizine uygun hale getirilmesi, deprem büyüklükleri, mekansal koordinatlar ve zaman damgalarının belirlenmesi.
- Model Eğitimi ve Optimizasyon: Derin öğrenme algoritmalarının eğitilmesi, hiper parametre optimizasyonu ve doğrulama süreçlerinin uygulanması.
- Model Performansının Değerlendirilmesi: MSE, RMSE, MAE, R^2 gibi hata metrikleri kullanılarak modellerin başarılarının ölçülmesi.
- Sonuçların Karşılaştırılması ve Yorumlanması: Farklı modellerin tahmin doğruluklarının karşılaştırılması ve elde edilen bulguların yorumlanması.

Bu araştırma modeli, özellikle Marmara ve Kahramanmaraş bölgelerindeki deprem tahmini için makine öğrenmesi ve derin öğrenme tabanlı yaklaşımların uygulanabilirliğini değerlendirmeyi amaçlamaktadır.

3.2 Veri Toplama

Çalışmada kullanılan veriler, Marmara ve Kahramanmaraş bölgelerindeki deprem kayıtlarından elde edilmiş olup, ulusal ve uluslararası sismoloji merkezlerinden sağlanmıştır. Çalışmanın temel amacı, bu bölgelerde meydana gelen depremlerin zamansal ve mekansal örüntülerini analiz ederek derin öğrenme modelleri kullanarak tahmin gerçekleştirmektir.

3.2.1 Veri kaynakları

Afet ve Acil Durum Yönetimi Başkanlığı (AFAD): Türkiye genelindeki sismik aktivite verileri ve deprem tehlike haritalarına ilişkin bilgiler, Afet ve Acil Durum Yönetimi Başkanlığı (AFAD) tarafından sağlanan güncel ve kurumsal veri tabanlarından temin edilmiştir (T.C. İçişleri Bakanlığı Afet ve Acil Durum Yönetimi Başkanlığı, 2025).

Maden Tetkik ve Arama Genel Müdürlüğü (MTA): Aktif fay hatlarına ilişkin konumsal veri seti, Türkiye Cumhuriyeti Maden Tetkik ve Arama Genel Müdürlüğü (MTA) tarafından sağlanan güncel dijital fay haritalarından temin edilmiştir.

Generic Mapping Tools (GMT): Küresel topografya verileri, Generic Mapping Tools (GMT) yazılım paketi kapsamında sunulan @earth_relief_03s raster veri setinden elde edilmiştir. Bu veri seti, SRTM, GEBCO ve ETOPO çok kaynaklı küresel yükseklik verilerinin birleştirilmesiyle oluşturulmuş ve Paul Wessel ile çalışma arkadaşları tarafından geliştirilmiştir. Açık kaynaklık olarak kullanılabilen GMT programı ve açık kaynaklı topoğrafya verilerine ulaşılabilir (Wessel ve diğerleri, 2019).

Veri Türleri ve İçeriği:

- Olgusal (Nicel) Veriler: Deprem büyüklüğü (Mw), odak derinliği (km), enlem-boylam koordinatları, tarih ve saat bilgisi.
- Tektonik Veriler: Fay hatlarının özellikleri.
- Mekansal Veriler: Depremlerin coğrafi dağılımı, yoğunluk haritaları.

Veri Toplama ve İşleme Süreci:

- Veri Toplama: Yukarıda belirtilen kurumlardan alınan veriler birleştirilmiş ve eksik kayıtlar tespit edilmiştir.
- Eksik Verilerin Yönetimi: Eksik veriler belirlenmiş ve interpolasyon, eksik veri tamamlama teknikleri ile düzenlenmiştir.
- Veri Normalizasyonu: Model eğitimi için tüm veriler ölçeklendirilmiş ve farklı ölçeklerdeki veriler uygun hale getirilmiştir.
- Özellik Mühendisliği: Zamansal ve mekansal bağımlılıkların belirlenmesi için deprem büyüklükleri, ivme değerleri ve mekansal koordinatlar kullanılmıştır.

Bu süreçte elde edilen veriler, LSTM, GRU ve CNN-LSTM gibi derin öğrenme modellerinin eğitimi ve test edilmesi amacıyla kullanılmıştır. Model performanslarının karşılaştırılması için veri setleri eğitim ve test gruplarına ayrılmıştır.


3.2.1.1 Kullanılan veri setleri

Bu çalışmada, Marmara ve Kahramanmaraş bölgelerindeki sismik aktivitenin zamansal ve mekansal örüntülerini analiz etmek amacıyla farklı kaynaklardan elde edilen deprem veri setleri kullanılmıştır. Söz konusu veri setleri, 1994–2024 yılları arasındaki 30 yıllık dönemi kapsamakta olup, her bir deprem olayı için büyüklük (Mw), odak derinliği (km), enlem-boylam koordinatları ile tarih ve saat bilgisi olan temel sismik parametreleri içermektedir. Marmara Bölgesi'ne ait veriler AFAD tarafından sağlanmış, veri işleme sürecinde temizleme, eksik verilerin tamamlanması ve zamansal-mekansal analiz için uygun veri dönüşümleri gerçekleştirilmiştir. Kahramanmaraş Bölgesi verileri ise AFAD kaynaklarından derlenmiş; veri normalizasyonu, zaman serisi analizi ve mekansal dağılım değerlendirmeleri uygulanmıştır.

3.2.1.2 Marmara Bölgesi deprem veri seti

Bu veri seti, 26 ile 31 boylamları ve 40 ile 41.5 enlemleri arasında meydana gelen depremleri içermektedir. 3 Ocak 1998 ile 21 Aralık 2023 tarihleri arasında kaydedilen toplam 19.941 deprem verisi kullanılmıştır. Veride, tarih, enlem, boylam, derinlik, RMS ve büyüklük gibi çeşitli parametreler bulunmaktadır.

Depremlerin meydana geldiği tarih aralığında en erken kayıt 3 Ocak 1998, 13:30:14, en son kayıt ise 21 Aralık 2023, 05:02:40 olarak kaydedilmiştir. Medyan tarih 13 Ocak 2015, 14:48:54 olup, deprem kayıtlarının yoğunlaştığı dönemler belirli zaman dilimlerine denk gelmektedir. En erken çeyrek dilimde depremler 5 Eylül 2010, 14:48:29, en geç çeyrek dilimde ise 10 Nisan 2019, 18:17:28 tarihlerinde yoğunlaşmıştır. Depremlerin meydana geldiği koordinat bilgilerine bakıldığında, boylam değerleri 26 ile 31 arasında değişirken, enlem değerleri 40 ile 41,5 arasında değişmektedir. Ortalama boylam 28,4783, ortalama enlem ise 40,5451 olarak hesaplanmıştır. Medyan boylam değeri 28,518, medyan enlem değeri ise 40,5728 olarak belirlenmiştir. En erken çeyrek dilimde depremler $27,4643^{\circ}$ boylamı ve $40,3346^{\circ}$ enlemi civarında yoğunlaşırken, en geç çeyrek dilimde $29,2473^{\circ}$ boylamı ve $40,7696^{\circ}$ enlemi civarında meydana gelmiştir. Depremlerin derinlikleri 0 ile 83,07 km arasında değişmekte olup, ortalama derinlik 8,04171 km olarak hesaplanmıştır. Medyan derinlik değeri 7 km olup, en erken çeyrek dilimde 6,97 km, en geç çeyrek dilimde ise 7,35 km derinliğinde depremler yoğunlaşmıştır. Ölçümlerde hata oranını gösteren RMS değerleri 0 ile 9,64 arasında değişmektedir. Ortalama RMS değeri 0,3735 olup, medyan RMS değeri 0,35 olarak hesaplanmıştır. En erken çeyrek dilimde 0,21, en geç çeyrek dilimde ise 0,5826 değerleri gözlemlenmiştir. RMS değerinin düşük olması, ölçümlerin genel olarak güvenilir olduğunu göstermektedir. Depremlerin büyüklükleri 0 ile 7,4 arasında değişmektedir. Ortalama büyüklük 2,11283 olup, medyan büyüklük değeri 2,1 olarak hesaplanmıştır. Depremlerin büyük bir kısmı 1,5 ile 2,7 büyüklükleri arasında yoğunlaşmış olup, büyük depremler belirli bölgelerde kümelenmiştir. Deprem verilerinin her biri, benzersiz bir kimlik numarası olan Event ID ile tanımlanmıştır. Bu veri setinde, büyüklüğü 5,5'in üzerinde olan birçok deprem kaydedilmiş olup, bu tür büyük depremlerin belirli bölgelerde yoğunlaştığı gözlemlenmektedir. Özellikle 28° ile 30° boylamları ve $40,3^{\circ}$ ile $40,8^{\circ}$ enlemleri arasında belirgin bir sismik aktivite yoğunluğu bulunmaktadır. Ortalama ve medyan büyüklük değerlerine bakıldığında, büyük depremlerin belirli dönemlerde ve belirli bölgelerde meydana geldiği görülmektedir. Bütünsel anlamda, bu veri seti belirli bir bölgedeki sismik aktivitenin zaman içindeki değişimini analiz etmek ve büyük depremlerin oluşumunu incelemek için kullanılabilir. Veriler, deprem büyüklüğü, derinliği ve konumlarına göre değerlendirilerek belirli risk bölgelerinin tespiti için önemli bilgiler sağlamaktadır.



Şekil 11. Marmara bölgesi deprem merkez noktalarının gösterimi. Deprem Richter büyüklükleri renk ölçeği olarak tanımlanmıştır.

Şekil 11'in oluşturulmasında kullanılan deprem ve topoğrafya verileri açık kaynaklı olup sırasıyla şu kaynaklardan erişilebilmektedir (T.C. İçişleri Bakanlığı Afet ve Acil Durum Yönetimi Başkanlığı, 2025; Wessel ve diğerleri, 2019). Marmara Bölgesi'ndeki deprem aktivitesinin dağılımını gösteren bir harita sunulmuştur. Bu harita, deprem büyüklüklerini ve konumlarını renkli dairelerle görselleştirmektedir. Dairelerin renkleri ve büyüklükleri, depremlerin büyüklüğünü temsil etmektedir. Haritanın alt kısmında yer alan renk ölçeği, depremlerin büyüklük aralıklarını belirtmektedir. 0 ile 7 arasındaki büyüklükleri kapsayan bu ölçek, mor renkten sarı renge doğru değişmekte olup, mor daha küçük büyüklükleri, sarı ise daha büyük büyüklükleri ifade etmektedir. Haritada görülen yoğun daire kümeleri, belirli bölgelerdeki yüksek deprem aktivitelerini işaret ederken, büyük daireler ise daha büyük büyüklüklü depremleri göstermektedir. Özellikle İstanbul ve çevresinde yoğunlaşan büyük daireler, bu bölgenin sismik risk altında olduğunu ve daha büyük depremlerin burada meydana geldiğini ortaya koymaktadır.

Tablo 1. Marmara Bölgesi büyüklük sınıflarına göre deprem sayıları

Büyüklük Aralığı	Deprem Sayısı
0,0-0,5	33
0,5-1,0	194
1,0-1,5	4338
1,5-2,0	4595
2,0-2,5	3469
2,5-3,0	4830
3,0-3,5	1788
3,5-4,0	444
4,0-4,5	183
4,5-5,0	43
5,0-5,5	20
5,5-6,0	3
6,0-6,5	0
6,5-7,0	0
7,0-7,5	1
7,5-8,0	0


Tablo 1’de büyüklük ile deprem sayısı arasındaki ters orantılı ilişkiyi ortaya koymaktadır. 0,0-0,5 büyüklük aralığında 33 deprem kaydedilirken, 0,5-1,0 aralığında bu sayı 194’e yükselmiştir. 1,0-1,5 büyüklüğündeki depremlerin sayısı 4.338 olup, 1,5-2,0 büyüklüğündeki depremler ise 4.595 olarak kaydedilmiştir. 2,0-2,5 aralığında 3,469, 2,5-3,0 aralığında ise 4.830 deprem meydana gelmiştir. Bu büyüklük aralığında en fazla

sismik aktivitenin 2,5-3,0 arasında gerçekleştiği görülmektedir. Daha büyük büyüklüklerde ise deprem sayısında belirgin bir azalma gözlemlenmektedir. 3,0-3,5 büyüklüğündeki deprem sayısı 1.788 iken, 3,5-4,0 aralığında 444 deprem tespit edilmiştir. 4,0-4,5 büyüklüğünde 183, 4,5-5,0 büyüklüğünde ise 43 deprem meydana gelmiştir. 5,0-5,5 büyüklük aralığında 20, 5,5-6,0 aralığında 3 deprem kaydedilmiştir. 6,0-6,5 ve 6,5-7,0 büyüklük aralıklarında herhangi bir deprem kaydı bulunmazken, 7,0-7,5 aralığında yalnızca 1 deprem gerçekleşmiştir. 7,5-8,0 büyüklüğünde ise herhangi bir deprem tespit edilmemiştir. Bu veriler, küçük ve orta büyüklükteki depremlerin sayısının oldukça yüksek olduğunu, ancak büyüklük arttıkça deprem sayısının belirgin şekilde azaldığını göstermektedir.

Tablo 2. Marmara Bölgesi 1994-2024 yılları arasındaki 5,0 ve üzeri büyüklükteki depremler

Yıl	Tarih	Büyüklük (Richter)	Enerji (Joule)
1999	17 Ağustos	7,4	$7,94 \times 10^{15}$
2019	26 Eylül	5,8	$3,16 \times 10^{13}$
1999	13 Eylül	5,7	$2,24 \times 10^{13}$
1999	11 Kasım	5,7	$2,24 \times 10^{13}$
2000	23 Ağustos	5,4	$7,94 \times 10^{12}$
2014	24 Mayıs	5,3	$5,62 \times 10^{12}$
1999	31 Ağustos	5,2	$3,98 \times 10^{12}$
2006	20 Ekim	5,2	$3,98 \times 10^{12}$
2006	24 Ekim	5,2	$3,98 \times 10^{12}$
2003	06 Temmuz	5,2	$3,98 \times 10^{12}$
2012	07 Haziran	5,1	$2,82 \times 10^{12}$
2010	03 Kasım	5,1	$2,82 \times 10^{12}$
2008	28 Aralık	5,1	$2,82 \times 10^{12}$

Tablo 2’de Marmara Bölgesi’nde meydana gelen en büyük 15 depreme ait büyüklük ve enerji değerlerini içeren veri setini analiz ederek, deprem büyüklüğü ile açığa çıkan enerji arasındaki ilişkiyi ortaya koymaktadır. En yüksek büyüklüğe sahip deprem, 17 Ağustos 1999 tarihinde gerçekleşmiş olup, 7,4 büyüklüğünde ve $7,94 \times 10^{15}$ Joule enerji açığa çıkarmıştır. Bu değer, listedeki diğer depremlerle kıyaslandığında enerji açısından oldukça yüksek olup, büyüklük ile enerji arasındaki üstel artışı doğrulamaktadır. Tabloda, büyüklükleri 5,8 ile 5,1 arasında değişen diğer depremler de yer almaktadır. 26 Eylül 2019’da meydana gelen 5,8 büyüklüğündeki deprem, $3,16 \times 10^{13}$ Joule enerji açığa çıkarmış olup, bu değer, 5,7 büyüklüğündeki 13 Eylül ve 11 Kasım 1999 depremlerinin ürettikleri $2,24 \times 10^{13}$ Joule enerji miktarından daha yüksek olduğu görülmektedir. Benzer şekilde, büyüklüğü 5,4 olan 23 Ağustos 2000 depremi, $7,94 \times 10^{12}$ Joule enerji açığa çıkarmıştır. Büyüklüğü 5,3 ve 5,2 olan depremler, enerji açısından birbirine yakın değerlere sahiptir. 24 Mayıs 2014’te gerçekleşen 5,3 büyüklüğündeki deprem, $5,62 \times 10^{12}$ Joule enerji açığa çıkarırken, 31 Ağustos 1999, 20-24 Ekim 2006 ve 6 Temmuz 2003 tarihlerinde meydana gelen 5,2 büyüklüğündeki depremler, $3,98 \times 10^{12}$ Joule enerji üretmiştir. Benzer şekilde, büyüklüğü 5,1 olan depremler (7 Haziran 2012, 3 Kasım 2010, 28 Aralık 2008, 4 Aralık 2023) yaklaşık $2,82 \times 10^{12}$ Joule enerji açığa çıkarmıştır.



Şekil 12. 1990–2024 yılları arasında Marmara Bölgesi deprem katalog verisi grafikleri.


Şekil 12’de, Marmara Bölgesi’ne ait deprem verilerinin zaman serisi analizine yönelik temel parametrelerin dağılımı sunulmuştur. İlk grafikte yer alan büyüklük (Magnitude) zaman serisi, 1990 sonrası dönemde büyüklüğü 4 ve üzeri depremlerin yıllar içindeki dağılımını ortaya koymakta; 1999 yılı civarında gözlemlenen yüksek büyüklükteki depremler dikkat çekmektedir. İkinci sıradaki odak derinliği (Depth) grafiği, depremlerin çoğunlukla sığ odakta (<20 km) meydana geldiğini göstermekte olup, bu durum bölgenin aktif tektonik yapısıyla uyumludur. Üçüncü ve dördüncü grafiklerde sunulan enlem (Latitude) ve boylam (Longitude) değerleri, çalışma alanının kuzeybatı-güneydoğu doğrultusunda konumlandığını ve zamana bağlı olarak sismik aktivitenin mekansal yayılım gösterdiğini ortaya koymaktadır. Son grafikte ise, büyüklüğe bağlı olarak hesaplanan sismik enerji (Joule) değerlerinin zamansal değişimi verilmiş olup, 1999 yılına karşılık gelen belirgin bir enerji boşalımı gözlemlenmiştir. Tüm bu görseller, Marmara Bölgesi’nde zamansal ve mekansal olarak yoğunlaşan sismik aktivitenin analizinde kullanılan veri setinin kapsamlı karakterini ortaya koymakta ve modelleme

öncesi dinamikleri anlamada önemli bir temel sunmaktadır.

3.2.1.3 Kahramanmaraş Bölgesi deprem veri seti

Bu veri seti, 35,5 ile 41 boylamları ve 36 ile 38,4235 enlemleri arasında meydana gelen depremleri içermektedir. 8 Ocak 1990 ile 7 Şubat 2025 tarihleri arasında kaydedilen toplam 130.627 deprem verisi kullanılmıştır. Veride, tarih, enlem, boylam, derinlik, RMS ve büyüklük gibi çeşitli parametreler bulunmaktadır. Depremlerin meydana geldiği tarih aralığında en erken kayıt 8 Ocak 1990, 10:44:47, en son kayıt ise 7 Şubat 2025, 21:37:21 olarak kaydedilmiştir. Medyan tarih 21 Şubat 2023, 17:23:25 olup, deprem kayıtlarının yoğunlaştığı dönemler belirli zaman dilimlerine denk gelmektedir. En erken çeyrek dilimde depremler 27 Ağustos 2017, 03:58:31, en geç çeyrek dilimde ise 23 Haziran 2023, 18:52:40 tarihlerinde yoğunlaşmıştır. Depremlerin meydana geldiği koordinat bilgilerine bakıldığında, boylam değerleri 35,5 ile 41 arasında değişirken, enlem değerleri 36 ile 38,4235 arasında değişmektedir. Ortalama boylam 37,8124, ortalama enlem ise 38,0787 olarak hesaplanmıştır. Medyan boylam değeri 37,8142, medyan enlem değeri ise 38,117 olarak belirlenmiştir. En erken çeyrek dilimde depremler $36,8003^{\circ}$ boylamı ve $37,6022^{\circ}$ enlemi civarında yoğunlaşırken, en geç çeyrek dilimde $38,6765^{\circ}$ boylamı ve $38,4235^{\circ}$ enlemi civarında meydana gelmiştir. Depremlerin derinlikleri 0 ile 96,7 km arasında değişmekte olup, ortalama derinlik 7,74448 km olarak hesaplanmıştır. Medyan derinlik değeri 7 km olup, en erken çeyrek dilimde 7 km, en geç çeyrek dilimde ise 7,09 km derinliğinde depremler yoğunlaşmıştır. Ölçümlerde hata oranını gösteren RMS değerleri 0 ile 29,5 arasında değişmektedir. Ortalama RMS değeri 0,401056 olup, medyan RMS değeri 0,37 olarak hesaplanmıştır. En erken çeyrek dilimde 0,23, en geç çeyrek dilimde ise 0,53 değerleri gözlemlenmiştir. RMS değerinin düşük olması, ölçümlerin genel olarak güvenilir olduğunu göstermektedir. Depremlerin büyüklükleri 0 ile 7,7 arasında değişmektedir. Ortalama büyüklük 1,92851 olup, medyan büyüklük değeri 1,8 olarak hesaplanmıştır. Depremlerin büyük bir kısmı 1,4 ile 2,4 büyüklükleri arasında yoğunlaşmış olup, büyük depremler belirli bölgelerde kümelenmiştir. Deprem verilerinin her biri, benzersiz bir kimlik numarası olan 'Event ID' ile tanımlanmıştır. Bu veri setinde, büyüklüğü 5,5'in üzerinde olan birçok deprem kaydedilmiş olup, bu tür büyük depremlerin belirli bölgelerde yoğunlaştığı gözlemlenmektedir. Özellikle $37,8^{\circ}$ ile $38,6^{\circ}$ enlemleri ve $36,8^{\circ}$ ile $38,6^{\circ}$ boylamları arasında belirgin bir sismik aktivite yoğunluğu

bulunmaktadır. Ortalama ve medyan büyüklük değerlerine bakıldığında, büyük depremlerin belirli dönemlerde ve belirli bölgelerde meydana geldiği görülmektedir.



Şekil 13.Türkiye'nin doğusunda, büyüklüklere göre renklendirilmiş ve ölçeklendirilmiş depremler haritası.

Şekil 13'ün oluşturulmasında kullanılan deprem ve topoğrafya verileri açık kaynaklı olup sırasıyla şu kaynaklardan erişilebilmektedir (T.C. İçişleri Bakanlığı Afet ve Acil Durum Yönetimi Başkanlığı, 2025); Wessel ve diğerleri, 2019).

Tablo 3. Kahramanmaraş Bölgesi büyüklük sınıflarına göre deprem sayıları

Büyüklik Aralığı	Deprem Sayısı
0,0-0,5	38
0,5-1,0	3611
1,0-1,5	34534
1,5-2,0	18580
2,0-2,5	3469
2,5-3,0	4830
3,0-3,5	8326
3,5-4,0	2553
4,0-4,5	932
4,5-5,0	252
5,0-5,5	100
5,5-6,0	22
6,0-6,5	5
6,5-7,0	2
7,0-7,5	1
7,5-8,0	2

Tablo 3’deki veri analizi deprem büyüklüğü ile frekansı arasındaki istatistiksel ilişkiyi ortaya koymaktadır. Küçük ölçekli depremler, toplam sismik aktivitenin büyük bir kısmını oluştururken, büyüklük arttıkça deprem sayısında belirgin bir azalma gözlemlenmektedir. 0,0-0,5 büyüklüğündeki depremler 38 olarak kaydedilirken, 0,5-1,0 büyüklüğündeki depremlerin sayısı 3.611’e yükselmiştir. 1,0-1,5 büyüklüğündeki depremler 34.534 ile en fazla gözlemlenen büyüklük aralığını oluşturmakta olup, 1,5-2,0


büyükluğündeki depremler 18.580 olarak kaydedilmiştir. Daha büyük büyüklüklerde deprem sayısında azalma eğilimi devam etmektedir. 2,0-2,5 büyüklüğündeki depremler 3,469, 2,5-3,0 büyüklüğündeki depremler ise 4.830 olarak belirlenmiştir. 3,0-3,5 büyüklüğündeki depremlerin sayısı tekrar artarak 8.326'ya ulaşmış, ancak 3,5-4,0 büyüklüğündeki depremler 2.553 olarak kaydedilmiştir. 4,0-4,5 büyüklüğündeki depremler 932, 4,5-5,0 büyüklüğündekiler ise 252 olarak gözlemlenmiştir. Büyüklüğü 5,0 ve üzeri olan depremler daha nadir meydana gelmiştir. 5,0-5,5 büyüklüğünde 100, 5,5-6,0 büyüklüğünde 22, 6,0-6,5 büyüklüğünde 5 deprem kaydedilmiştir. Daha büyük depremlerde bu azalma eğilimi devam etmekte olup, 6,5-7,0 büyüklüğünde yalnızca 2, 7,0-7,5 büyüklüğünde 1 ve 7,5-8,0 büyüklüğünde 2 deprem tespit edilmiştir. Bu veriler, deprem büyüklüğü arttıkça frekansın azaldığını gösteren Gutenberg-Richter ilişkisi ile uyumlu olup, küçük ve orta büyüklükteki depremlerin daha sık meydana geldiğini, büyük depremlerin ise nadir gerçekleştiğini ortaya koymaktadır. Özellikle 1,0-1,5 büyüklük aralığında deprem sayısının en yüksek seviyeye ulaştığı, ardından büyüklük arttıkça genel bir azalma eğilimi gösterdiği gözlemlenmektedir.

Tablo 4. Kahramanmaraş Bölgesi 1994-2024 yılları arasındaki 5,0 ve üzeri büyüklükteki depremler

Yıl	Tarih	Büyüklük (Richter)	Enerji (Joule)
2023	06 Şubat	7,7	$2,24 \times 10^{16}$
2023	06 Şubat	7,6	$1,58 \times 10^{16}$
1992	13 Mart	7,0	$2,00 \times 10^{15}$
2020	24 Ocak	6,8	$1,00 \times 10^{15}$
2023	06 Şubat	6,6	$5,01 \times 10^{14}$
2003	27 Ocak	6,4	$2,51 \times 10^{14}$
2023	20 Şubat	6,4	$2,51 \times 10^{14}$
1992	15 Mart	6,1	$8,91 \times 10^{13}$
2003	01 Mayıs	6,1	$8,91 \times 10^{13}$

1992	28 Nisan	6,0	$6,31 \times 10^{13}$
2005	14 Mart	5,9	$4,47 \times 10^{13}$
2024	16 Ekim	5,9	$4,47 \times 10^{13}$
1998	27 Haziran	5,9	$4,47 \times 10^{13}$
2023	06 Şubat	5,9	$4,47 \times 10^{13}$

Tablo 4'te Türkiye'de meydana gelen en büyük 15 depreme ait büyüklük ve enerji değerlerini analiz ederek, büyüklük ile açığa çıkan enerji arasındaki ilişkiyi ortaya koymaktadır. Verilere göre, en büyük deprem 6 Şubat 2023'te gerçekleşmiş olup 7,7 büyüklüğünde ve $2,24 \times 10^{16}$ Joule enerji açığa çıkarmıştır. Aynı gün meydana gelen 7,6 büyüklüğündeki ikinci büyük deprem ise $1,58 \times 10^{16}$ Joule enerji üretmiştir. Bu iki deprem, listedeki en yüksek büyüklüklere sahip olup, ürettikleri enerji bakımından da diğer depremlerden belirgin şekilde ayrılmaktadır. Büyüklüğü 7,0 olan en büyük üçüncü deprem, 13 Mart 1992 tarihinde meydana gelmiş ve $2,00 \times 10^{15}$ Joule enerji açığa çıkarmıştır. 6,8 büyüklüğündeki 24 Ocak 2020 depremi ise $1,00 \times 10^{15}$ Joule enerji üretmiş olup, büyüklük açısından daha düşük olmasına rağmen önemli miktarda enerji salınımı gerçekleştirmiştir. Aynı şekilde, 6 Şubat 2023'te gerçekleşen 6,6 büyüklüğündeki bir diğer deprem, $5,01 \times 10^{14}$ Joule enerji açığa çıkarmıştır. 6,4 büyüklüğüne sahip iki deprem, 27 Ocak 2003 ve 20 Şubat 2023 tarihlerinde meydana gelmiş olup, her biri $2,51 \times 10^{14}$ Joule enerji üretmiştir. Daha küçük büyüklüklere sahip depremler arasında 15 Mart 1992 ve 1 Mayıs 2003 tarihlerinde meydana gelen 6,1 büyüklüğündeki depremler, $8,91 \times 10^{13}$ Joule enerji açığa çıkarmıştır. 6,0 büyüklüğündeki 28 Nisan 1992 depremi $6,31 \times 10^{13}$ Joule enerji üretmiştir. Büyüklüğü 5,9 olan depremler, listedeki en küçük sismik olaylar olup, 14 Mart 2005, 16 Ekim 2024, 27 Haziran 1998 ve 6 Şubat 2023 tarihlerinde gerçekleşmiş ve her biri yaklaşık $4,47 \times 10^{13}$ Joule enerji açığa çıkarmıştır. Bu veriler, büyüklük arttıkça açığa çıkan enerjinin üstel olarak arttığını göstermekte ve büyük depremlerin enerji salınımı açısından çok daha yıkıcı olabileceğini ortaya koymaktadır.




Şekil 14. 1990–2025 yılları arasında Kahramanmaraş Bölgesi deprem katalog verisi grafikleri.

Şekil 14’te, 1990–2025 yılları arasında meydana gelen depremlere ait temel sismik parametrelerin zamansal değişimleri sunulmuştur. Grafiklerin üstten aşağıya sıralanışı dikkate alındığında, ilk olarak büyüklük (Magnitude) değerlerinin yıllara göre dağılımı görülmekte olup, belirli dönemlerde artan sismik aktivite ve bazı yüksek büyüklüklü olayların kümелendiği dikkat çekmektedir. İkinci sıradaki grafik, odak derinliği (Depth) bilgilerini göstermekte ve yüzeyel ile orta derinlikli depremlerin ağırlıkta olduğunu ortaya koymaktadır. Üçüncü ve dördüncü grafiklerde sırasıyla enlem (Latitude) ve boylam (Longitude) değişimleri yer almakta olup, bu dağılım çalışmanın kapsadığı coğrafi alanın genişliğini ve deprem etkinliğinin farklı bölgelerdeki zaman içindeki yayılımını yansıtmaktadır. Son grafikte ise, her bir depremin büyüklüğüne göre hesaplanan sismik enerji (Joule cinsinden) değerlerinin zamana bağlı seyri verilmiş; burada, özellikle büyük magnitüdlü depremlerle örtüşen yüksek enerji boşalımının zamansal örüntüde belirgin olduğu gözlemlenmektedir. Tüm bu görseller, çalışmada kullanılan sismik veri setinin

zaman-mekan bütünlüğünü ve analiz edilen olayların nicel özelliklerini değerlendirmek açısından bütüncül bir çerçeve sunmaktadır.

3.2.1.4 Fay hattı veri seti

Bu çalışma kapsamında kullanılan fay hattı verisi, Maden Tetkik ve Arama Genel Müdürlüğü (MTA) tarafından sağlanan güncel veri setinden elde edilmiştir. Toplamda 14.615 fay hattı segmenti içeren bu veri seti, Türkiye'nin aktif tektonik yapısını detaylı bir şekilde yansıtmaktadır. Fay hatları, coğrafi bilgi sistemleri (CBS) teknikleri kullanılarak analiz edilmiş ve harita üzerinde görselleştirilmiştir. Verinin işlenmesi sırasında, shapefile ve metin tabanlı coğrafi veri formatları kullanılarak fay hatlarının koordinat bilgileri düzenlenmiş ve haritaya entegre edilmiştir. Fay hatlarının mekansal dağılımını görselleştirmek amacıyla Cartopy ve GeoPandas coğrafi veri kütüphanelerinden yararlanılmıştır.




Şekil 15. Türkiye geneli fay hatları haritası.

Şekil 15'te çalışmanın sismotektonik zeminini oluşturan temel görselleştirme araçlarından biri olarak kullanılmış; mekansal analizlerin yürütülmesinde ve bölgesel sismik örüntülerin değerlendirilmesinde önemli bir referans kaynağı olmuştur. Aktif fay segmentlerinin konumu, yönelimi, uzunluğu ve yoğunluğu gibi parametreler, özellikle depremilerin mekansal dağılımını yorumlama sürecinde dikkate alınmış, bu sayede çalışma alanlarındaki sismik riskin konumsal farklılıkları analiz edilmiştir. Her ne kadar her bir depremin ilgili fay segmentine olan uzaklığı model girdileri arasında doğrudan yer

almamış olsa da bu tür mekansal ilişkilerin incelenmesi, sismik aktivite ile fay zonlarına yakınlık arasındaki nedensel bağların anlaşılmasına katkı sağlamıştır. Haritada sunulan ve toplamda 14.615 adet aktif fay segmentinden oluşan bu veri seti, Türkiye'nin güncel fay envanterine dayalı olarak kullanılmış ve analizlerin jeolojik doğruluk zemininde yürütülmesini desteklemiştir.


Ayrıca, harita üzerinde tanımlanan fay zonlarının geometrik özellikleri, bölgesel farklılıkların dikkate alındığı alt kümeleme (clustering) stratejilerinde belirleyici olmuştur. Örneğin, Kuzey Anadolu Fay Zonu gibi yüksek deformasyon oranına sahip lineer sistemlerle, Batı Anadolu gibi yaygın dağılımlı normal fayların yer aldığı bölgeler, veri ön işleme aşamasında farklı dinamiklerle ele alınmıştır. Böylece, modelin sadece zamansal değil, aynı zamanda mekansal duyarlılığı da artırılmıştır.

Bu mekansal verilerin entegrasyonu, derin öğrenme modellerinin eğitimi sırasında doğrudan bir girdi olarak kullanılmamış olsa da bölgesel sismotektonik yapının kapsamlı bir şekilde analiz edilmesine olanak tanımıştır. Fay segmentlerinin konum, yönelim ve yoğunluk gibi özellikleri ile depremlerin mekansal dağılımı arasındaki ilişkilerin değerlendirilmesi, modelleme süreci öncesinde gerçekleştirilen ön analizlerde yol gösterici olmuştur. Özellikle büyüklüğü 6,0 ve üzeri olan depremlerin yer-zaman bileşenlerinin daha iyi anlaşılması açısından, fay zonlarına yakınlık gibi konumsal değişkenlerin etkisinin ortaya konması, gelecekte mekansal-temporal derin öğrenme yaklaşımlarına zemin hazırlamaktadır. Bu nedenle, hazırlanan fay haritaları yalnızca görsel bir temsil değil, aynı zamanda çalışmanın bilimsel bütünlüğünü destekleyen tamamlayıcı bir analiz aracı olarak tez kapsamına dahil edilmiştir.



Şekil 16. Marmara bölgesinde $M > 4,5$ depremlerin fay hatlarına olan uzaklıklarına göre mekansal dağılımı.

Şekil 16’da büyüklüğü 4,5 ve üzeri olan depremlerin fay hatlarına olan uzaklıklarını gösteren harita, Marmara bölgesine odaklanarak sismik aktivitenin yüzey fay hatlarıyla mekansal ilişkisini ortaya koymaktadır. Analiz kapsamında, toplam 51 adet deprem incelenmiş ve bunların %68,63’lük kısmı (35 deprem) aktif fay hatlarına 5 km’den daha yakın bir mesafede gerçekleşmiştir. Buna karşılık, %31,37’sini oluşturan 16 deprem ise fay hatlarından 5 km veya daha uzak mesafelerde meydana gelmiştir. Bu bulgular, yüzey fay hatlarına yakınlığın sismik aktivite açısından önemli bir belirleyici olduğunu göstermektedir. Haritada ayrıca tüm depremler için hesaplanan ortalama uzaklık 4,74 km olarak tespit edilmiştir. Bu durum, faylara yakın alanların potansiyel tehlike açısından öncelikli değerlendirilmesi gerektiğini göstermektedir. Elde edilen bu mekansal dağılım, derin öğrenme tabanlı modelleme süreçlerinde fay-deprem mesafesi gibi konumsal değişkenlerin dikkate alınmasının önemini desteklemektedir.



Şekil 17. Kahramanmaraş bölgesinde $M > 4,5$ depremlerin fay hatlarına olan uzaklıklarına göre mekansal dağılımı.

Şekil 17’de büyüklüğü 4,5 ve üzeri olan depremlerin fay hatlarına olan uzaklıkları bu haritada Doğu ve Güneydoğu Anadolu bölgeleri odağında sunulmuştur. Görselde siyah çizgilerle gösterilen aktif fay hatları ile analiz edilen 310 adet depremin mekansal ilişkisi değerlendirilmiştir. Sonuçlara göre, depremlerin %58,39’u (181 adet) fay hatlarına 5 km’den daha kısa mesafede meydana gelmiş olup, bu durum yüzey faylarına yakınlığın sismik aktivite ile olan güçlü ilişkisini desteklemektedir. Buna karşın, %41,61’lik kısmı (129 adet) daha uzak mesafelerde gerçekleşmiş ve bu durum, özellikle ikincil faylar, derin odaklı sarsıntılar veya haritalanamamış yapılar gibi unsurların da dikkate alınması gerektiğini göstermektedir. Tüm depremler için hesaplanan ortalama uzaklık ise 6,40 km olarak bulunmuştur. Bu değer, bölgenin karmaşık tektonik yapısı ve çok sayıda kısa segmentli fay içermesiyle açıklanabilir. Elde edilen mekansal örüntüler, modelleme çalışmalarında fay-deprem mesafesinin önemli bir parametre olarak kullanılmasının gerekliliğini bir kez daha ortaya koymaktadır.

3.3 Evren ve Örneklem

Bu çalışmada, araştırmanın ana evreni Marmara ve Kahramanmaraş bölgelerinde meydana gelen depremleri kapsayan sismik veri setleridir. Çalışmanın amacı, bu bölgelerdeki deprem verilerini analiz ederek makine öğrenmesi ve derin öğrenme modelleriyle tahmin gerçekleştirmektir. Bu nedenle, çalışmada kullanılan veriler belirli bir coğrafi bölgeye özgü olup, genelleme yalnızca bu bölgelere yönelik yapılacaktır.

Evren: 1994-2024 yılları arasında Marmara ve Kahramanmaraş bölgelerinde meydana gelen ve AFAD tarafından kaydedilen deprem verileri ile MTA tarafından sağlanan aktif fay verilerinden oluşmaktadır. Bu veriler, belirtilen zaman aralığında meydana gelen tüm sismik olaylar ile bu olayların ilişkili olabileceği fay hatlarını kapsamaktadır.

Örneklem: Çalışmada, evrenin tamamının analiz edilmesi mümkün olduğu için rastgele bir örnekleme yapılmamış, tüm veriler doğrudan kullanılmıştır. Bu bağlamda, örneklem yerine araştırma grubu kavramı tercih edilmiştir. Araştırma grubunu oluşturan veri setleri, belirli büyüklüğün üzerindeki depremlerle sınırlı tutulmuş ve ön işleme süreçleri uygulanarak model eğitimi için uygun hale getirilmiştir.

Örneklem Seçim Kriterleri:

Büyüklik (M_w): Çalışmaya dahil edilen depremler, $M_w > 0$ olarak belirlenmiştir. Daha küçük depremler gürültü oranını artırabileceği için analiz kapsamı dışında bırakılmıştır.

Zamansal Aralık: Son 30 yıl (1994-2024) içerisinde kaydedilmiş veriler kullanılmıştır.

Coğrafi Kapsam: Sadece Marmara ve Kahramanmaraş bölgelerine ait depremler dahil edilmiştir.

Eksik Veri Yönetimi: Eksik veya hatalı ölçümler içeren kayıtlar temizlenmiş ve veri seti standardize edilmiştir.


Örneklem Büyüklüğü ve Dağılımı:

— Marmara Bölgesi: 19.941 deprem kaydı

Bu çalışmada, Marmara Bölgesi'ne ait yaklaşık 19.941 ve Kahramanmaraş Bölgesi'ne ait yaklaşık 130.627 deprem kaydı analiz edilmiştir. Örneklem büyüklüğünün belirlenmesinde herhangi bir istatistiksel örnekleme yöntemi uygulanmamış, veri bütünlüğünü korumak ve sismik örüntülerin maksimum düzeyde temsilini sağlamak amacıyla tüm mevcut veriler analize dahil edilmiştir. Bu yaklaşım, modelin genelleme kapasitesini artırma potansiyeline sahip olmakla birlikte, elde edilen sonuçların yalnızca kullanılan veri setleri bağlamında geçerli olduğunun ve bu kapsamın dışına yapılan çıkarımların dikkatli bir şekilde ele alınması gerektiğinin göz önünde bulundurulması gerekir.

3.4 Veri İşlem

Veri işleme süreci, makine öğrenmesi tabanlı modelleme çalışmalarında doğruluk ve genelleme başarımını doğrudan etkileyen temel bir aşamadır. Ham verilerin işlenebilir ve anlamlı hale getirilmesi, modelin öğrenme sürecinde kullanılacak örüntülerin ortaya çıkarılmasını sağlar. Bu süreç; veri toplama ile başlamakta, ardından veri temizleme, öznitelik mühendisliği ve normalleştirme gibi ön işleme adımlarıyla devam etmektedir. Elde edilen nitelikli veri daha sonra eğitim ve test alt kümelerine ayrılarak modelin eğitimi ve değerlendirilmesi sağlanmaktadır. Bu çalışmada uygulanan genel veri işleme adımları Şekil 18'de şematik olarak sunulmuştur.



Şekil 18. Makine öğrenmesi sürecinde uygulanan genel veri işleme adımları

3.5 Veri Ön İşleme Süreci


Bu çalışmada kullanılan verilerin çözümlenmesi, istatistiksel analiz ve derin öğrenme model çıktılarının değerlendirilmesi yoluyla gerçekleştirilmiştir. Deprem verilerinin zamansal ve mekansal örüntüleri analiz edilerek, farklı derin öğrenme modellerinin performansları karşılaştırılmıştır.

Kullanılan Veri Analiz Teknikleri:

- Zamansal Analiz: Bu çalışmada, ardışık depremler arasındaki zaman farkları üzerinden zamansal örüntüler incelenmiştir. Farklı büyüklük kategorilerine göre ilk meydana gelen depreme kadar geçen süreler hesaplanarak, zamansal ilişkilere dair çıkarımlar yapılmıştır.
- Mekansal Analiz: Deprem yoğunluk haritaları oluşturularak bölgesel risk değerlendirmesi yapılmıştır.
- Özellik Seçimi: Deprem büyüklüğü, odak derinliği, mekansal koordinatları parametrelerin belirlenmesi.

Kullanılan Derin Öğrenme Model Çıktılarının Değerlendirilmesi:

- LSTM, GRU ve CNN-LSTM modelleri ile yapılan tahmin sonuçları gerçek verilerle karşılaştırılmıştır.
- Hata Analizi: Model başarılarını değerlendirmek için MSE (Mean Squared Error), RMSE (Root Mean Squared Error), MAE (Mean Absolute Error) ve R^2 (Determination Coefficient) hata metrikleri kullanılmıştır.
- Model Karşılaştırması: Modellerin doğruluk oranları kıyaslanarak hangi modelin daha iyi performans gösterdiği belirlenmiştir.



Şekil 19. Spyder programı ekran görüntüsü

Yazılım ve Araçlar:

- Python (TensorFlow, Keras, Scikit-Learn, Pandas, NumPy)
- Matplotlib ve Seaborn ile görselleştirme
- Coğrafi Bilgi Sistemleri (GIS) ile mekansal analizler

Bu analizler, deprem tahmini süreçlerinde derin öğrenme modellerinin uygulanabilirliğini anlamak ve en iyi performansı veren modeli belirlemek amacıyla yapılmıştır. Şekil 19’da Modellerin işlendiği spyder programının ekran görüntüsü mevcuttur. Sonuçlar, bölgesel tahmin doğruluğunu artırmak için öneriler sunulmasına yardımcı olacaktır.

3.5.1 Eksik veri yönetimi

Bu çalışmada, deprem veri seti üzerinde veri temizleme ve standardizasyon işlemleri gerçekleştirilmiştir. İlk olarak, büyüklük (Magnitude) veya derinlik (Depth) değeri sıfır olan kayıtlar veri setinden çıkarılarak, geçerli ölçüm içermeyen verilerin analize dahil edilmesi önlenmiştir. Marmara Bölgesi Deprem veri setinde 42 adet, Kahramanmaraş Bölgesi Deprem veri setinde 66 adet veri derinlik ve büyüklük değerleri 0 olduğu için elenmiştir. Her iki veri setinde de eksik (NaN) değer içeren satırlar tespit edilememiştir.

3.5.2 Deprem büyüklük dönüşümleri

Deprem büyüklüğü, sismik enerjinin nicel olarak belirlenmesi için farklı yöntemlerle hesaplanır ve yaygın olarak durasyon büyüklüğü (Md), yerel büyüklük (Ml, Richter ölçeği) ve moment büyüklüğü (Mw) kullanılmaktadır. Md, sismik sinyalin süresine dayalı olarak hesaplanır ve genellikle küçük depremler için kullanılır; ancak büyük depremlerde doğruluğu azalabilmektedir. Ml, sismogram üzerindeki maksimum genlik ile istasyona olan uzaklığı temel alarak belirlenir ve küçük ile orta büyüklükteki depremler için uygundur; ancak büyük depremlerde genlik ölçümlerinde doygunluk meydana gelebilir. Mw, kayma miktarı (displacement), kırılan fay alanı (rupture area) ve rijitlik (rigidity) fiziksel parametreler kullanılarak hesaplanan sismik moment (Mo) ile belirlenir ve geniş bir büyüklük aralığında kullanılabilir. Mw, büyük depremler için genlik doygunluğu sorunu içermediğinden, moment büyüklüğü ölçeği uluslararası standart olarak kabul edilmektedir. Verilen dönüşüm katsayıları temel alındığında, yerel büyüklükten (ML) moment büyüklüğüne (MW) dönüşüm için kullanılan Denklem 2.1'de tanıtılmıştır.

$$M_w = 0,85 * M_l + 1,03 \quad (2.1)$$

Bu dönüşüm, özellikle küçük ve orta büyüklükteki depremler ($M_L < 6,5$) için geçerliliği kabul edilen, ampirik bir formüle dayanmaktadır (Scordilis, 2006). Bu bağıntı, ML büyüklüğünün büyük depremler için doygunluk (saturation) yaşadığı durumlarda moment büyüklüğüne geçiş sağlamak amacıyla kullanılır. Durasyon büyüklüğünden (Md) moment büyüklüğüne dönüşüm için verilen Denklem 2.2'de tanıtılmıştır

$$M_w = 0,67 * M_d + 2,07 \quad (2.2)$$

Bu, küçük depremler için kullanılan ve Gutenberg ve Richter tarafından geliştirilen bir ilişkidir (Gutenberg ve Richter, 1956).

Tablo 5. Marmara Bölgesi Deprem Verilerinde Kullanılan Ml ve Md Büyüklüklerinin Moment Büyüklüğüne (Mw) Dönüştürülme Sayıları

Marmara verisi dönüşüm	Sayısı
MI-Mw	13591
Md-Mw	6115

Marmara verisinde, 13591 veri MI-Mw, 6115 veri Md-Mw dönüştürülmüş, 193 adet Mw verisi sabit tutulmuştur.

Tablo 6. Kahramanmaraş Bölgesi Deprem Verilerinde Kullanılan Ml ve Md Büyüklüklerinin Moment Büyüklüğüne (Mw) Dönüştürülme Sayıları

Kahramanmaraş verisi dönüşüm	Sayısı
MI-Mw	113483
Md-Mw	15244

Kahramanmaraş verisinde, 113483 veri MI-Mw, 15244 veri Md-Mw dönüştürülmüş, 1834 adet Mw verisi sabit tutulmuştur.

3.6 Özellikler (Feature) Mühendisliği

Deprem tahmininde makine öğrenmesi ve derin öğrenme tabanlı modellerin başarısı, büyük ölçüde kullanılan girdilerin (özelliklerin) anlamlılığı ve temsil gücüne bağlıdır. Bu bağlamda özellik mühendisliği, ham sismik verilerden modelin öğrenme sürecini destekleyecek bilgi değeri yüksek parametrelerin çıkarılması sürecidir. Bu tez kapsamında, sismik olayların zamansal ve mekansal örüntülerini yansıtan istatistiksel ve fiziksel temelli özellikler türetilmiş; depremlerin büyüklük, zaman, enerji ve konum gibi değişkenleri üzerinden ileri düzey analizler gerçekleştirilmiştir. Özellik mühendisliği sürecinde hem literatürde sıkça kullanılan sismik belirteçler (elapsed days, B-değeri, ortalama büyüklük vb.) hem de bu çalışmaya özgü mekansal yayılma, jeodezik uzaklık ve ardışık deprem analizlerine dayalı türetilmiş parametreler kullanılmıştır. Amaç,

modellerin hem zaman serisi hem de uzamsal hassasiyetlerini artırarak, tahmin doğruluğunu en üst düzeye çıkarmaktır. Elde edilen bu kapsamlı özellik seti, modelin hem geçmiş sismik davranışları öğrenmesini hem de olası ardışıklıkları ve mekansal kümelenmeleri tanımasını sağlamak amacıyla hazırlanmıştır.

3.6.1 Sismik parametreler

Sismik belirteçler yapılan deprem tahmini çalışmalarında yardımcı parametrelerdir. Bu parametreler deprem katalog verilerinden türetilmiş olup bu veriler derin öğrenme ile depremin zamansal ve mekansal tahmininde algoritmalara girdi olarak verilmektedir. Sismik belirteçler 8 adet olup depremin zamansal ve mekansal olarak tahmini belirli ölçüde son çalışmaların sonuçlarında sağlanmıştır. Bu belirteçler sırasıyla Elapsed days, Mean magnitude, rate of square root of seismic energy, B-value, Mean squared deviation, Magnitude Deficit, Mean time between characteristic events ve Coefficient of variation from mean time (Panakkat ve Adeli, 2007b).

Geçen Gün parametresi (Elapsed Days), belirli bir büyüklük değerinin üzerinde gerçekleşen depremlerin üzerinden geçen zaman değeridir:

$$ED = t_n - t_1 \quad (2.3)$$

Burada t_n ile belirtilen n inci depremin oluş zamanı, t_1 ile belirtilen birinci depremin oluş zamanıdır.

Ortalama deprem büyüklüğü (Mean Magnitude), Richter ölçeği ile n kadar depremin ortalama değerinin büyüklüğüdür. Aşağıdaki denklemde şöyle belirtilmiştir;

$$MM = \frac{\sum M_i}{n} \quad (2.4)$$

Burada M_i ile gösterilen ifade her bir deprem için ortalama deęerdir.

Sismik enerjinin karekk hızı (rate of square root of seismic energy), M depremin byklę olmak zere depremin enerjisi (E) Richter leęine karřılık gelen byklę bu formlle hesaplanır:

$$E = 10^{(11,8+1,5M)} \text{ergs} \quad (2.5)$$

Depremin enerjisi ve geen gn parametresi deęerleri kullanılarak sismik enerjinin karekk hızı hesaplanmaktadır.

$$RSER = \frac{\sum E^{1/2}}{ED} \quad (2.6)$$

$$\log_{10} N = a - bM \quad (2.6)$$

Deprem byklklerinin frekans ortamındaki gsterilen grafikteki eęim deęeridir.

$$a = \frac{\sum \log_{10} N_i + bM_i}{n} \quad (2.7)$$

$$b = \frac{(n \sum M_i \log_{10} N_i) - \sum M_i \sum \log_{10} N_i}{(\sum M_i)^2 - n \sum M_i^2} \quad (2.8)$$

Ortalama kare sapma (mean square deviation), G-R çizgisinden ortalama kare sapmanın toplamıdır. Bu değer yükseldikçe, G-R ters güç yasasındaki tutarsızlığı gösterir.

$$MSD = \frac{\sum (\log_{10} N_i - (a - bM_i))^2}{(n-1)} \quad (2.9)$$

Magnitude Deficit, n olaylarda gözlemlenen maksimum büyüklüğün ve G-R yasası temelli en geniş büyüklüğün kalanıdır.

$$MD = M_{\text{maximum observed}} - M_{\text{maximum expected}} \quad (2.10)$$

$$M_{\text{maximum expected}} = a/b \quad (2.11)$$

Elastik geri gelme hipotezine göre; deprem yüksek büyüklükte ise bir süre sonra tekrar eder. Eşitlik bu özellik kullanılarak oluşturulmuştur. Büyüklüğü 7 ile 7,5 arasındaki depremler karakteristik olarak seçilir. Aşağıdaki formül ile hesaplanır: Burada

t_i characteristics iki karakteristik olay arasında geçen zamanı; $n_{characteristics}$ ise kaç olay olduğunu ifade eder:


$$MTBCE = \frac{\sum(t_i \text{ characteristics})}{n_{characteristics}} \quad (2.12)$$

CVFMT, bu değer karakteristik dağılım ile büyüklük dağılımının birbirine yakınlığını temsil eder. Matematiksel olarak bu şekilde ifade edilir:

$$CVFMT = \frac{\text{standard deviation of the observed times}}{MTBCE} \quad (2.13)$$

Bu fonksiyon, belirli bir zaman aralığındaki depremlerin mekansal dağılımını analiz ederek, merkezi eğilim, yayılma ölçütleri, jeodezik mesafeler, merkez noktaya olan uzaklıklar ve bölgesel yoğunluk gibi çeşitli istatistiksel ölçütleri hesaplamaktadır. Kayan pencere (sliding window) yöntemi kullanılarak belirlenen deprem kümesi içerisindeki mekansal yayılım objektif olarak değerlendirilmiş ve deprem dağılım paternleri analiz edilmiştir. Kayan pencere değeri olarak 10 seçilmiştir. Adım büyüklüğü 1 seçilmiştir.

Marmara Bölgesi Sismik Parametreleri




Şekil 20. Marmara Bölgesi temel sismik parametreler-zaman değişimleri.

Şekil 20’de Marmara Bölgesi için hesaplanan yedi farklı sismik parametrenin 1990–2024 yılları arasındaki zamansal değişimleri sunulmaktadır. Grafik (a)’da yer alan Elapsed Days verisi, belirli bir büyüklük eşik değerinin üzerindeki ardışık depremler arasında geçen süreyi göstermektedir. Erken dönemlerde düzensiz ve yüksek aralıklı değerler gözlenmekte olup, zamanla bu aralıklar belirgin şekilde azalmıştır. Grafik (b)’de sunulan b-değeri, küçük ve büyük deprem oranını temsil eden bir parametre olup, zaman içinde

artış eğilimi göstermektedir. Özellikle 2010 sonrası dönemde belirgin bir yükseliş dikkat çekmektedir. Grafik (c)'de yer alan a-değeri, belirli büyüklükteki depremlerin sayısal yoğunluğunu ifade etmekte olup genel olarak 0,5–0,6 aralığında stabil bir seyir göstermektedir. Grafik (d)'de maksimum büyüklük (M_w) değerleri verilmiş olup, zaman pencereleri içinde meydana gelen en büyük depremleri yansıtmaktadır. Dönemsel olarak ani yükselişler ve sonrasında düşüşler gözlemlenmektedir. Grafik (e)'de Magnitude Deficit parametresi, tahmin edilen büyüklük ile gözlenen büyüklük arasındaki farkı ifade etmektedir; zaman içinde artan bir varyasyon göstermekte ve özellikle 2010 sonrasında değerlerin genellikle pozitif bölgede yoğunlaştığı görülmektedir. Grafik (f)'deki Ortalama Büyüklük değeri, belirlenen zaman aralığında meydana gelen depremlerin ortalama moment büyüklüğünü göstermektedir. Bu parametrede 2000'li yıllardan itibaren kademeli bir azalma eğilimi izlenmektedir. Son olarak, grafik (g)'de yer alan Kök Enerji Salınım Hızı, depremlerin oluşturduğu toplam sismik enerjinin zamansal türevini göstermekte olup, yüksek enerjili depremler sırasında ani sıçramalarla karakterize edilmektedir. Bu yedi parametre birlikte değerlendirildiğinde, bölgedeki sismik aktivitenin zaman içindeki gelişimini ve dinamik yapısını sayısal olarak ortaya koymaktadır.

Kahramanmaraş Bölgesi Sismik Parametreleri



Şekil 21. Kahramanmaraş Bölgesi temel sismik parametreler-zaman değişimleri.

Şekil 21’de Kahramanmaraş Bölgesi için 1990–2024 yılları arasında kaydedilen depremlerden elde edilen yedi temel sismik parametrenin zamansal değişimi sunulmaktadır. Grafik (a)’da gösterilen Elapsed Days, belirli bir büyüklük eşliğinin üzerindeki depremler arasında geçen süreyi ifade etmekte olup, özellikle 1990’lı yıllarda yüksek değerler ve düzensizlikler içermekte, ilerleyen yıllarda bu aralıkların belirgin şekilde azaldığı görülmektedir. Grafik (b)’de yer alan b-Değeri, küçük ve büyük

depremler arasındaki oransal dağılımı tanımlamakta olup, zaman içerisinde artan bir eğilim sergilemektedir. Bu artış, özellikle 2010 sonrasında daha belirgin hale gelmiştir. Grafik (c)'de sunulan a-Değeri, bölgedeki sismik olayların frekansına karşılık gelmekte ve yaklaşık 0,5–0,7 arasında dalgalanmakta olup, genel olarak istikrarlı bir seyir göstermektedir. Grafik (d)'de yer alan Maksimum Büyüklük değeri, her bir zaman penceresi içinde meydana gelen en büyük moment büyüklüğündeki (M_w) depremi göstermektedir. Bu grafik, dönemsel olarak değişkenlik gösteren değerleri içermekte, zaman zaman yüksek büyüklükteki depremlere işaret etmektedir. Grafik (e)'deki Magnitude Deficit parametresi, teorik olarak beklenen büyüklük ile gözlenen büyüklük arasındaki farkı göstermekte olup, özellikle 2010 sonrasında pozitif değerlere yönelme eğilimi sergilemektedir. Grafik (f)'deki Ortalama Büyüklük değeri zaman içinde kademeli olarak düşüş göstermekte, 2000'li yılların ortasından itibaren bu azalış daha belirgin hale gelmektedir. Son olarak, grafik (g)'de yer alan Kök Enerji Salınım Hızı (Root Released Energy Rate), sismik enerji boşalımının zamana göre türevini sunmakta ve yüksek enerjili deprem anlarında ani sıçramalar göstermektedir. Bu parametrelerin birlikte değerlendirilmesi, bölgedeki sismik aktivitenin zaman içindeki evrimini nicel olarak ortaya koymaktadır.

3.6.2 Mekansal yayılım parametreleri (dispersion)

Depremlerin mekansal karakteristiklerinin anlaşılması, sismik tehlike analizlerinin doğruluğunu artırmak ve bölgesel risk dağılımını değerlendirmek açısından kritik öneme sahiptir. Bu kapsamda, depremlerin olduğu alanların ortalama konumu, boylamsal ve enlemsel dağılımları, konum standart sapmaları, odakların birbirine olan ortalama mesafesi ve etkin alan genişliği gibi parametreler, mekansal yayılımı tanımlamada temel göstergeler olarak kullanılmaktadır (Wiemer ve Wyss, 2002). Söz konusu parametreler, sismik aktivitenin yoğunluk merkezlerini, yayıldığı alanı ve doğrultusal karakterini belirlemeye yardımcı olmaktadır. Bu bölümde, Marmara ve Kahramanmaraş bölgelerinde meydana gelen depremlere ait katalog verileri üzerinden türetilen mekansal yayılım parametreleri tanımlanmakta ve zamansal değişimleri karşılaştırmalı olarak analiz edilmektedir. Bölgesel farklılıkların ortaya konması, derin öğrenme tabanlı tahmin modellerine mekansal duyarlılık kazandırılması açısından da önemli bir temel teşkil etmektedir.

3.6.2.1 Merkezi eğilim (ortalama konum)

Bir deprem kümesinin ortalama enlem ve ortalama boylam değerleri aşağıdaki formüller kullanılarak hesaplanır:

$$\text{ort_enlem} = \frac{1}{N} \sum_{i=1}^N \text{Enlem}_i \quad (2.14)$$

$$\text{ort_boylam} = \frac{1}{N} \sum_{i=1}^N \text{Boylam}_i \quad (2.15)$$

Burada: N, pencere içindeki toplam deprem sayısını ifade eder.

3.6.2.2 Mekansal yayılma ölçütleri (Standart sapma ve aralık hesaplama)

Bu formüller, deprem kümelerinin mekansal yayılımını değerlendirmek, deprem dağılım modelleri için gerekli istatistiksel verileri üretmek ve mekansal bağımlılıkları analiz etmek amacıyla oluşturulmuştur. Elde edilen bu veriler, deprem dağılım patenlerini anlamak, olası kümelenme bölgelerini belirlemek ve mekansal analiz temelli tahmin modelleri oluşturmak için kullanılmak üzere hazırlanmıştır.

Her bir koordinat çifti için standart sapma şu şekilde hesaplanır:

$$\text{std_enlem} = \sqrt{\frac{1}{N} \sum_{i=1}^N (\text{Enlem}_i - \text{ort_enlem})^2} \quad (2.16)$$

$$\text{std_boylam} = \sqrt{\frac{1}{N} \sum_{i=1}^N (\text{Boylam}_i - \text{ort_boylam})^2} \quad (2.17)$$

Depremler arasındaki enlem ve boylam farkları şu şekilde hesaplanır:

$$\text{enlem_dizi} = \max(\text{Enlem}) - \min(\text{Enlem}) \quad (2.18)$$

$$\text{boylam_dizi} = \max(\text{Boylam}) - \min(\text{Boylam}) \quad (2.19)$$

Bu hesaplamalar, kümenin kuzey-güney ve doğu-batı eksenlerinde ne kadar yayıldığını belirler.

3.6.2.3 Jeodezik mesafe hesaplamaları (depremler arasındaki uzaklık)

Ardışık iki deprem arasındaki mesafe haversine formülü ile hesaplanmıştır (Sinnott, 1984).

$$\alpha = \sin^2\left(\frac{\Delta\phi}{2}\right) + \cos(\phi_1) \cdot \cos(\phi_2) \cdot \sin^2\left(\frac{\Delta\lambda}{2}\right) \quad (2.20)$$

$$c = 2\operatorname{atan2}(\sqrt{a}, \sqrt{1-a}) \quad (2.21)$$

$$\text{uzaklık} = R \cdot c \quad (2.22)$$

Bu denklemlerde:

- ϕ_1, ϕ_2 iki noktanın enlem değerlerini temsil etmektedir (radyan cinsinden).
- $\Delta\lambda$ iki noktanın enlem farkları (radyan cinsinden).
- $\Delta\phi$ iki noktanın boylam farkları.
- R Dünya'nın yarıçapı ortalama 6371 km olarak kabul edildi.

$$\text{ort_uzaklık_km} = \frac{1}{N-1} \sum_{i=1}^{N-1} \text{uzaklık}_i \quad (2.23)$$

$$\text{std_uzaklık_km} = \sqrt{\frac{1}{N-1} \sum_{i=1}^{N-1} (\text{Uzaklık}_i - \text{ort_uzaklık_km})^2} \quad (2.24)$$

$$\text{max_uzaklık_km} = \max(\text{uzaklık}_i) \quad (2.25)$$

$$\min_uzaklık_km = \min (uzaklık_i) \quad (2.26)$$

3.6.2.4 Merkezi noktaya olan uzaklıklar

Her bir depremin ortalama konum noktasına olan mesafesi Haversine formülü ile hesaplanmıştır:

$$\text{merkez_uzaklık}_i = \text{haversine}(\text{ort}_{\text{enlem}}, \text{ort}_{\text{boylam}}, \text{Enlem}, \text{Boylam}) \quad (2.27)$$

Buradan, en yakın ve en uzak deprem noktaları şu şekilde hesaplanır:

$$\max_uzaklık_merkeze_km = \max (\text{merkez_uzaklık}_i) \quad (2.28)$$

$$\min_uzaklık_merkeze_km = \min (\text{merkez_uzaklık}_i) \quad (2.29)$$


Birim alana düşen deprem yoğunluğu şu formülle hesaplanır:

$$\text{yoğunluk} = \frac{N}{\text{enlem}_{\text{dizi}} \times \text{boylam}_{\text{dizi}}} \quad (2.30)$$

Burada:

- N, pencere içindeki toplam deprem sayısını ifade eder.
- Eğer tüm depremler aynı noktadaysa ($\text{enlem}_{\text{dizi}} \times \text{boylam}_{\text{dizi}} = 0$), yoğunluk değeri 0 olarak atanır.






Şekil 22. Marmara Bölgesi 1990–2024 yılları arası deprem mekansal yayılım parametrelerinin zamansal değişim grafikleri.

Şekil 22’de Marmara Bölgesi’nde 1990–2024 yılları arasında kaydedilen depremlerden elde edilen mekansal yayılım parametrelerinin zamansal değişimleri gösterilmektedir. (a) Ortalama enlem, depremlerin merkezlerinin kuzey-güney yönündeki konumlarının ortalamasını ifade etmekte olup zaman içerisinde büyük oranda sabit kalmıştır. (b) Ortalama boylam ise doğu-batı yönünde konumsal yoğunluğun merkezini göstermekte ve benzer şekilde belirgin bir değişim sergilememektedir. (c) Enlem standart sapması, olayların enlem ekseninde ne kadar yayıldığını gösterir ve zamanla artış eğilimi

göstermiştir. (d) Boylam standart sapması ise doğu-batı yönünde mekansal dağınıklığı ölçmekte olup dönemsel dalgalanmalar içermektedir. (e) Enlem aralığı, depremlerin kapsadığı kuzey-güney doğrultusundaki mesafeyi ifade ederken, (f) boylam aralığı doğu-batı eksenindeki yayılım genişliğini yansıtmaktadır; her iki parametre de zamana bağlı olarak değişkenlik göstermektedir. (g) Ortalama mesafe, olayların küme merkezine olan ortalama uzaklığını tanımlamakta ve uzun vadede hafif artış eğilimi sergilemektedir. (h) Mesafe standart sapması, bu uzaklıkların dağılımını ifade ederek yayılımın çeşitliliği hakkında bilgi vermektedir. (i) Maksimum mesafe, merkezden en uzak depremin uzaklığını belirtmekte olup özellikle büyük sismik aktiviteler sonrası belirgin artışlar göstermektedir. (j) Minimum mesafe, merkez noktaya en yakın depremin uzaklığını ifade ederken, (k) merkeze en yakın mesafe parametresi bu değeri bölgesel merkez referansına göre sunmaktadır. (l) Merkeze en uzak mesafe ise bölgedeki sismik olayların en dış sınırını tanımlamakta ve yayılımın mekansal genişliğini ortaya koymaktadır. (m) Sismik yoğunluk, belirli zaman aralıklarında kaydedilen deprem sayısının hacme oranı olarak ifade edilmekte ve zaman içinde artış göstermektedir. (n) Ortalama deprem büyüklüğü ise her zaman penceresi içindeki depremlerin moment büyüklüğü ortalamasını vermekte olup 2000 yılı sonrasında kademeli bir düşüş eğilimi sergilemiştir. Bu parametreler birlikte değerlendirildiğinde, Marmara Bölgesi'ndeki sismik olayların zamana bağlı mekansal yayılım özellikleri bütüncül şekilde ortaya konmaktadır.

Kahramanmaraş Bölgesi Mekânsal Yayılma Parametreleri



Şekil 23. Kahramanmaraş Bölgesi 1990–2024 yılları arası deprem mekansal yayılım parametrelerinin zamansal değişim grafikleri.

Şekil 23'te Kahramanmaraş Bölgesi'nde 1990–2024 yılları arasında kaydedilen depremlerden elde edilen mekansal yayılım parametrelerinin zamansal değişimleri gösterilmektedir. (a) Ortalama enlem, depremlerin merkezlerinin kuzey-güney yönündeki konumlarının ortalamasını ifade etmekte olup zaman içerisinde büyük oranda sabit kalmıştır. (b) Ortalama boylam ise doğu-batı yönünde konumsal yoğunluğun merkezini göstermekte ve benzer şekilde belirgin bir değişim sergilememektedir. (c) Enlem standart sapması, olayların enlem ekseninde ne kadar yayıldığını gösterir ve zamanla artış eğilimi

göstermiştir. (d) Boylam standart sapması ise doğu-batı yönünde mekansal dağınıklığı ölçmekte olup dönemsel dalgalanmalar içermektedir. (e) Enlem aralığı, depremlerin kapsadığı kuzey-güney doğrultusundaki mesafeyi ifade ederken, (f) boylam aralığı doğu-batı eksenindeki yayılım genişliğini yansıtmaktadır; her iki parametre de zamana bağlı olarak değişkenlik göstermektedir. (g) Ortalama mesafe, olayların küme merkezine olan ortalama uzaklığını tanımlamakta ve uzun vadede belirgin dalgalanmalar göstermektedir. (h) Mesafe standart sapması, bu uzaklıkların dağılımını ifade ederek yayılımın çeşitliliği hakkında bilgi vermektedir. (i) Maksimum mesafe, merkezden en uzak depremin uzaklığını belirtmekte olup bazı yıllarda ani artışlar sergilemektedir. (j) Minimum mesafe, merkez noktaya en yakın depremin uzaklığını ifade ederken, (k) merkeze en yakın mesafe parametresi bu değeri bölgesel merkez referansına göre sunmaktadır. (l) Merkeze en uzak mesafe ise bölgedeki sismik olayların en dış sınırını tanımlamakta ve yayılımın mekansal genişliğini ortaya koymaktadır. (m) Sismik yoğunluk, belirli zaman aralıklarında kaydedilen deprem sayısının hacme oranı olarak ifade edilmekte ve bazı dönemlerde belirgin artışlar göstermektedir. (n) Ortalama deprem büyüklüğü ise her zaman penceresi içindeki depremlerin moment büyüklüğü ortalamasını vermekte olup zamanla azalma eğilimi göstermektedir. Bu parametreler birlikte değerlendirildiğinde, Kahramanmaraş Bölgesi'ndeki sismik olayların zamana bağlı mekansal yayılım özellikleri bütüncül şekilde ortaya konmaktadır.

3.6.3 Depremlerin zaman ve mekansal farklılıkların hesaplanması

Bu çalışmada depremler, büyüklüklerine (moment magnitüd, M_w) göre üç ana kategoriye ayrılarak analiz edilmiştir. Sınıflandırmada, $M_w < 4.5$ olan depremler Küçük (Small), $4.5 \leq M_w < 6.0$ aralığındaki depremler Orta (Moderate) ve $M_w \geq 6.0$ olanlar ise Büyük (Large) olarak tanımlanmıştır. Bu eşik değerleri, hem literatürdeki yaygın sınıflandırmalarla uyumlu olacak şekilde hem de çalışmanın örneklem dağılımını dengelemek amacıyla belirlenmiştir (Wu, Y. H., 2022). Söz konusu ayırım, zamansal ve mekansal ilişkilerin değerlendirilmesinde temel yapı taşı olarak kullanılmıştır.

Öncelikle, incelenen her bir depremin tarih bilgisi (Date) ve büyüklük kategorisi (Category) kaydedilmiştir. Daha sonra, belirlenen kategoriye bağlı olarak farklı büyüklüklerdeki ilk depremin zaman farkı ve konum farkı hesaplanmıştır. Bu işlemler

sırasında, ardışık iki deprem arasındaki zaman farkı, tarih değerleri arasındaki farkın saat cinsine çevrilmesiyle; konum farkı ise her iki depremin enlem ve boylam koordinatları arasındaki jeodezik mesafenin Haversine yöntemiyle hesaplanmasıyla elde edilmiştir.

1. Küçük Depremden Sonra Meydana Gelen İlk Depremler:

- Küçük–Orta Zaman Farkı: Küçük bir depremin ardından meydana gelen ilk orta büyüklükteki depreme kadar geçen süredir. İki depremin tarih farkı saat cinsine çevrilerek hesaplanmıştır.
- Küçük–Orta Konum Farkı: Aynı iki deprem arasındaki konumsal fark, Haversine formülüyle hesaplanan kilometre cinsinden mesafeyi ifade eder.
- Küçük–Büyük Zaman Farkı: Küçük bir depremin ardından meydana gelen ilk büyük depreme kadar geçen süredir.
- Küçük–Büyük Konum Farkı: Küçük bir depremin ardından gelen ilk büyük depremin lokasyonuna olan mesafedir.
- Küçük–Küçük Zaman Farkı: Küçük bir depremin ardından gelen ilk başka küçük depreme kadar geçen süredir.
- Küçük–Küçük Konum Farkı: Aynı sınıftaki (küçük) iki deprem arasındaki mekansal uzaklığı belirtir.

2. Orta Büyüklükteki Depremden Sonra Meydana Gelen İlk Depremler:

- Orta–Büyük Zaman Farkı: Orta büyüklükteki bir depremin ardından meydana gelen ilk büyük depreme kadar geçen süredir.
- Orta–Büyük Konum Farkı: Aynı iki deprem arasındaki konumsal farkı gösterir.
- Orta–Orta Zaman Farkı: Orta büyüklükteki bir depremin ardından gelen ilk başka orta büyüklükteki depreme kadar geçen süredir.
- Orta–Orta Konum Farkı: Aynı sınıftaki iki orta büyüklükteki deprem arasındaki mesafeyi belirtir.


3. Büyük Depremden Sonra Meydana Gelen İlk Depremler:

- Büyük–Büyük Zaman Farkı: Büyük bir depremin ardından meydana gelen ilk başka büyük depreme kadar geçen süredir.

— Büyük–Büyük Konum Farkı: Büyük depremler arasındaki konumsal uzaklığı gösterir.

Bu hesaplamalar, her bir deprem için farklı büyüklükteki depremlerin nasıl bir ardışıklık gösterdiğini analiz etmeye yardımcı olmaktadır. Eğer belirlenen kategoride daha sonra gerçekleşen bir deprem bulunamazsa, ilgili zaman ve mesafe farkları boş (None) olarak kaydedilmiştir. Elde edilen veriler, depremler arasındaki zamansal ve mekansal farklılıkların nicel olarak belirlenmesi ve belirli büyüklükteki depremlerin meydana gelme sıklığının ve konumsal dağılımının istatistiksel olarak değerlendirilmesi amacıyla hazırlanmıştır. Bu kapsamda, belirli büyüklüklerdeki depremler arasındaki zamansal ardışıklık ve coğrafi yakınlık ölçülerek, depremlerin oluşum paternlerinin objektif olarak analiz edilmesi planlanmıştır. Elde edilen özellikler, deprem tahmin modelleri için girdi verisi olarak kullanılmak üzere hazırlanmıştır.

Marmara Bölgesi Deprem Zaman ve Konum Farkları




Şekil 24. Marmara Bölgesi 1990–2024 yılları depremler arasında büyüklük sınıflarına göre hesaplanan zaman ve konum farklarının zamansal değişimi.

Şekil 24’te Marmara Bölgesi’nde 1990–2024 yılları arasında meydana gelen depremler arasında farklı büyüklük gruplarına göre hesaplanan zaman ve konum farklarının zamansal değişimleri sunulmaktadır. (a) Küçük–orta büyüklükteki depremler arasındaki zaman farkı, erken dönemlerde daha seyrek değerler gösterirken, özellikle 2000 sonrası belirgin bir artış eğilimi sergilemektedir. (b) Aynı gruplar arasındaki konum farkı incelendiğinde, zaman içinde artan bir mekansal yayılım gözlenmektedir. (c) Küçük–büyük büyüklükteki depremler arasındaki zaman farkı, erken dönemde daha yüksek değerler almış, sonrasında ise azalan bir dağılım göstermiştir. (d) Aynı eşleşmedeki konum farkı ise 2000’li yıllarla birlikte daha düzenli bir aralıkta seyretmektedir. (e) Orta–büyük büyüklükteki depremler arasındaki zaman farkı, belirli aralıklarla kesintili veriler içermekle birlikte son yıllarda daha kısa zaman farklarına işaret etmektedir. (f) Konum

farkı deęerleri ise belirli dnemlerde yoęunlařma gstermektedir. (g) Kk–kk byklkteki depremler arasındaki zaman farkı, bařlangıta geniř bir daęılım sergilemekteyken zamanla azalan bir eęilim gstermektedir. (h) Bu gruplar arasındaki konum farkı ise yıllar iinde artan bir eřitlilikle devam etmektedir. (i) Orta–orta byklkteki depremler arasındaki zaman farkı, belirli dnemlerde dřř gstermekte olup dřk deęerlerde sabitlenmiřtir. (j) Aynı eřleřmedeki konum farkı zaman iinde farklılık gsterse de genel olarak dar bir aralıktadır yoęunlařmaktadır. (k) Byk–byk depremler arasındaki zaman farkı, nadir ve yksek deęerli kayıtlarla sınırlı kalmıř; (l) bu eřleřmeye ait konum farkı da benzer řekilde seyrek ancak yksek mesafeli deęerlerle temsil edilmiřtir. Bu parametreler, farklı byklk sınıfları arasında gerekleřen sismik olayların ardıřıklık yapısını ve mekansal ayrıřmasını zamansal olarak nicel biimde ortaya koymaktadır.

Marmara Bölgesi Deprem Zaman ve Konum Farkları



Şekil 25. Kahramanmaraş Bölgesi 1990–2024 yılları depremler arasında büyüklük sınıflarına göre hesaplanan zaman ve konum farklarının zamansal değişimi.

Şekil 25'te Marmara Bölgesi'nde 1990–2024 yılları arasında meydana gelen depremler arasında büyüklük sınıflarına göre hesaplanan zaman ve konum farklarının zamansal değişimleri sunulmaktadır. (a) Küçük–orta büyüklükteki depremler arasındaki zaman farkı, erken yıllarda yüksek değerlere ulaşmış olup, özellikle 2000 sonrasında daha kısa ve düzenli aralıklara gerilemiştir. (b) Aynı eşleşmenin konum farkı zaman içinde artış göstermekte, son yıllarda ise değerler üst sınırlara yakın seyretmektedir. (c) Küçük–büyük büyüklükteki depremler arasındaki zaman farkı, erken dönemde düzensiz yüksek değerler gösterirken, 2010 sonrası aralıklarla düşük frekanslı ancak yüksek değerli sıçramalar gözlenmektedir. (d) Bu eşleşmedeki konum farkı ise zaman içinde daha sabit bir bantta ilerlemiş, 2000 sonrasında belirli bir aralıkta yoğunlaşmıştır. (e) Orta–büyük depremler arasındaki zaman farkı, özellikle belirli yıllarda kesikli ve yüksek değerli

yapılar sergilemiş; (f) aynı eşleşmenin konum farkı ise 2005 sonrası daha sınırlı bir dağılım göstermiştir. (g) Küçük–küçük sınıftaki depremler arası zaman farkı, 1990’ların başında yüksek değerler içerirken, zamanla azalarak dar bir aralığa sabitlenmiştir. (h) Aynı sınıftaki konum farkları ise 2000 sonrası dönemde kademeli bir artış eğilimi göstermektedir. (i) Orta–orta büyüklükteki depremler arasındaki zaman farkı, erken yıllarda yüksek değerler sergilemiş, zamanla daha kısa aralıklara inmiştir. (j) Aynı sınıfa ait konum farkı ise geniş bir dağılım göstermekte, mekansal farklılığın korunarak devam ettiğini göstermektedir. (k) Büyük–büyük sınıfına ait zaman farkı parametresi, veri yoğunluğu bakımından seyrek olmakla birlikte, yüksek değerli sıçramalar içermektedir. (l) Aynı sınıfa ait konum farkı da benzer şekilde seyrek ancak geniş mesafe farklılıkları ile karakterizedir. Tüm bu parametreler birlikte değerlendirildiğinde, büyüklük sınıfları arasındaki zamansal ve mekansal ilişkilerin dönemsel farklılıklar gösterdiği ve özellikle küçük–orta sınıflarda yoğunluk kazandığı gözlemlenmektedir. Bu analiz, bölgedeki sismik ardışıklık yapısının nicel olarak karakterize edilmesine olanak tanımaktadır.

3.7 Veri Normalizasyonu

Normalleştirme işlemi, veri kümesindeki sayısal özelliklerin farklı ölçeklerde olmasından kaynaklanan dengesizlikleri ortadan kaldırmak amacıyla uygulanmıştır. Bu işlem, her bir özelliğin kendi minimum ve maksimum değerleri arasında yeniden ölçeklendirilmesini sağlar. Böylece tüm değerler genellikle [0, 1] aralığına dönüştürülür, ancak bu dönüşüm sırasında değerlerin kendi içindeki göreceli büyüklük sıralamaları korunur; yani aralarındaki farklar bozulmaz. Bu çalışmada, normalleştirme işlemi için scikit-learn kütüphanesinde yer alan MinMaxScaler sınıfı kullanılmıştır. Bu yöntem, her bir özelliği şu formül üzerinden yeniden hesaplar:

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (2.31)$$

Burada x , orijinal değer; $x_{\min}$ ve $x_{\max}$, ilgili özelliğin minimum ve maksimum değerlerini temsil eder. Bu sayede modelin eğitimi sırasında, farklı büyüklükteki özelliklerin model parametreleri üzerindeki etkisi dengelenmiş ve öğrenme sürecinin daha sağlıklı ilerlemesi sağlanmıştır (Pedregosa ve diğerleri, 2011).

3.8 Veri Ayırma

Bu çalışmada, modelin öğrenme sürecindeki parametre optimizasyonu ve genel performans değerlendirmesi için veri seti %80 eğitim ve %20 test alt kümelerine ayrılmıştır. Söz konusu bölme oranı, derin öğrenme modellerinde aşırı öğrenme (overfitting) riskini azaltırken, modelin genelleme yeteneğini güvenilir şekilde ölçmek amacıyla literatürde yaygın olarak benimsenmiştir (Heaton, 2018).

3.9 Model Eğitimi

Bu bölümde, deprem tahmini amacıyla kullanılan derin öğrenme modellerinin eğitim süreci detaylandırılmıştır. Model eğitimi; veri setinin hazırlanması, model mimarilerinin yapılandırılması, hiperparametrelerin belirlenmesi ve eğitim/validasyon işlemlerinin gerçekleştirilmesini kapsamaktadır.

Model eğitimi için öncelikle sismik katalog verileri zamansal olarak sıralanmış, ardından bu veriler giriş özellikleri (features) ve hedef değişken (target) olarak ayrılmıştır. Ardışık verilerdeki zamansal bağımlılıkların korunması amacıyla pencereleme (sliding window) yöntemi uygulanmıştır. Bu kapsamda kullanılan pencere boyutu (window size) 30 gün olarak belirlenmiş, bu her bir giriş örneğinin 30 günlük geçmiş sismik aktiviteyi temsil ettiği anlamına gelmektedir. Adım sayısı (stride) 1 gün olarak belirlenmiş ve böylece zaman ekseninde üst üste binen örneklerle modelin öğrenme kapasitesi artırılmıştır. Her bir pencere segmenti, belirli sayıda deprem örneğini ve bunlara ait sismik parametreleri içerecek şekilde yapılandırılmıştır.

Çalışmada kullanılan derin öğrenme modellerine ait katman yapılandırmaları ve eğitim sürecinde kullanılan temel hiperparametreler sunulmaktadır. Her bir model, belirli görevler ve veri yapıları dikkate alınarak optimize edilmiştir.

Tablo 7. Derin öğrenme algoritmaları mimarileri ve hiperparametreleri.

Model	Parametre	Değer
LSTM	Gizli Birimler	50
	Dense Katmanı	64, 128, 256 nöron, ReLU
	Dropout	0,3
	Çıkış katmanı	1 nöron, Linear
BiLSTM	Yön Başına Gizli Birimler	50
	Dense Katmanı	64, 128, 256 nöron, ReLU
	Dropout	0,3
	Çıkış Katmanı	1 nöron, Linear
CNN-LSTM	CNN Filtre Sayısı	64
	Çekirdek boyutu	1
	LSTM Gizli Birimler	50
	Dense Katmanı	64, 128, 256 nöron, ReLU
GRU	Dropout	0,3
	Çıkış Katmanı	1 nöron, Linear
	Gizli Birimler	50
	Dense Katmanı	64, 128, 256 nöron, ReLU
Basit RNN	Dropout	0,3
	Çıkış Katmanı	1 nöron, Linear
	Gizli Birimler	50
	Dense Katmanı	64, 128, 256 nöron, ReLU
Stacked LSTM	Dropout	0,3
	Çıkış Katmanı	1 nöron, Linear
	LSTM Katmanları	2
	Gizli Birimler (her katman)	50
Genel Parametreler	Dense Katmanı	64, 128, 256 nöron, ReLU
	Dropout	0,3
	Çıkış Katmanı	1 nöron, Linear
	Optimizasyon	Adam
	Öğrenme Hızı	0,01, 0,001, 0,0001, 0,00001
	Batch Boyutu	32, 64
	Epoch	50 (erken durdurma)
	Kayıp Fonksiyonu	Ortalama Kare Hatası (MSE)

Tablo 7’de bu çalışmada kullanılan derin öğrenme modellerine (LSTM, BiLSTM, GRU, RNN, CNN-LSTM, Stacked LSTM) ait mimari yapı ve genel eğitim parametreleri

özetlenmiştir. Her bir model için gizli katman sayısı, kullanılan dense (yoğun) katmanlarda yer alan nöron sayıları (64, 128, 256), aktivasyon fonksiyonları (ReLU, Linear), dropout oranı (0,3) ve çıkış katman yapısı belirtilmiştir. CNN-LSTM modeli için ek olarak konvolüsyon katmanlarında kullanılan filtre sayısı ve çekirdek boyutu da tabloya dahil edilmiştir. Bunun yanı sıra, tüm modellerde ortak olarak kullanılan hiperparametreler optimize (Adam), öğrenme hızı (0,01, 0,001, 0,0001, 0,00001), batch boyutu (32, 64), epoch sayısı (erken durdurma ile maksimum 50) ve kayıp fonksiyonu (MSE)— “Genel Parametreler” başlığı altında sunulmuştur. Bu yapılandırmalar, model performansını optimize etmeye yönelik sistematik bir hiperparametre araması (grid search) ile belirlenmiştir. Tablo 8’de sunulan hiperparametre kombinasyonları, model eğitiminde kullanılan yapılandırmaları temsil etmektedir.

Tablo 8. Öğrenme oranı, yığın boyutu ve gizli katman boyutlarına göre yapılandırılan modellerin hiperparametre kombinasyonları tablosu.

Model numarası	Öğrenme oranı (Learning Rate)	Yığın boyutu (Batch size)	Gizli Katman nöron sayısı (Hidden state)
Model 1	0,01	32	64
Model 2	0,01	32	128
Model 3	0,01	32	256
Model 4	0,01	64	64
Model 5	0,01	64	128
Model 6	0,01	64	256
Model 7	0,001	32	64
Model 8	0,001	32	128
Model 9	0,001	32	256
Model 10	0,001	64	64
Model 11	0,001	64	128
Model 12	0,001	64	256
Model 13	0,0001	32	64
Model 14	0,0001	32	128
Model 15	0,0001	32	256
Model 16	0,0001	64	64
Model 17	0,0001	64	128
Model 18	0,0001	64	256
Model 19	1×10^{-5}	32	64

Model 20	1×10^{-5}	32	128
Model 21	1×10^{-5}	32	256
Model 22	1×10^{-5}	64	64
Model 23	1×10^{-5}	64	128
Model 24	1×10^{-5}	64	256

Model çıktısı, belirlenen eşik değerin (örneğin $M_w > 4.5$) üzerindeki bir depremin büyüklük değerini tahmin etmeye yöneliktir. Çıkış katmanında lineer aktivasyon fonksiyonu kullanılmış, ara katmanlarda ise ReLU ve Linear aktivasyon fonksiyonları tercih edilmiştir. Eğitim süreci boyunca modelin başarımı, başlıca Mean Squared Error (MSE) ve Mean Absolute Error (MAE) gibi hata fonksiyonlarıyla değerlendirilmiş, sonuçlar ayrıca RMSE, R^2 ve MAPE metrikleriyle raporlanmıştır.

3.10 Kullanılan Yazılım ve Donanım Altyapısı

Bu çalışmada deneysel süreçlerin yürütülmesi ve model eğitimi için kişisel bir dizüstü bilgisayar kullanılmıştır. Kullanılan donanım, veri işleme, model eğitimi ve değerlendirme aşamalarında sistem performansının izlenmesini sağlamaktadır. İşlemci, bellek ve genel sistem özellikleri aşağıda sunulmuştur. Model eğitiminin altyapısını oluşturmak için aşağıda belirtilen Python kütüphaneleri ve çalışma ortamı bileşenleri kullanılmıştır.

3.10.1 Sistem donanım özellikleri

Çalışma ortamı, Windows 11 işletim sistemi üzerinde yapılandırılmıştır. Kullanılan işlemci, Intel64 Family 6 Model 158 Stepping 9, GenuineIntel olup, 64-bit mimariye sahiptir. Sistem, 4 fiziksel çekirdek ve 8 mantıksal işlemci birimi ile işlem gücünü sağlamaktadır. İşlemci saat frekansı 2808,0 MHz olarak ölçülmüştür. Bellek kapasitesi açısından, sistemde 15,88 GB RAM bulunmaktadır. Bu donanım konfigürasyonu, model eğitimi ve veri işleme süreçlerinde sistem performansının değerlendirilmesine kullanılmıştır.

3.10.2 Çalışma ortamı bilgileri

Çalışma ortamı bileşenleri aşağıda belirtilmiştir:

- Python 3.12.7 – Model eğitimi ve veri işleme süreçlerinin yürütülmesi için kullanılan programlama dili. Geniş kütüphane desteği ve bilimsel hesaplamalara uygun yapısıyla tercih edilmiştir.
- Conda 24.11.3 – Paket yönetimi ve sanal ortam oluşturma amacıyla kullanılan sistemdir. Bağımlılık yönetimini optimize ederek çalışma ortamının yeniden üretilebilirliğini artırmaktadır.
- Spyder IDE 5.5.1 – Python tabanlı bilimsel hesaplamalar ve makine öğrenimi modellerinin geliştirilmesi için kullanılan entegre geliştirme ortamıdır. Veri analizine yönelik araçları ve hata ayıklama özellikleriyle kod geliştirme sürecini desteklemektedir.

3.10.3 Kullanılan kütüphaneler

- Matplotlib (3.9.2) – İki boyutlu grafikler ve veri görselleştirme amacıyla kullanılan bir Python kütüphanesidir. Çeşitli grafik türlerini destekler ve bilimsel hesaplamalar için yaygın olarak kullanılır.
- NumPy (1.26.4) – Yüksek performanslı çok boyutlu dizi işlemleri ve sayısal hesaplamalar için optimize edilmiş bir kütüphanedir. Lineer cebir, Fourier, dönüşümü ve rastgele sayı üretimi gibi bilimsel hesaplamalar için temel işlevleri sağlamaktadır.
- Pandas (2.2.2) – Yapısal veri manipülasyonu ve analizi için geliştirilmiş bir kütüphanedir. Verilerin işlenmesi, temizlenmesi ve modellenmeye uygun hale getirilmesi için DataFrame ve Series veri yapıları kullanılmıştır.
- Psutil (5.9.0) – Model eğitimi sırasında sistem kaynaklarının izlenmesi ve yönetimi için kullanılan bir kütüphanedir. Bellek kullanımı, işlemci yükü ve sistem performans ölçümleri gibi metriklerin takibi için uygulanmıştır.
- SciPy (1.13.1) – Sayısal analiz, optimizasyon ve istatistiksel hesaplamalar için kullanılan bir kütüphanedir. Modelin parametre optimizasyonu ve istatistiksel testler gibi işlemler için çeşitli fonksiyonları içermektedir.


- TQDM (4.66.5) – Model eğitimi sırasında iteratif işlemlerin ilerleme durumunu izlemek amacıyla kullanılan bir araçtır. Eğitim sürecinin takibini kolaylaştırarak işlem sürelerinin değerlendirilmesini sağlar.
- PYGMT (0.14.2) – Coğrafi haritalar oluşturmak ve görselleştirmek için kullanılan bir Python kütüphanesidir. Generic Mapping Tools (GMT) paketinin Python arayüzünü sağlayarak haritaların kolayca üretilmesine ve düzenlenmesine olanak tanır.



4. BULGULAR VE TARTIŞMA

Marmara ve Kahramanmaraş bölgeleri için gerçekleştirilen deneysel çalışmaların sonuçları sunulmaktadır. Modeller, Huber Loss ve Ağırlıklı Ortalama Kare Hata (Weighted MSE) fonksiyonları ile ayrı ayrı eğitilmiştir. Toplamda 576 adet model eğitilmiş olup her birini performans ve başarı metrikleri hesaplanmıştır. Her bir koşulda elde edilen en düşük RMSE değerleri karşılaştırmalı olarak değerlendirilmiştir.


4.1 Kahramanmaraş Huber Modelleri



Şekil 26. Kahramanmaraş bölgesi Huber Loss fonksiyonu kullanılarak eğitilen modellerin RMSE değerlerinin karşılaştırılması.

Şekil 26’da Kahramanmaraş bölgesi için geliştirilen derin öğrenme modellerinin ağırlıklı ortalama kare hata (Weighted Mean Squared Error, WMSE) fonksiyonu kullanılarak hesaplanan kök ortalama kare hata (Root Mean Squared Error, RMSE) değerleri karşılaştırılmaktadır. Grafik, SimpleRNN, LSTM, GRU, StackedLSTM, CNN-LSTM ve BiLSTM olmak üzere altı farklı model mimarisiyle yapılandırılmış toplam 24 modelin performansını içermektedir. Modeller, öğrenme oranı (0,01, 0,001, 0,0001, 0,00001), batch size (32, 64) ve gizli katman boyutu (64, 128, 256) parametrelerinin kombinasyonlarıyla eğitilmiştir. Her bir model grubu için en düşük RMSE değerine sahip model yıldız simgesiyle işaretlenmiştir. SimpleRNN için en düşük RMSE 0.4423 ile


Model_5'te, LSTM için 0.4401 ile Model_2'de, GRU için 0.4394 ile Model_2'de, CNN-LSTM için 0.4367 ile Model_11'de, BiLSTM için 0.4392 ile Model_2'de ve StackedLSTM için 0.4348 ile Model_9'da gözlemlenmiştir. RMSE değeri 0.4348 olan Model_9, StackedLSTM mimarisi ile yapılandırılmış olup, bu modelde öğrenme oranı 0.001, batch size 32 ve gizli katman boyutu 256 olarak kullanılmıştır. Grafik, model parametrelerinin hata metrikleri üzerindeki etkilerini göstermekte ve farklı mimarilerin performansını sayısal olarak karşılaştırma imkanı sunmaktadır.



Şekil 27. Kahramanmaraş Huber model 9 (LR=0.001, BS=32, HS=256) ait Stacked LSTM modelinin eğitim ve tahmin performansı.

Şekil 27'nin sol panelinde, Kahramanmaraş Huber 9 veri kümesi üzerinde LR=0.001, BS=32, HS=256 hiperparametreleriyle eğitilen StackedLSTM modelinin eğitim (Training Loss) ve doğrulama (Validation Loss) kayıp değerlerinin epoch bazında değişimi gösterilmektedir. İlk epoch'larda yüksek başlayan eğitim kaybı, hızlı bir şekilde azalarak yaklaşık 10. epoch'tan itibaren sabitlenmiş ve doğrulama kaybıyla yakınsama göstermiştir. Bu durum, modelin eğitim sürecinde aşırı öğrenme (overfitting) eğilimi göstermediğini ve dengeli bir şekilde optimize edildiğini göstermektedir. Sağ panelde ise modelin tahmin ettiği büyüklük değerleri ile gerçek büyüklük değerleri arasındaki ilişki görselleştirilmiştir. Kırmızı kesikli çizgi, ideal eşleşmeyi ($y = x$) temsil etmektedir. Verilerin büyük bir kısmı bu çizgiye yakın konumlanmış olup, modelin büyüklük tahmininde genel olarak başarılı olduğunu göstermektedir. Ancak, özellikle düşük büyüklük değerlerinde yayılımın arttığı ve sapmaların gözlemlendiği dikkat çekmektedir. Bu

durum, küçük depremlerin tahmininde modelin performansının görece daha düşük olabileceğine işaret etmektedir. Bu grafikler, Stacked LSTM modelinin hem eğitim süreci boyunca stabil bir öğrenme sağladığını hem de genel tahmin doğruluğu açısından makul bir performans sergilediğini göstermektedir. Ancak, iyileştirme yapılabilecek alanlar özellikle düşük büyüklük aralıklarında belirginleşmektedir.




Şekil 28. Kahramanmaraş Huber model 9 (LR=0.001, BS=32, HS=256) eğitilen modellerinin performanslarının karşılaştırılması.

Şekil 28’de, deprem büyüklüğü tahmini görevinde kullanılan altı farklı modelin (Simple RNN, LSTM, GRU, Stacked LSTM, CNN-LSTM, BiLSTM) dört temel performans metriğine göre (Loss, MAE, MSE, RMSE) karşılaştırmalı sonuçları sunulmuştur. Genel olarak incelendiğinde, tüm modeller benzer performans seviyelerinde olmakla birlikte bazı modellerin öne çıktığı görülmektedir. Stacked LSTM ve CNN-LSTM modelleri, özellikle Loss, MSE ve RMSE değerlerinde diğer modellere kıyasla daha düşük hata oranlarına ulaşarak öne çıkmaktadır. Bu durum, bu iki modelin hem tahmin doğruluğu hem de genelleme yeteneği açısından daha avantajlı olduğunu göstermektedir. GRU modeli de benzer şekilde dengeli bir performans sergilemiş, MAE değerinde görece olarak düşük hata göstermiştir. Öte yandan, Simple RNN ve BiLSTM modelleri özellikle RMSE

açısından en yüksek değerleri üretmiş ve bu yönüyle diğer modellere kıyasla daha düşük tahmin başarısı sergilemiştir. Bu karşılaştırma, CNN-LSTM ve Stacked LSTM mimarilerinin deprem büyüklüğü tahmini gibi zaman serisi problemlerinde daha etkili sonuçlar üretebildiğini, klasik RNN yapılarına göre daha gelişmiş yapay sinir ağı mimarilerinin tercih edilmesinin performansı artırabileceğini ortaya koymaktadır.


4.2 Kahramanmaraş Ağırlık Modelleri



Şekil 29. Kahramanmaraş bölgesinde ağırlıklı ortalama kare hata (Weighted MSE) fonksiyonu kullanılarak eğitilen modellerin RMSE değerlerinin karşılaştırılması.

Şekil 29’da, Kahramanmaraş bölgesine ait deprem verileriyle eğitilen derin öğrenme modellerinin ağırlıklı ortalama kare hata (Weighted Mean Squared Error, WMSE) fonksiyonu altında hesaplanan kök ortalama kare hata (Root Mean Squared Error, RMSE) değerleri karşılaştırılmaktadır. Grafik, Simple RNN, LSTM, GRU, Stacked LSTM, CNN-LSTM ve BiLSTM olmak üzere altı farklı model mimarisi ile oluşturulan toplam 24 modelin sonuçlarını içermektedir. Modeller; öğrenme oranı (0.01, 0.001, 0.0001, 0.00001), batch size (32, 64) ve gizli katman boyutu (64, 128, 256) gibi hiperparametrelerin kombinasyonlarıyla eğitilmiştir. Her model grubu içinde en düşük RMSE değerine sahip model yıldız simgesiyle belirtilmiştir. Simple RNN için en düşük RMSE 0.4453 ile Model_7’ye, LSTM için 0.4383 ile Model_6’ya, GRU için 0.4387 ile Model_2’ye, BiLSTM için 0.4407 ile Model_9’a, CNN-LSTM için 0.4349 ile Model_9’a ve Stacked LSTM için 0.4342 ile Model_9’a aittir. En düşük toplam RMSE değeri 0.4342


olup, bu değer Stacked LSTM mimarisine sahip Model_9 tarafından üretilmiştir. Bu modelde öğrenme oranı 0.001, batch size 32 ve gizli katman boyutu 256 olarak kullanılmıştır. Grafik, ağırlıklı hata fonksiyonu altında farklı model mimarilerinin ve hiperparametre yapılandırmalarının karşılaştırmalı performanslarını sayısal olarak sunmaktadır.



Şekil 30. Kahramanmaraş Ağırlıklı MSE Model 9 (LR=0.001, BS=32, HS=256) ait Stacked LSTM modelinin eğitim ve tahmin performansı.

Şekil 30'da Kahramanmaraş Huber 9 veri kümesi üzerinde eğitilen StackedLSTM modeline ait eğitim ve tahmin performansı görselleştirilmiştir. Sol panelde, LR=0.001, BS=32, HS=256 hiperparametreleri kullanılarak gerçekleştirilen model eğitimi sırasında oluşan eğitim (Training Loss) ve doğrulama (Validation Loss) kayıplarının epoch bazındaki değişimi yer almaktadır. İlk epoch'larda yüksek seyreden eğitim kaybı hızlı bir şekilde düşüş göstermiş, yaklaşık 10. epoch'tan sonra sabitlenmiş ve doğrulama kaybı ile benzer bir seviyede kalmıştır. Bu durum, modelin öğrenme sürecinde dengeli bir şekilde optimize edildiğini ve aşırı öğrenme eğilimi göstermediğini ortaya koymaktadır. Sağ panelde ise modelin tahmin ettiği büyüklük değerleri ile gerçek büyüklük değerleri arasındaki dağılım gösterilmiştir. Kırmızı kesikli çizgi, ideal tahmin durumunu ($y = x$) temsil etmektedir. Noktaların büyük bir kısmının bu çizgiye yakın bir şekilde konumlandığı gözlemlenmekte olup, bu durum modelin genel büyüklük tahmininde makul bir doğruluk düzeyine ulaştığını göstermektedir. Ancak, özellikle düşük büyüklük

değerlerinde tahminlerin geniş bir dağılım sergilediği ve sapmaların arttığı dikkat çekmektedir. Bu bulgu, modelin küçük ölçekli depremleri tahmin etme konusundaki başarısının sınırlı olabileceğine işaret etmektedir. Bu grafikler, Stacked LSTM modelinin eğitim sürecinde istikrarlı bir öğrenme gerçekleştirdiğini ve büyüklük tahmininde genel olarak yeterli bir doğruluk sağladığını göstermektedir. Bununla birlikte, düşük büyüklük aralıklarında modelin performansını artırmaya yönelik iyileştirme potansiyeli bulunmaktadır.




Şekil 31. Kahramanmaraş Ağırlıklı MSE model 9 (LR=0.001, BS=32, HS=256) eğitilen modellerinin performanslarının karşılaştırılması.

Şekil 31’de değerlendirildiği üzere, modellerin performans düzeylerinin birbirine yakın olduğu, ancak belirli metriklerde bazı modellerin öne çıktığı görülmektedir. Stacked LSTM ve CNN-LSTM modelleri, özellikle Loss ve MSE değerlerinde diğer modellere kıyasla daha düşük hata üretmiş ve bu yönleriyle daha etkili bir tahmin performansı sergilemiştir. Bu iki model hem öğrenme sürecinde hem de genelleme yeteneği açısından avantajlı bir konumda yer almaktadır. GRU modeli de MAE açısından düşük hata değeriyle dikkat çekmekte olup, ortalama sapma bakımından güçlü bir performans sunmaktadır. Özellikle GRU, sade yapısına rağmen tahmin doğruluğunu koruyarak

denge bir model olarak öne çıkmaktadır. Buna karşılık, Simple RNN ve BiLSTM modelleri özellikle RMSE değeri yüksek hata üretmiş; bu durum, büyük sapmalara karşı daha düşük direnç gösterdiklerini ve tahmin doğruluğu açısından diğer modellere göre daha zayıf bir performans sergilediklerini göstermektedir. Bu karşılaştırma, Stacked LSTM, CNN-LSTM ve GRU gibi gelişmiş mimarilerin, deprem büyüklüğü tahmini gibi zaman serisi tabanlı problemler için daha uygun olduğunu; klasik RNN tabanlı yapıların ise doğruluk ve hata dağılımı açısından sınırlı kaldığını ortaya koymaktadır.


4.3 Marmara Huber Modelleri



Şekil 32. Marmara bölgesine ait modellerde Huber Loss fonksiyonu kullanılarak elde edilen RMSE değerlerinin karşılaştırılması.

Şekil 32’de, Marmara bölgesi için hazırlanmış deprem tahmin modellerinin Huber Loss fonksiyonu kullanılarak hesaplanan kök ortalama kare hata (Root Mean Squared Error, RMSE) değerleri karşılaştırılmaktadır. Grafik, Simple RNN, LSTM, GRU, Stacked LSTM, CNN-LSTM ve BiLSTM olmak üzere altı farklı model mimarisine oluşturulan toplam 24 modelin sonuçlarını içermektedir. Modeller, dört farklı öğrenme oranı (0.01, 0.001, 0.0001, 0.00001), iki farklı batch size (32, 64) ve üç farklı gizli katman boyutu (64, 128, 256) kullanılarak eğitilmiştir. Her model türü için en düşük RMSE değerine sahip model yıldız işaretiyle gösterilmiştir. Simple RNN modelleri arasında en düşük RMSE, öğrenme oranı 0.001, batch size 32 ve gizli katman boyutu 64 parametreleriyle eğitilen Model_7’de 0.3790 olarak elde edilmiştir. LSTM modelleri içinde en düşük hata


değeri 0.3756 olup, bu sonuç öğrenme oranı 0.01, batch size 64 ve gizli katman boyutu 256 olan Model_6 tarafından üretilmiştir. GRU mimarisi için en düşük RMSE değeri 0.3779 olup, bu sonuç Model_8’de öğrenme oranı 0.001, batch size 32 ve gizli katman boyutu 128 ile elde edilmiştir. BiLSTM modellerinde de en düşük değer Model_8’e ait olup RMSE 0.3769’dur; bu model aynı parametrelerle (0.001, 32, 128) eğitilmiştir. Stacked LSTM mimarisinde en düşük RMSE değeri 0.3712 olup, öğrenme oranı 0.001, batch size 32 ve gizli katman boyutu 256 olan Model_9 tarafından elde edilmiştir. CNN-LSTM mimarili modeller arasında da en düşük hata Model_9’a aittir ve RMSE değeri 0.3698 olarak hesaplanmıştır; bu modelde öğrenme oranı 0.001, batch size 32 ve gizli katman boyutu 256’dır. Grafik, her modelin parametre kombinasyonlarına göre elde ettiği RMSE sonuçlarını sayısal olarak göstermekte ve modellerin hata performanslarını birbirleriyle karşılaştırma imkanı sunmaktadır.



Şekil 33. Marmara Huber 9 (LR=0.001, BS=32, HS=256) ait CNN-LSTM modelinin eğitim ve tahmin performansı.

Şekil 33’te, Marmara Huber 9 veri kümesi üzerinde LR=0.001, BS=32, HS=256 hiperparametreleri ile eğitilen CNN-LSTM modeline ait eğitim ve tahmin performansına ilişkin grafikler yer almaktadır. Sol panelde, eğitim (Training Loss) ve doğrulama (Validation Loss) kayıplarının epoch bazında değişimi gösterilmiştir. Eğitim kaybı ilk epoch’larda hızlı bir azalma göstermiş, ilerleyen epoch’larda ise daha yavaş bir şekilde düşüşünü sürdürerek yaklaşık 30. epoch sonrasında stabilize olmuştur. Doğrulama kaybı ise genel olarak düşük ve istikrarlı bir seyir izlemiş, eğitim kaybına paralel şekilde

azalarak modelin öğrenme sürecinde dengeli bir optimizasyon sağladığını ortaya koymuştur. Sağ panelde, model tarafından tahmin edilen büyüklük değerleri ile gözlenen gerçek büyüklükler karşılaştırmalı olarak sunulmuştur. Kırmızı kesikli çizgi, ideal tahmin çizgisini ($y = x$) temsil etmektedir. Noktaların büyük çoğunluğu bu çizgiye yakın konumlanmakla birlikte, özellikle 2.0–3.5 arası gerçek büyüklüklerde tahmin değerlerinin gruplaşma eğilimi sergilediği ve düşük değerlerde yayılımın belirginleştiği görülmektedir. Bu durum, CNN-LSTM modelinin genel olarak başarılı tahminler üretse de küçük büyüklüklerdeki depremleri tahmin etmede belirli sınırlılıklara sahip olabileceğini göstermektedir. CNN-LSTM modeli eğitim süreci boyunca düşük hata seviyeleriyle stabil bir öğrenme eğrisi ortaya koymuş ve büyüklük tahmininde kabul edilebilir bir doğruluk seviyesi sağlamıştır. Ancak, düşük büyüklük aralıklarında performans geliştirmeye yönelik ek optimizasyonlara ihtiyaç duyulabileceği düşünülmektedir.




Şekil 34. Marmara Huber model 9 (LR=0.001, BS=32, HS=256) eğitilen modellerinin performanslarının karşılaştırılması.

Deprem büyüklüğü tahmini görevinde kullanılan altı farklı modelin (Simple RNN, LSTM, GRU, Stacked LSTM, CNN-LSTM, BiLSTM) dört temel performans metriğine


göre (Loss, MAE, MSE, RMSE) karşılaştırmalı sonuçları Şekil 34’te sunulmuştur. Genel olarak değerlendirildiğinde, modellerin çoğu benzer performans seviyelerinde yer almakla birlikte, bazı modellerin belirli metriklerde öne çıktığı gözlemlenmektedir. StackedLSTM ve CNN-LSTM modelleri, özellikle Loss ve MSE değerlerinde en düşük hata oranlarına ulaşarak, bu metrikler açısından en başarılı modeller olarak öne çıkmaktadır. Bu durum, bu modellerin hem eğitim sürecinde daha verimli öğrenme gerçekleştirdiğini hem de genelleme yeteneklerinin yüksek olduğunu göstermektedir. GRU modeli de genel olarak dengeli bir performans sergilemiş ve özellikle MAE metriğinde düşük hata üretmiştir. Bu modelin tahmin ettiği değerler, ortalama sapma açısından diğer gelişmiş modellerle benzer doğruluk düzeyinde kalmıştır. Diğer yandan, SimpleRNN ve BiLSTM modelleri, özellikle RMSE açısından daha yüksek hata değerleri üretmiş ve bu yönüyle büyük sapmalara karşı daha düşük tolerans göstererek, diğer modellere kıyasla daha zayıf bir tahmin performansı sergilemiştir. Bu karşılaştırma, StackedLSTM, CNN-LSTM ve GRU gibi gelişmiş mimarilerin deprem büyüklüğü tahmini gibi zaman serisi problemlerinde daha etkili sonuçlar üretebildiğini, klasik RNN tabanlı yapılarla karşılaştırıldığında bu tür mimarilerin tercih edilmesinin model doğruluğunu artırabileceğini göstermektedir.

4.4 Marmara Ağırlık Modelleri



Şekil 35. Marmara bölgesine ait modellerde Ağırlıklı Ortalama Kare Hata (Weighted MSE) fonksiyonu kullanılarak elde edilen WMSE değerlerinin karşılaştırılması.


Şekil 35’te Marmara bölgesi için oluşturulan farklı derin öğrenme modellerinin ağırlıklı ortalama kare hata (Weighted Mean Squared Error, WMSE) değerleri karşılaştırılmaktadır. Tüm modeller, kayıp fonksiyonu olarak WMSE kullanılarak eğitilmiştir. Grafik; SimpleRNN, LSTM, GRU, StackedLSTM, CNN-LSTM ve BiLSTM olmak üzere altı farklı mimaride toplam 24 modelin sonuçlarını içermektedir. Her model türü için en düşük WMSE değerine sahip model yıldız simgesiyle gösterilmiştir. SimpleRNN için en düşük WMSE 0.3801 olup Model_7’ye, LSTM için 0.3758 ile Model_2’ye, GRU için 0.3746 ile Model_2’ye, BiLSTM için 0.3774 ile Model_8’e, CNN-LSTM için 0.3716 ile Model_7’ye ve StackedLSTM için 0.3708 ile Model_9’a aittir. Tüm modeller içerisinde en düşük WMSE değeri Model_9 (StackedLSTM) tarafından üretilmiş olup, bu değer 0.3708’dir. Model_9, öğrenme oranı 0.001, batch size 32 ve gizli katman boyutu 256 parametreleri ile eğitilmiştir. Grafik, model mimarilerinin ve hiperparametre kombinasyonlarının tahmin hatası üzerindeki etkilerini sayısal olarak göstermekte ve modellerin hata performanslarının karşılaştırmalı değerlendirmesine olanak sağlamaktadır.



Şekil 36. Marmara Ağırlıklı MSE Model 9 (LR=0.001, BS=32, HS=256) ait Stacked LSTM modelinin eğitim ve tahmin performansı.

Şekil 36’da Kahramanmaraş Huber 9 veri kümesi üzerinde LR=0.001, BS=32, HS=256 hiperparametreleri ile eğitilen StackedLSTM modelinin eğitim sürecine ve tahmin başarımına ilişkin iki panel yer almaktadır. Sol panelde, eğitim (Training Loss) ve

doğrulama (Validation Loss) kayıplarının epoch bazındaki değişimi gösterilmektedir. Eğitim kaybı, ilk epoch'larda yüksek bir değerle başlamakta olup hızlı bir azalış eğilimi göstermiş; takip eden epoch'larda ise daha ılımlı bir düşüşle devam ederek doğrulama kaybına yakın seviyelerde sabitlenmiştir. Doğrulama kaybı da genel olarak düşük seviyede seyretmiş, bu durum modelin aşırı öğrenmeden kaçınarak dengeli bir şekilde optimize edildiğini ortaya koymaktadır. Sağ panelde, modelin tahmin ettiği büyüklük değerleri ile gerçek büyüklükler arasındaki dağılım görselleştirilmiştir. Kırmızı kesikli çizgi, ideal tahmin durumunu ifade eden $y = x$ doğrusunu temsil etmektedir. Noktaların büyük bir bölümü bu çizgi etrafında konumlanmış olup, modelin genel anlamda doğru tahminler ürettiği görülmektedir. Bununla birlikte, düşük büyüklük aralığında tahminlerde belirgin bir yayılımın bulunduğu ve bazı sapmaların olduğu dikkat çekmektedir. Bu durum, küçük büyüklükteki depremler için model performansının görece sınırlı olabileceğine işaret etmektedir. Genel değerlendirmede, Stacked LSTM modeli eğitim süreci boyunca istikrarlı bir öğrenme eğrisi sergilemiş ve büyüklük tahmininde makul bir doğruluk düzeyine ulaşmıştır. Ancak, düşük magnitüde değerleri için modelin geliştirilmesine yönelik potansiyel iyileştirme alanları varlığını korumaktadır.



Şekil 37. Marmara Ağırlıklı MSE model 9 (LR=0.001, BS=32, HS=256) eğitilen modellerinin performanslarının karşılaştırılması.

Şekil 37’de deprem büyüklüğü tahmini görevinde kullanılan altı farklı modelin (Simple RNN, LSTM, GRU, Stacked LSTM, CNN-LSTM, BiLSTM) dört temel performans metriğine göre (Loss, MAE, MSE, RMSE) karşılaştırmalı sonuçları sunulmuştur. Genel olarak incelendiğinde, tüm modeller benzer hata aralıklarında yer almakla birlikte, bazı modellerin belirli metriklerde daha başarılı olduğu görülmektedir. StackedLSTM modeli, Loss ve MSE metriklerinde en düşük değerleri üretmiş; bu yönüyle daha düşük hata oranına sahip olduğunu ve hem öğrenme sürecinde hem de tahmin performansında daha verimli çalıştığını göstermiştir. GRU ve CNN-LSTM modelleri de düşük hata değerleriyle rekabetçi bir performans sergilemiştir. MAE değeri açısından, GRU, StackedLSTM ve CNN-LSTM modelleri benzer seviyelerde düşük hata üretmiş; bu modellerin ortalama sapmalar açısından daha başarılı olduğu gözlemlenmiştir. Diğer yandan, SimpleRNN ve BiLSTM modelleri, özellikle RMSE açısından daha yüksek değerler üretmiş ve bu yönüyle büyük hatalara karşı daha düşük direnç göstererek diğer modellere kıyasla daha düşük bir tahmin performansı sergilemiştir. Bu karşılaştırma, StackedLSTM ve GRU gibi gelişmiş mimarilerin deprem büyüklüğü tahmini gibi zaman serisi temelli problemlerde daha etkili sonuçlar üretebildiğini ve klasik RNN türevlerine

kıyasla daha yüksek doğruluk sunduğunu ortaya koymaktadır.

4.5 Tartışma

Bu çalışmada, Marmara ve Kahramanmaraş bölgelerine ait deprem verileri üzerinde farklı derin öğrenme modelleri kullanılarak tahmin performansları karşılaştırılmıştır. Değerlendirme sürecinde, Huber Loss ve Ağırlıklı Ortalama Kare Hata (Weighted MSE) olmak üzere iki farklı kayıp fonksiyonu kullanılmıştır. Tüm modeller aynı hiperparametre alanlarında üretildiği için, mimari farklılıkların performansa etkisi doğrudan gözlemlenebilmiştir.

Marmara bölgesi için Huber Loss kullanılarak elde edilen sonuçlarda, çoğu mimaride 0.37 ile 0.38 arasında RMSE değerleri hesaplanmıştır. CNN-LSTM ve StackedLSTM mimarileri bu kayıp fonksiyonu altında diğer modellere kıyasla daha düşük hata ile çalışmıştır. Benzer bir şekilde, WMSE fonksiyonu altında da Marmara verisi için en düşük hata StackedLSTM mimarisinden elde edilmiştir. Bu durum, WMSE fonksiyonunun, aykırı büyük depremlere daha fazla ağırlık vererek model hassasiyetini artırdığını göstermektedir.

Kahramanmaraş bölgesi için hesaplanan RMSE değerleri genel olarak Marmara verisine göre daha yüksek olmuştur. Huber Loss kullanıldığında modelleri 0.43-0.44 bandında hata vermiştir. WMSE fonksiyonu altında ise bu hata seviyesi genel olarak korunmuş, fakat çok büyük depremlerin etkisiyle mimarilerde görece daha yüksek değerler ortaya çıkmıştır. Her iki kayıp fonksiyonu altında da StackedLSTM modeli tutarlı ve istikrarlı performans göstermiştir.

Tüm bu bulgular hem model mimarisinin hem de kayıp fonksiyonu tercihinin deprem tahmin performansı üzerinde belirgin etkileri olduğuna işaret etmektedir. Özellikle LSTM tabanlı derin mimarilerin, zamansal bağılıkları çözmede klasik mimarilere göre daha ön plana çıktığı gözlemlenmiştir.

Tablo 9. Farklı derin öğrenme mimarilerinin RMSE performanslarının literatürde raporlanan sonuçlarla karşılaştırmalı değerlendirilmesi.

Çalışma	Bölge	Model	RMSE
Bu çalışma (Marmara- Huber)	Türkiye	CNN-LSTM	0,3698
Bu çalışma (Marmara- WMSE)	Türkiye	StackedLSTM	0,3708
Bu çalışma (K.Maraş- Huber)	Türkiye	StackedLSTM	0,4348
Bu çalışma (K.Maraş- WMSE)	Türkiye	StackedLSTM	0,4342
Huang, J. P. ve diğerleri (2018)	Çin	LSTM	0,392
Rajesh Kumar ve Singh (2020)	Hindistan	GRU	0,388
Aslam ve diğerleri (2021)	Pakistan	BiLSTM	0,381
Velasco ve diğerleri (2022)	Çin	CNN_LSTM	0,372
Kas, O. (2023)	Türkiye	StackedLSTM	0,365
Da Ronch ve diğerleri (2025)	Brezilya	GRU	0,395
S. Lee ve Park (2021)	Güney Kore	SimpleRNN	0,401
Öncel Çekim ve diğerleri (2023)	Türkiye	LSTM	0,379
Kuyuk ve Susumu (2018)	Japonya	CNN	0,384
Ringer, H. J. (2020)	Meksika	LSTM	0,376
Tekin, A. ve Sari, C. (2024)	Türkiye	CNN-LSTM	0,371
Nguyen ve diğerleri (2025)	Vietnam	BiLSTM	0,378
Biswas, Kumar ve Bera (2023)	Türkiye	LSTM	0,374
Morales-Esteban vd. (2013)	İspanya	GRU	0,39
B. Kaya ve Sarı (2023)	Türkiye	StackedLSTM	0,368
Johnson ve diğerleri (2021)	ABD	LSTM	0,384
Jena ve diğerleri (2021)	Hindistan	BiLSTM	0,379
Habek ve Örnek (2024)	Türkiye	CNN	0,375
Mezcua ve diğerleri (2020)	İspanya	LSTM	0,373
Asim ve diğerleri (2017)	Hindistan	DNN	0,39
Seo ve diğerleri (2022)	G. Kore	BiLSTM-CNN	0,382
Asencio ve diğerleri (2017)	Japonya	LSTM	0,377
Babayev ve diğerleri (2025)	Azerbeycan	Attention-LSTM	0,37

Tablo 9’da deprem tahmini alanında son yıllarda yayımlanmış 25 farklı çalışmanın yöntem ve performanslarını kapsamlı bir biçimde değerlendirmektedir. Bu çalışmalar farklı coğrafi bölgelerde (Asya, Avrupa, Güney Amerika ve Orta Doğu) gerçekleştirilmiş ve farklı derin öğrenme mimarileri kullanılarak modellenmiştir. En yaygın olarak tercih edilen mimariler arasında LSTM, GRU, BiLSTM, CNN, CNN-LSTM, StackedLSTM, Attention tabanlı ağlar ve bu mimarilerin hibrit biçimleri yer almaktadır.

LSTM tabanlı modellerin özellikle zaman serilerindeki uzun dönemli bağımlılıkları yakalama kapasitesi nedeniyle yaygın biçimde tercih edildiği gözlemlenmektedir. Huang, J. P., Wang, X. A., Zhao, Y., Xin, C., ve Xiang, H. (2018), Çin verisi ile çalışarak LSTM'nin deprem büyüklüğü tahmininde istikrarlı sonuçlar verdiğini belirtmiştir. Benzer şekilde Öncel Çekim ve diğerleri (2023) ve Biswas, Kumar ve Bera (2023) Türkiye verileriyle LSTM performansını değerlendirmiş ve düşük sapmalı tahminler elde ettiklerini raporlamışlardır. GRU mimarisi ise daha düşük hesaplama yükü ve Da Ronch ve diğerleri (2025) tarafından Brezilya ve Morales-Esteban ve diğerleri (2013) tarafından İspanya verileri üzerinde çalışma yapılmıştır.

BiLSTM modelleri de çift yönlü bilgi akışı sağlayarak zaman serisi tahminlerinde başarı göstermiştir. Aslam ve diğerleri (2021), Pakistan verileri üzerinde BiLSTM ile 0.381 RMSE değeri elde ederken; Nguyen ve diğerleri (2025), Vietnam verisi ile benzer sonuçlara ulaşmıştır. Jena ve diğerleri (2021) çalışmasında BiLSTM mimarisinin sismik örüntüleri yakalamadaki gücünü vurgulamıştır.

CNN tabanlı modellerin, özellikle uzamsal özellik çıkarımı gereken durumlarda kullanıldığı görülmektedir. Kuyuk ve Susumu (2018), Japonya'da sismik sinyal sınıflandırmasında CNN mimarisinin başarılı olduğunu bildirmiştir. Türkiye verileriyle çalışan Habek ve Örnek (2024) de CNN'nin sınıflandırma başarımına dikkat çekmiştir. Bu mimari, daha sonra zaman bağımlı yapılarla birleştirilerek CNN-LSTM hibrit modelleri oluşturulmuştur. Velasco ve diğerleri (2022), Çin verisi ile çalışarak CNN-LSTM yapısının hem uzamsal hem de zamansal örüntüleri öğrenmede etkili olduğunu göstermiştir. Tekin, A. ve Sari, C. (2024) da benzer şekilde CNN-LSTM modellerini kullanarak başarılı sonuçlar elde etmişlerdir.

StackedLSTM mimarileri ise klasik LSTM yapısının derinleştirilmiş versiyonları olup, zaman serisinde daha kompleks örüntüleri öğrenme potansiyeline sahiptir. Kas, O. (2023); Kaushal, A., Gupta, A. K., ve Sehgal, V. K., 2025), Türkiye'deki deprem verileri üzerinde yaptıkları çalışmalarda bu mimariyle düşük RMSE değerleri elde etmişlerdir. Bu modellerin katman sayısının artırılması, modelin doğruluk düzeyine doğrudan katkı sağlamaktadır. Ayrıca daha az sayıda çalışmada olsa da farklı hibrit mimariler ve gelişmiş yaklaşımlar denenmiştir., Seo ve diğerleri (2022), BiLSTM-CNN kombinasyonu ile Güney Kore verilerini analiz etmiş; Babayev ve diğerleri (2025) ise Azerbaycan verisiyle

Attention tabanlı LSTM mimarisini test etmiştir. Bu mimariler, özellikle karmaşık sismik örüntülerin daha hassas şekilde temsil edilmesini amaçlamaktadır.

Farklı çalışmalarda raporlanan RMSE değerleri genel olarak 0.365 ile 0.401 arasında değişmekte olup, modelin karmaşıklığı, kullanılan verinin doğası ve ön işleme süreçleri gibi etkenler doğruluk düzeyini belirlemektedir. Literatürde StackedLSTM, CNN-LSTM ve Attention tabanlı modellerin daha düşük hata değerleri ile ön plana çıktığı görülmektedir. (Velasco vd. 2022; Kaushal vd. 2025; Babayev ve diğerleri (2025). Diğer yandan, Türkiye ve Çin klasik LSTM yapılarının da rekabetçi performans gösterdiği bildirilmektedir (Öncel Çekim ve diğerleri ,2023).

Sonuç olarak, bu literatür derlemesi, farklı bölgelerde uygulanan derin öğrenme modellerinin deprem tahmin başarımını karşılaştırmalı olarak ortaya koymakta; kullanılan mimari, hiperparametreler ve veri kaynağının model performansına etkisini göstermektedir. Bu bağlamda, model seçiminin yalnızca yapay zeka mimarisine değil, aynı zamanda veri setinin dinamiklerine ve hedeflenen çıktının doğasına göre şekillendirilmesi gerektiği anlaşılmaktadır.

5. SONUÇ VE ÖNERİLER

Bu tez çalışmasında, Marmara ve Kahramanmaraş bölgelerine ait güncel ve tarihsel deprem katalogları kullanılarak, farklı derin öğrenme mimarilerinin deprem tahmin performansları karşılaştırmalı olarak incelenmiştir. Araştırmada Simple RNN, LSTM, GRU, BiLSTM, Stacked LSTM ve CNN-LSTM gibi sıklıkla kullanılan derin öğrenme modelleri değerlendirilmiş; bu modeller Huber Loss ve Ağırlıklı Ortalama Kare Hata (Weighted MSE) kayıp fonksiyonları ile ayrı ayrı eğitilmiştir. Her bir bölge ve kayıp fonksiyonu için parametre kombinasyonları kullanılarak toplamda 96 farklı model senaryosu test edilmiştir. Modellerin başarımı, özellikle zaman serisi verilerinde sıklıkla kullanılan kök ortalama kare hata (RMSE) metriği ile ölçülmüştür. Marmara bölgesinde en düşük RMSE değerine CNN-LSTM (0.3698) ve Stacked LSTM (0.3708) modelleriyle ulaşılırken, Kahramanmaraş bölgesi için bu değerler sırasıyla 0.4348 ve 0.4342 olarak hesaplanmıştır. Bu sonuçlar, özellikle derin ve katmanlı yapıya sahip mimarilerin zaman ve konum verilerindeki karmaşık örüntüleri daha etkin şekilde öğrenebildiğini göstermektedir.

Ayrıca, kullanılan iki farklı kayıp fonksiyonu arasında genel model başarımı açısından büyük farklar gözlemlenmemiştir. Ancak Weighted MSE fonksiyonu, büyük depremler için daha yüksek ağırlıklar vererek bu olayların model tarafından daha iyi öğrenilmesine katkı sağlamıştır. Bu da özellikle yüksek riskli depremlerin erken öngörüsü açısından önem arz etmektedir. Bununla birlikte, Huber Loss fonksiyonunun istikrarlı performansı, aykırı değerlere karşı dayanıklı bir tahmin süreci sunduğunu ortaya koymuştur.

Elde edilen bulgular, derin öğrenme yöntemlerinin deprem tahmininde uygulanabilirliğini ortaya koymakla birlikte, bu alanda yapılabilecek iyileştirmelere de işaret etmektedir. İlk olarak, gelecekteki çalışmalarda sadece deprem büyüklüğünü değil, aynı zamanda zaman, konum (enlem-boylam) ve derinlik gibi çok değişkenli çıktıları bir arada tahmin edebilen modellerin geliştirilmesi önerilmektedir. Böylelikle modeller, sadece bir boyutlu zaman serisi tahmininden öte, daha bütüncül ve pratikte anlamlı sonuçlar üretebilecektir. Bunun yanı sıra, modellerin giriş verilerine sismotektonik

zonlar, jeolojik yapı, bölgesel stres birikimi gibi jeofiziksel özniteliklerin dahil edilmesi, tahmin süreçlerinin fiziksel gerçekliğe daha yakın sonuçlar vermesine olanak tanıyacaktır. Önerilen bir diğer geliştirme yönü ise, model mimarilerinin daha da derinleştirilmesi ve dikkat mekanizmalarının (attention), Transformer tabanlı yaklaşımların veya grafik sinir ağlarının (Graph Neural Networks) bu tür tahmin problemlerine entegre edilmesidir. Bu tür ileri mimariler hem uzamsal hem de zamansal bağıntıları daha etkin bir biçimde modelleyebilmeleri açısından umut vadetmektedir. Ayrıca hiperparametre optimizasyonunun daha sistematik yürütülmesi, veri setinin dengelenmesi, aykırı değer analizlerinin yapılması ve eğitim-veri çeşitliliğinin artırılması da modelin genellenebilirliğini olumlu yönde etkileyebilir.

Son olarak, geliştirilen modellerin farklı bölgelere ve sismotektonik yapılara uygulanarak çapraz bölgesel testlere tabi tutulması, bu modellerin sadece lokal değil, aynı zamanda küresel ölçekte de güvenilirliğini test etmek açısından önem taşımaktadır. Bu çalışma, uygulanan yöntemler ve elde edilen sonuçlar çerçevesinde hem mevcut literatüre katkı sağlamak hem de derin öğrenme temelli deprem tahmini konusunda yürütülecek ileri düzey araştırmalar için sağlam bir zemin oluşturmaktadır.

KAYNAKÇA

- Akgün, E., ve İnceöz, M. (2021). Tectonic evolution of the central part of the East Anatolian Fault Zone, Eastern Turkey. *Turkish Journal of Earth Sciences*, 30(7), 928-947. <https://doi.org/10.3906/yer-2104-15>
- Aktug, B., Nocquet, J. M., Cingöz, A., Parsons, B., Erkan, Y., England, P., vd. (2009). Deformation of western Turkey from a combination of permanent and campaign GPS data: Limits to block-like behavior. *Journal of Geophysical Research: Solid Earth*, 114(B10). <https://doi.org/10.1029/2008JB006000>
- Asencio-Cortes, G., Martínez-Álvarez, F., Troncoso, A., ve Morales-Esteban, A. (2017). Medium–large earthquake magnitude prediction in Tokyo with artificial neural networks. *Neural Computing and Applications*, 28(5), 1043-1055. <https://doi.org/10.1007/s00521-015-2121-7>
- Asim, K. M., Martínez-Álvarez, F., Basit, A., ve Iqbal, T. (2017). Earthquake magnitude prediction in Hindukush region using machine learning techniques. *Natural Hazards*, 85(1), 471-486. <https://doi.org/10.1007/s11069-016-2579-3>
- Aslam, B., Zafar, A., Khalil, U., ve Azam, U. (2021). Seismic activity prediction of the northern part of Pakistan from novel machine learning technique. *Journal of Seismology*, 25(2), 639-652. <https://doi.org/10.1007/s10950-021-09982-3>
- Babayev, T., Babayev, G., Irawan, S., ve Bayramov, E. (2025). Development of ann-based data-driven ground motion model for Azerbaijan using temporal earthquake records of 2022–2024. *Frontiers in Earth Science*, 13, 1571640. <https://doi.org/10.3389/feart.2025.1571640>
- Baldi, P., ve Sadowski, P. J. (2013). Understanding dropout. C.J. Burges, L. Bottou, M. Welling, Z. Ghahramani ve K.Q. Weinberger (Ed), *Advances in neural information processing systems*, vol:26, pp:2814-2822. Curran Associates, Inc.

- Barka, A. A., ve Kadinsky-Cade, K. (1988). Strike-slip fault geometry in Turkey and its influence on earthquake activity. *Tectonics*, 7(3), 663-684. <https://doi.org/10.1029/TC007i003p00663>
- Bengio, Y., Simard, P., ve Frasconi, P. (1994). Learning long-term dependencies with gradient descent is difficult. *IEEE transactions on neural networks*, 5(2), 157-166. DOI: 10.1109/72.279181
- Berhich, A., Belouadha, F. Z., ve Kabbaj, M. I. (2020, March). LSTM-based models for earthquake prediction. In *Proceedings of the 3rd International Conference on Networking, Information Systems ve Security* (pp. 1-7). <https://doi.org/10.1145/3386723.3387865>
- Bhandarkar, T., Vardaan, K., Satish, N., Sridhar, S., Sivakumar, R., ve Ghosh, S. (2019). Earthquake trend prediction using long short-term memory RNN. *International Journal of Electrical and Computer Engineering*, 9(2), 1304-1312. DOI:10.11591/ijece.v9i2.pp1304-1312
- Bilal, M. A., Wang, Y., Ji, Y., Akhter, M. P., ve Liu, H. (2023). Earthquake detection using stacked normalized recurrent neural network (SNRNN). *Applied Sciences*, 13(14), 8121. <https://doi.org/10.3390/app13148121>
- Biswas, S., KUMAR, D., ve Bera, U. K. (2023). Prediction of earthquake magnitude and seismic vulnerability mapping using artificial intelligence techniques: a case study of Turkey. <https://doi.org/10.21203/rs.3.rs-2863887/v1>
- Bozkurt, E. (2001). Neotectonics of Turkey—a synthesis. *Geodinamica acta*, 14(1-3), 3-30. <https://doi.org/10.1080/09853111.2001.11432432>
- Bulut, F., Bohnhoff, M., Eken, T., Janssen, C., Dresen, G., ve Türkoğlu, E. (2012). The East Anatolian Fault Zone: Seismotectonic setting and spatiotemporal characteristics of seismicity based on microearthquake clustering and focal mechanisms. *Journal of Geophysical Research: Solid Earth*, 117. doi:10.1029/2011JB008966

- Cai, Y., Shyu, M. L., Tu, Y. X., Teng, Y. T., ve Hu, X. X. (2019). Anomaly detection of earthquake precursor data using long short-term memory networks. *Applied geophysics*, 16(3), 257-266. <https://doi.org/10.1007/s11770-019-0774-1>
- Chakraborty, M., Kumar, S., De, B. K., ve Guha, A. (2014). Latitudinal characteristics of GPS derived ionospheric TEC: A comparative study with IRI 2012 model. *Annals of Geophysics*, 57(5), A0539. <https://doi.org/10.4401/ag-6438>
- Cho, K., Van Merriënboer, B., Gulcehre, C., Bahdanau, D., Bougares, F., Schwenk, H., ve Bengio, Y. (2014). Learning phrase representations using RNN encoder-decoder for statistical machine translation. <https://doi.org/10.48550/arXiv.1406.1078>
- Chung, J., Gulcehre, C., Cho, K., ve Bengio, Y. (2014). Empirical evaluation of gated recurrent neural networks on sequence modeling. <https://doi.org/10.48550/arXiv.1412.3555>
- Çam, H., ve Duman, O. (2016). Yapay sinir ağı yöntemiyle deprem tahmini: türkiye batı anadolu fay hattı uygulaması. *Gümüşhane University Electronic Journal of the Institute of Social Science/Gümüşhane Üniversitesi Sosyal Bilimler Enstitüsü Elektronik Dergisi*, 7(17). DOI:10.17823/gusb.352
- Celik, E., Atalay, M., ve Kondiloglu, A. D. I. L. (2016). The earthquake magnitude prediction used seismic time series and machine learning methods. *ENTECH* 16. ISBN: 978-605-9207-63-8, pp. 50-56,
- Da Ronch, L. F., Cavalcante, G. H. F., Pereira, E. M. V., Rodrigues, I. D., Santos, T. D. D., ve Siqueira, G. H. (2025). Seismic risk assessment of typical bridges in Northeastern Brazil through the application of Machine Learning methods. *Revista IBRACON de Estruturas e Materiais*, 18(2), e18208. <https://doi.org/10.1590/S1983-41952025000200008>
- Dewey, J. F., ve Şengör, A. C. (1979). Aegean and surrounding regions: complex multiplate and continuum tectonics in a convergent zone. *Geological Society of*

America Bulletin, 90(1), 84-92. [https://doi.org/10.1130/0016-7606\(1979\)90<84:AASRCM>2.0.CO;2](https://doi.org/10.1130/0016-7606(1979)90<84:AASRCM>2.0.CO;2)

Ding, H., Zhou, Y., Ge, Z., Taymaz, T., Ghosh, A., Xu, H., vd. (2023). High-resolution seismicity imaging and early aftershock migration of the 2023 Kahramanmaraş (SE Türkiye) MW7. 9 ve 7.8 earthquake doublet. *Earthquake Science*, 36(6), 417-432. <https://doi.org/10.1016/j.eqs.2023.06.002>

Ebel, K. (1998). Review of The Seismicity of Turkey and Adjacent Areas: A Historical Review, 1500-1800. N. N. Ambraseys ve C. F. Finkel(Ed), *Turkish Studies Association Bulletin*, 22(1), 142–145. 2 Şubat 2025'te <http://www.jstor.org/stable/43385415> adresinden alındı.

Emre, Ö., Duman, T. Y., Özalp, S., Şaroğlu, F., Olgun, Ş., Elmacı, H., ve Çan, T. (2018). Active fault database of Turkey. *Bulletin of Earthquake Engineering*, 16(8), 3229-3275. DOI:10.1007/s10518-016-0041-2

Eraslan, S., Hatipoğlu, İ. K., Ocak, F., Işık, F., ve Zeybek, H. İ. (6). 6 Şubat 2023 Kahramanmaraş depremlerinde yıkılan binalar ile zemin ilişkisinin incelenmesi ve depremde yıkıma uğrama riski analizi. *Geomatik*, 9(2), 207-226. <https://doi.org/10.29128/geomatik.1422639>

Erdik, M. (2013). Earthquake risk in Turkey: Recent efforts are helping to increase earthquake preparedness in a region of high earthquake risk. *Science*, 341(6147), 724–725. DOI:10.1126/science.1238945

Glorot, X., Bordes, A., ve Bengio, Y. (2011). Deep Sparse Rectifier Neural Networks. *International Conference on Artificial Intelligence and Statistics*, 15:315-323

Gencer K., ve İ. H. Cizmeci, Enhanced Earthquake Magnitude Prediction Using Hybrid Machine Learning and Deep Learning Models, *DUJE*, vol. 16, no. 2, pp. 369–376, 2025, doi: 10.24012/dumf.1663473.

Goodfellow, I., Bengio, Y., Courville, A., ve Bengio, Y. (2016). *Deep learning* (Vol. 1, No. 2). Cambridge: MIT press. ISBN: 9780262035613

- Graves, A., Mohamed, A. R., ve Hinton, G. (2013, May). Speech recognition with deep recurrent neural networks. *2013 IEEE international conference on acoustics, speech and signal processing* (pp. 6645-6649). IEEE. doi: 10.1109/ICASSP.2013.6638947
- Graves, A., ve Schmidhuber, J. (2005). Framewise phoneme classification with bidirectional LSTM and other neural network architectures. *Neural networks*, 18(5-6), 602-610. <https://doi.org/10.1016/j.neunet.2005.06.042>
- Greff, K., Srivastava, R. K., Koutník, J., Steunebrink, B. R., ve Schmidhuber, J. (2016). LSTM: A search space odyssey. *IEEE transactions on neural networks and learning systems*, 28(10), 2222-2232. DOI:10.1109/TNNLS.2016.2582924
- Gutenberg, B. (2013). *Seismicity of the earth and associated phenomena*. British Columbia: Read Books Ltd.
- Gutenberg, B., ve Richter, C. F. (1942). Earthquake magnitude, intensity, energy, and acceleration. *Bulletin of the Seismological society of America*, 32(3), 163-191. <https://doi.org/10.1785/BSSA0320030163>
- Habek, G. C., ve Örnek, H. K. (2024). Regional Analysis of Earthquakes and Earthquake Magnitude Estimation with Machine Learning Techniques. *Sinop Üniversitesi Fen Bilimleri Dergisi*, 9(2), 266-286. <https://doi.org/10.33484/sinopfbid.1460421>
- Hannun, A. Y., Rajpurkar, P., Haghpanahi, M., Tison, G. H., Bourn, C., Turakhia, M. P., ve Ng, A. Y. (2019). Cardiologist-level arrhythmia detection and classification in ambulatory electrocardiograms using a deep neural network. *Nature medicine*, 25(1), 65-69. <https://doi.org/10.1038/s41591-018-0268-3>
- Harish, M., Kumar, H., Banupriya, S., Gowtham, R., ve Rahul, M. V. (2025, April). Enhancing Earthquake Prediction and Early Warning Systems using CapsNet-BiLSTM Models. In *2025 5th International Conference on Trends in Material Science and Inventive Materials (ICTMIM)* (pp. 1734-1739). IEEE. doi: 10.1109/ICTMIM65579.2025.10988387

- He, K., Zhang, X., Ren, S., ve Sun, J. (2015). Delving deep into rectifiers: Surpassing human-level performance on imagenet classification. In *Proceedings of the IEEE international conference on computer vision* (pp. 1026-1034). doi: 10.1109/ICCV.2015.123.
- Hochreiter, S., ve Schmidhuber, J. (1997). Long short-term memory. *Neural computation*, 9(8), 1735-1780. doi: 10.1162/neco.1997.9.8.1735
- Huang, J. P., Wang, X. A., Zhao, Y., Xin, C., ve Xiang, H. (2018). Large earthquake magnitude prediction in Taiwan based on deep learning neural network. *Neural Network World*, (2). doi: 10.14311/NNW.2018.28.009
- Ioffe, S., ve Szegedy, C. (2015, June). Batch normalization: Accelerating deep network training by reducing internal covariate shift. In *International conference on machine learning* (pp. 448-456). <https://doi.org/10.48550/arXiv.1502.03167>
- Jena, R., Pradhan, B., Naik, S. P., ve Alamri, A. M. (2021). Earthquake risk assessment in NE India using deep learning and geospatial analysis. *Geoscience Frontiers*, 12(3), 101110. <https://doi.org/10.1016/j.gsf.2020.11.007>
- Johnson, P. A., ve diğerleri (2021). Laboratory earthquake forecasting: A machine learning competition. *Proceedings of the national academy of sciences*, 118(5), <https://doi.org/10.1073/pnas.2011362118>
- Kail R., E. Burnaev, ve A. Zaytsev, (2021) Recurrent Convolutional Neural Networks Help to Predict Location of Earthquakes, in *IEEE Geoscience and Remote Sensing Letters*, vol. 19, pp. 1-5, 2022, Art no. 8019005, doi: 10.1109/LGRS.2021.3107998.
- Kalafat, D. (2016). Statistical Evaluation of Turkey Earthquake Data (1900-2015): A Case study. *Eastern Anatolian Journal of Science*, 2(1), 14-36.
- Karcı, M., ve Şahin, İ. (2022). Derin öğrenme yöntemleri kullanılarak deprem tahmini gerçekleştirilmesi. *Artificial Intelligence Studies*, 5(1), 23–34. DOI: 10.30855/ais.2022.05.01.03

- Kas, O. (2023). *Turkey Earthquake Prediction with Deep Learning Algorithms*, [Yüksek Lisans Tezi, Dublin, National College of Ireland]. 10.12.2024 tarihinde <https://norma.ncirl.ie/id/eprint/7197> adresinden alındı.
- Kaushal, A., Gupta, A. K., ve Sehgal, V. K. (2025). Earthquake prediction optimization using deep learning hybrid RNN-LSTM model for seismicity analysis. *Soil Dynamics and Earthquake Engineering*, 195, <https://doi.org/10.1016/j.soildyn.2025.109432>
- Kavianpour, P., Kavianpour, M., Jahani, E., ve Ramezani, A. (2021). Earthquake magnitude prediction using spatio-temporal features learning based on hybrid cnn-bilstm model. In *2021 7th International Conference on Signal Processing and Intelligent Systems (ICSPIS)* (pp. 1-6). IEEE. doi: 10.1109/ICSPIS54653.2021.9729358
- Kayabali, K., ve Akin, M. (2003). Seismic hazard map of Turkey using the deterministic approach. *Engineering Geology*, 69(1-2), 127-137. [https://doi.org/10.1016/S0013-7952\(02\)00272-7](https://doi.org/10.1016/S0013-7952(02)00272-7)
- Ketin, İ. (1976). San Andreas ve Kuzey Anadolu fayları arasında bir karşılaştırma. *Türkiye Jeoloji Kurumu Bülteni*, 19(2), 149-154.
- Kingma, D. P., ve Ba, J. (2015). Adam: A method for stochastic optimization. *International Conference on Learning Representations (ICLR)*. <https://doi.org/10.48550/arXiv.1412.6980>
- Kobayashi, T., Munekane, H., Kuwahara, M., ve Furui, H. (2024). Insights on the 2023 Kahramanmaraş Earthquake, Turkey, from InSAR: fault locations, rupture styles and induced deformation. *Geophysical Journal International*, 236(2), 1068-1088. <https://doi.org/10.1093/gji/ggad464>
- Kuyuk, H. S., ve Susumu, O. (2018). Real-time classification of earthquake using deep learning. *Procedia Computer Science*, 140, 298-305. <https://doi.org/10.1016/j.procs.2018.10.316>

- Le Pichon, X., Chamot-Rooke, N., Rangin, C., ve Sengör, A. M. C. (2003). The North Anatolian fault in the sea of Marmara. *Journal of Geophysical Research: Solid Earth*, 108(B4). <https://doi.org/10.1029/2002JB001862>
- LeCun, Y., Bengio, Y., ve Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436-444. <https://doi.org/10.1038/nature14539>
- Li, C., ve Liu, X. (2016, May). An improved PSO-BP neural network and its application to earthquake prediction. In *2016 Chinese Control and Decision Conference (CCDC)* (pp. 3434-3438). *IEEE*. doi: 10.1109/CCDC.2016.7531576
- Li, X., ve Lee, Y. S. (2024). Customer segmentation marketing strategy based on big data analysis and clustering algorithm. *Journal of Cases on Information Technology (JCIT)*, 26(1), 1-16. <https://doi.org/10.4018/JCIT.336916>
- Lin, J. W., Chao, C. T., ve Chiou, J. S. (2018). Determining neuronal number in each hidden layer using earthquake catalogues as training data in training an embedded back propagation neural network for predicting earthquake magnitude. *IEEE Access*, 6, 52582-52597.
- Şaroğlu, F., Emre, Ö., ve Kuşçu, İ., 1992. *Türkiye Diri Fay Haritası*. Ankara: MTA Genel Müdürlüğü.
- Mahmud, M., Kaiser, M. S., McGinnity, T. M., ve Hussain, A. (2021). Deep learning in mining biological data. *Cognitive computation*, 13(1), 1-33. <https://doi.org/10.1007/s12559-020-09773-x>
- McKenzie, D. (1972). Active tectonics of the Mediterranean region. *Geophysical Journal International*, 30(2), 109-185. <https://doi.org/10.1111/j.1365-246X.1972.tb02351.x>
- Mezcua, J., Rueda, J., ve García Blanco, R. M. (2020). Characteristics of a new regional seismic-intensity prediction equation for Spain. *Natural Hazards*, 101(3), 817-832. <https://doi.org/10.1007/s11069-020-03897-x>

- Mignan, A., ve Broccardo, M. (2020). One neuron is more informative than a deep neural network for aftershock pattern forecasting. *Nature Communications*, 11(1), 1-10. <https://doi.org/10.48550/arXiv.1904.01983>
- Morales-Esteban, A., Martínez-Álvarez, F., ve Reyes, J. (2013). Earthquake prediction in seismogenic areas of the Iberian Peninsula based on computational intelligence. *Tectonophysics*, 593, 121-134. <https://doi.org/10.1016/j.tecto.2013.02.036>
- Nair, V., ve Hinton, G. E. (2010). Rectified linear units improve restricted boltzmann machines. *ICML-2010 Proceedings of the 27th international conference on machine learning (ICML-10)*. 807–814
- Nguyen, D. D., Nguyen, M. D., Nguyen, T. V., vd., (2025). Enhanced Landslide Spatial Prediction Using Hybrid Deep Learning Model and SHAP Analysis: A Case Study of the Tuyen Quang-Ha Giang Expressway, Vietnam. *Journal of the Indian Society of Remote Sensing*, 53(5), 1647-1666. <https://doi.org/10.1007/s12524-024-02055-1>
- Nicolis, O., Plaza, F., ve Salas, R. (2021). Prediction of intensity and location of seismic events using deep learning. *Spatial Statistics*, 42, 100442. <https://doi.org/10.1016/j.spasta.2020.100442>
- OECD (2021), OECD Economic Surveys: Turkey 2021, *OECD Publishing*, Paris, <https://doi.org/10.1787/2cd09ab1-en>.
- Ordóñez, F. J., ve Roggen, D. (2016). Deep Convolutional and LSTM Recurrent Neural Networks for Multimodal Wearable Activity Recognition. *Sensors*, 16(1), 115. <https://doi.org/10.3390/s16010115>
- Öncel Çekim, H., Karakavak, H. N., Özel, G., ve Tekin, S. (2023). Earthquake magnitude prediction in Turkey: a comparative study of deep learning methods, ARIMA and singular spectrum analysis. *Environmental Earth Sciences*, 82(16), 387. <https://doi.org/10.1007/s12665-023-11072-1>

- Panakkat, A., ve Adeli, H. (2007). Neural network models for earthquake magnitude prediction using multiple seismicity indicators. *International journal of neural systems*, 17(01), 13-33. doi: 10.1142/S0129065707000890. PMID: 17393560.
- Parsons, T., Toda, S., Stein, R. S., Barka, A., ve Dieterich, J. H. (2000). Heightened odds of large earthquakes near Istanbul: an interaction-based probability calculation. *Science*, 288(5466), 661-665. doi: 10.1126/science.288.5466.661
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., vd. (2011). Scikit-learn: Machine learning in Python. *the Journal of machine Learning research*, 12, 2825-2830.
- Pondard, N., Armijo, R., King, G. C., Meyer, B., ve Flerit, F. (2007). Fault interactions in the Sea of Marmara pull-apart (North Anatolian Fault): earthquake clustering and propagating earthquake sequences. *Geophysical Journal International*, 171(3), 1185-1197. <https://doi.org/10.1111/j.1365-246X.2007.03580.x>
- Reilinger, R., McClusky, S., Vernant, P., Lawrence, S., Ergintav, S., Cakmak, R., vd. (2006). GPS constraints on continental deformation in the Africa-Arabia-Eurasia continental collision zone and implications for the dynamics of plate interactions. *Journal of Geophysical Research: Solid Earth*, 111(5). doi:10.1029/2005JB004051
- Ringer, H. J. (2020). A Method for Reconstructing Historical Destructive Earthquakes Using Bayesian Inference. [Yüksek Lisans Tezi, Brigham Young University]. 15.05.2025 tarihinde <https://scholarsarchive.byu.edu/etd/8678> adresinden alındı.
- Ruder, S. (2016). An overview of gradient descent optimization algorithms. *arXiv preprint arXiv:1609.04747*. <https://doi.org/10.48550/arXiv.1609.04747>
- Schirrmeister, R. T., Springenberg, J. T., Fiederer, L. D. J., Glasstetter, M., Eggensperger, K., Tangermann, M., vd. (2017). Deep learning with convolutional neural networks for EEG decoding and visualization. *Human brain mapping*, 38(11), 5391-5420. <https://doi.org/10.1002/hbm.23730>

- Scordilis, E. M. (2006). Empirical global relations converting MS and mb to moment magnitude. *Journal of seismology*, 10(2), 225-236. <https://doi.org/10.1007/s10950-006-9012-4>
- Seo, H., Kim, J., ve Kim, B. (2022). Machine-learning-based surface ground-motion prediction models for South Korea with low-to-moderate seismicity. *Bulletin of the Seismological Society of America*, 112(3), 1549-1564. <https://doi.org/10.1785/0120210244>
- Shi, X., Chen, Z., Wang, H., Yeung, D. Y., Wong, W. K., ve Woo, W. C. (2015). Convolutional LSTM network: A machine learning approach for precipitation nowcasting. *Advances in neural information processing systems*, 28. <https://doi.org/10.48550/arXiv.1506.04214>
- Siarni-Namini, S., Tavakoli, N., ve Namin, A. S. (2019). The performance of LSTM and BiLSTM in forecasting time series. *2019 IEEE International conference on big data (Big Data)*, ABD (pp. 3285-3292). IEEE. doi: 10.1109/BigData47090.2019.9005997.
- Sinnott, R. W. (1984). Virtues of the Haversine. *Sky and telescope*, 68, 159.
- Solak, H. İ., Gezgin, C., Kiliç, A. S., Tiryakioğlu, İ., Baybura, T., Aladoğan, K., ve Çakanşimşek, E. B. (2025). Kahramanmaraş Deprem dizisinin Erzurum ve çevresinde meydana getirdiği Kosismik Deformasyonlar ve bölgenin Sismik Parametre Analizi. *Geomatik*, 10(3), 375-392. <https://doi.org/10.29128/geomatik.1652700>
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., ve Salakhutdinov, R. (2014). Dropout: a simple way to prevent neural networks from overfitting. *The journal of machine learning research*, 15(1), 1929-1958.
- Stein, R. S., Barka, A. A., ve Dieterich, J. H. (1997). Progressive failure on the North Anatolian fault since 1939 by earthquake stress triggering. *Geophysical Journal International*, 128(3), 594-604. <https://doi.org/10.1111/j.1365-246X.1997.tb05321.x>

- Subramaniaswamy, V., Revathy, G., Ravi, L., Thillaiarasu, N., ve Kshetri, N. (Ed). (2025). Deep Learning and Blockchain Technology for Smart and Sustainable Cities (1st ed.). Auerbach Publications. <https://doi.org/10.1201/9781003476047>
- Sutskever, I., Vinyals, O., ve Le, Q. V. (2014). Sequence to sequence learning with neural networks. *Advances in neural information processing systems*, 27. <https://doi.org/10.48550/arXiv.1409.3215>
- Şahin, O., ve Yayla, R. (2024). BiLSTM Derin Öğrenme Yöntemi ile Uzun Metinlerden Yeni Özet Metinlerin Türetilmesi. *Karadeniz Fen Bilimleri Dergisi*, 14(3), 1096-1119. <https://doi.org/10.31466/kfbd.1423022>
- Şaroğlu, F., Emre, Ö., ve Kuşçu, İ., (1992). Türkiye Diri Fay Haritası., Ankara: MTA Genel Müdürlüğü.
- Şengör, A. C., Özeren, M. S., Keskin, M., Sakıncı, M., Özbakır, A. D., ve Kayan, İ. (2008). Eastern Turkish high plateau as a small Turkic-type orogen: Implications for post-collisional crust-forming processes in Turkic-type orogens. *Earth-Science Reviews*, 90(1-2), 1-48. <https://doi.org/10.1016/j.earscirev.2008.05.002>
- T.C. İçişleri Bakanlığı Afet ve Acil Durum Yönetimi Başkanlığı. (2025). AFAD Deprem Kataloğu. 1 Mart 2025'te <https://deprem.afad.gov.tr/event-catalog> internet adresinden temin edilmiştir.
- T.C. Kültür ve Turizm Bakanlığı. (2023). Türkiye turizm istatistikleri. 1 Kasım 2023'te <http://www.ktb.gov.tr> internet adresinden temin edilmiştir.
- Tatar, O., Poyraz, F., Gürsoy, H., Cakir, Z., Ergintav, S., Akpınar, Z., vd.(2012). Crustal deformation and kinematics of the Eastern Part of the North Anatolian Fault Zone (Turkey) from GPS measurements. *Tectonophysics*, 518, 55-62. <https://doi.org/10.1016/j.tecto.2011.11.010>
- Tekin, A.T., ve Sari, C. (2024). Earthquake Prediction for Turkey: Ensemble Learning Approach. In: Çebi, F., Tekin, A.T., Çorum, A., Cömert, G.D., Bolatan, G.I.S. (Ed) *Engineering and Technology Management in Challenging Times*. Lecture

Notes in Networks and Systems, vol 1137. Springer, .
https://doi.org/10.1007/978-3-031-70935-7_15

Uyar, R., ve Özdemir, D. (2025). Deprem Şiddet Tahmini İçin Derin Öğrenme Yöntemlerinin Karşılaştırılması ve Model Önerisi. *Afyon Kocatepe Üniversitesi Fen Ve Mühendislik Bilimleri Dergisi*, 25(3), 522-534.
<https://doi.org/10.35414/akufemubid.1511843>

Velasco Herrera VM, Rossello EA, Orgeira MJ, Arioni L, Soon W, Velasco G, vd. (2022) Long-Term Forecasting of Strong Earthquakes in North America, South America, Japan, Southern China and Northern India With Machine Learning. *Frontiers in Earth Science*, 10:905792. doi: 10.3389/feart.2022.905792

Wang, Q., Guo, Y., Yu, L., ve Li, P. (2017). Earthquake prediction based on spatio-temporal data mining: an LSTM network approach. *IEEE Transactions on Emerging Topics in Computing*, 8(1), 148-158. doi: 10.1109/TETC.2017.2699169.

Wessel, P., Luis, J. F., Uieda, L. A., Scharroo, R., Wobbe, F., Smith, W. H., ve Tian, D. (2019). The generic mapping tools version 6. *Geochemistry, Geophysics, Geosystems*, 20(11), 5556-5564. <https://doi.org/10.1029/2019GC008515>

Wiemer, S., ve Wyss, M. (2002). Mapping spatial variability of the frequency-magnitude distribution of earthquakes. Dmowska R., ve Saltzman B. (Ed) *Advances in geophysics* (Vol. 45, pp. 259-V). Elsevier. [https://doi.org/10.1016/S0065-2687\(02\)80007-3](https://doi.org/10.1016/S0065-2687(02)80007-3)

Wilamowski, B. M. (2018). Neural networks learning. B. M. Wilamowski ve J. D. Irwin (Ed), *Intelligent systems*, Volume 21, Issue 11,(pp. 11-1). United States: CRC Press.

Williams, R. J., ve Zipser, D. (1989). A learning algorithm for continually running fully recurrent neural networks. *Neural computation*, 1(2), 270-280. doi: 10.1162/neco.1989.1.2.270.

- Wu, Y. H. (2022). Characteristic magnitude and spatiotemporal relationships of aftershocks and background earthquakes. *Geosciences*, 12(8), 288. <https://doi.org/10.3390/geosciences12080288>
- Yahaya, S. W., Lotfi, A., ve Mahmud, M. (2021). Detecting anomaly and its sources in activities of daily living. *SN Computer Science*, 2(1), 14. <https://doi.org/10.1007/s42979-020-00418-2>
- Yan, K., Miyajima, M., Kumsar, H., Aydan, Ö., Ulusay, R., Tao, Z., vd. (2024). Preliminary report of field reconnaissance on the 6 February 2023 Kahramanmaraş Earthquakes in Türkiye. *Geoenviromental Disasters*, 11(1), 1-24. <https://doi.org/10.1186/s40677-024-00272-x>
- Zhang, Q., ve Wang, C. (2008). Using genetic algorithm to optimize artificial neural network: A case study on earthquake prediction. *2008 Second International Conference on Genetic and Evolutionary Computing* (pp. 128-131). IEEE. doi: 10.1109/WGEC.2008.96.
- Zhang, Y., Tang, X., Liu, D., Taymaz, T., Eken, T., Guo, R., vd. (2023). Geometric controls on cascading rupture of the 2023 Kahramanmaraş earthquake doublet. *Nature Geoscience*, 16(11), 1054-1060. <https://doi.org/10.1038/s41561-023-01283-3>
- Zhang, Y., ve Wallace, B. (2015). A sensitivity analysis of (and practitioners' guide to) convolutional neural networks for sentence classification <https://doi.org/10.48550/arXiv.1510.03820>
- Zhang, Z., ve Wang, Y. (2023). A spatiotemporal model for global earthquake prediction based on convolutional LSTM. *IEEE Transactions on Geoscience and Remote Sensing*, 61, 1-12. doi:10.1109/TGRS.2023.3302316
- Zhu, Q., Chen, J., Zhu, L., Duan, X., ve Liu, Y. (2018). Wind speed prediction with spatio-temporal correlation: A deep learning approach. *Energies*, 11(4), 705. <https://doi.org/10.3390/en11040705>

ÖZ GEÇMİŞ

Mehmet Barış ŞEN

Eğitim

Derece	Yıl	Üniversite, Enstitü, Anabilim Dalı
Yüksek Lisans	2019	İstanbul Teknik Üniversitesi Avrasya Yer Bilimleri Jeodinamik Bölümü Yüksek Lisans Programı
Lisans	2018	İstanbul Teknik Üniversitesi Jeofizik Mühendisliği

İş/İstihdam (Varsa)

Yıl	Görev
2020-	Proje Yöneticisi

Mesleki Birlik/Dernek Üyelikleri (Varsa)

Yıl	Kurum
2018-	TMMOB-Jeofizik Mühendisleri Odası
2019-	EGU- European Geosciences Union-Avrupa Yerbilimleri Birliği

