TÜRK DEPREM ARAŞTIRMA DERGİSİ
TURKISH JOURNAL OF EARTHQUAKE RESEARCH

Utilizing Historical Earthquake Catalogs and GNSS Time Series for Earthquake Prediction via Deep Learning in the Bolu Region

Fulya Battal Samiloglu [1], Veysel Isik [2], Bahadir Aktug [3], Andac Tore Samiloglu [4]

[1] Ministry of Environment, Urbanization and Climate Change, General Directorate of Geographical Information, 06530 Ankara, Türkiye
[2]Ankara University, Department of Geological Engineering, Tectonics Research Group, 06830 Ankara, Türkiye
[3] Ankara University, Department of Geophysical Engineering, 06830 Ankara, Türkiye
[4] Başkent University, Department of Artificial Intelligence Engineering, 06790 Ankara, Türkiye

Keywords
Deep learning, GNSS, LSTM, Stress accumulation, Earthquake prediction, North Anatolian Fault Zone

Highlights
* Stress accumulation modeling using GNSS data
* Earthquake prediction of small and medium-sized earthquakes using LSTM
* Relationship between GNSS movements and seismic activity

Aim
To develop and validate an LSTM-based model that uses GNSS-derived stress time series and historical catalogs to forecast earthquakes in the Bolu region (NAFZ)

Location
This study has been implemented in a field area encompassing the Bolu region along the North Anatolian Fault Zone

Methods
In this study, an LSTM model was trained and validated using GNSS-derived stress time series and historical earthquake catalogs to forecast small-to-moderate earthquakes

Results
Using GNSS-derived stress time series, the LSTM model captured the nonlinear patterns governing the stress–seismicity relationship and achieved comparatively successful forecasts for small-to-moderate earthquakes. Threshold-like behavior was observed: following ~50 → M4.8 (2013), ~62 → M4.9 (2018) and ~70 → M5.2/4.3/3.8 (2021), stress was found to decrease and then build up again.

Supporting Institutions
The authors declared that this study has used no support data from other institutions (AFAD, MTA, HGM)

Financial Disclosure:
The authors declared that this study has received no financial support

Peer-review
Externally peer-reviewed

Conflict of Interest:
The authors have no conflicts of interest to declare

Manuscript
Research Article

Received: 26.05.2025
Revised: 03.08.2025
Accepted: 08.08.2025
Printed: 30.12.2025

DOI
10.46464/tdad.1706258

Content of this journal is licensed under a Creative Commons Attribution 4.0 International Non-Commercial License

Corresponding Author
Fulya Battal Samiloglu
Email: fulya.battal@gmail.com

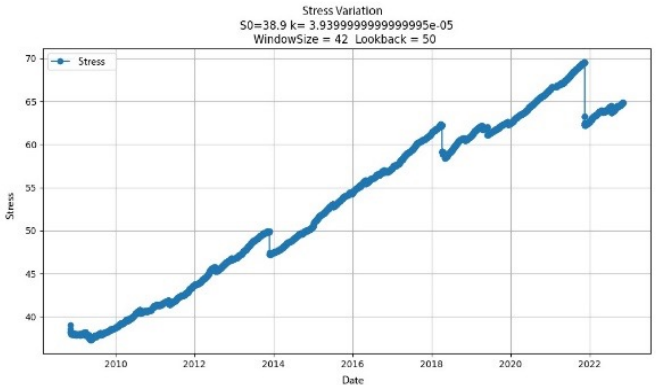


Figure
Model for predicting cumulative seismic values – Stress Change

How to cite:
Samiloglu F.B., Isik V., Aktug B., Samiloglu A.T., 2025. Utilizing Historical Earthquake Catalogs and GNSS Time Series for Earthquake Prediction via Deep Learning in the Bolu Region, Turk Deprem Arastirma Dergisi 7(3), 571-589, DOI:10.46464/tdad.1706258.

TÜRK DEPREM ARAŞTIRMA DERGİSİ
TURKISH JOURNAL OF EARTHQUAKE RESEARCH

Bolu İli Çevresinde Geçmiş Deprem Kataloğu ve GNSS Zaman Serilerinin Derin Öğrenme ile Deprem Tahmininde Kullanımı

Fulya Battal Şamiloğlu [1], Veysel Işık [2], Bahadir Aktuğ [3], Andaç Töre Şamiloğlu [4]

[1] Çevre Şehircilik ve İklim Değişikliği Bakanlığı, Coğrafi Bilgi Sistemleri Genel Müdürlüğü, 06530 Ankara, Türkiye
[2] Ankara Üniversitesi, Jeoloji Mühendisliği Bölümü, Tektonik Araştırma Grubu, 06830 Ankara, Türkiye
[3] Ankara Üniversitesi, Jeofizik Mühendisliği Bölümü, 06830 Ankara Türkiye
[4] Başkent Üniversitesi, Yapay Zeka Mühendisliği Bölümü, 06790 Ankara Türkiye

ÖZET
Bu çalışma, Kuzey Anadolu Fay Zonu üzerindeki Bolu çevresinde, GNSS verileri ve aletsel dönem deprem katalogları kullanılarak LSTM tabanlı bir deprem tahmin modeli geliştirmeyi amaçlamaktadır. GNSS verilerinden hesaplanan stres zaman serileri modele girdi olarak verilmiş ve hiperparametre optimizasyonu ile küçük ve orta büyüklükteki depremler yüksek doğrulukla tahmin edilmiştir. Ancak, çalışma alanında M > 6.0 büyüklüğünde deprem yaşanmamış olması, modelin bu tür büyük olayları öğrenmesini sınırlamıştır. Bulgular, GNSS verilerinin stres birikimini yansıttığını ve LSTM yaklaşımıyla bütünleştirildiğinde anlamlı öngörüler sağladığını ortaya koymuştur. En iyi performansın elde edildiği parametrelerle, bölgedeki stresin 2023 yılı sonunda tekrar 65 birimin üzerine çıktığı ve yaklaşık M>5.0 büyüklüğünde bir depremin olası olduğuna işaret ettiği belirlenmiştir. Elde edilen bulgular, önerilen modelin deprem öngörüsü alanında uygulanabilirliğini ve potansiyel katkısını ortaya koymaktadır.

Anahtar Kelimeler
Derin öğrenme, GNSS zaman serileri, LSTM, Stres birikimi, Deprem tahmini, Kuzey Anadolu Fay Zonu

Öne Çıkanlar
* GNSS verileri ile stres birikimi modellemesi
* LSTM kullanılarak küçük ve orta büyüklükteki depremlerin tahmini
* GNSS hareketleri ile sismik aktivite arasında kurulan ilişki

Makale
Araştırma Makalesi

Geliş: 26.05.2025
Düzeltme: 03.08.2025
Kabul: 08.08.2025
Basım: 30.12.2025

DOI
10.46464/tdad.1706258

Sorumlu yazar
Fulya Battal Şamiloğlu
E-posta:
fulya.battal@gmail.com

Utilizing Historical Earthquake Catalogs and GNSS Time Series for Earthquake Prediction via Deep Learning in the Bolu Region

Fulya Battal Samiloglu [1], Veysel Isik [2], Bahadir Aktug [3], Andac Tore Samiloglu [4]

[1] Ministry of Environment, Urbanization and Climate Change, General Directorate of Geographical Information, 06530 Ankara, Türkiye
[2] Ankara University, Department of Geological Engineering, Tectonics Research Group, 06830 Ankara, Türkiye
[3] Ankara University, Department of Geophysical Engineering, 06830 Ankara, Türkiye
[4] Başkent University, Department of Artificial Intelligence Engineering, 06790 Ankara, Türkiye

ABSTRACT
This study aims to develop an LSTM-based earthquake prediction model using GNSS data and instrumental earthquake catalogs for the Bolu region, located along the North Anatolian Fault Zone. Stress time series derived from GNSS observations were used as model inputs, and with hyperparameter optimization, small and moderate magnitude earthquakes were predicted with high accuracy. However, the absence of earthquakes with magnitude M > 6.0 in the study area limited the model's ability to learn from such large events. The findings demonstrate that GNSS data effectively reflect stress accumulation and, when integrated with the LSTM approach, can yield meaningful predictions. Using the best-performing parameters, the regional stress was observed to rise above 65 units by the end of 2023, indicating the potential for an earthquake of approximately M > 5.0. The results highlight the applicability and potential contribution of the proposed model to earthquake forecasting efforts.

Keywords
Deep learning, GNSS, LSTM, Stress accumulation, Earthquake prediction, North Anatolian Fault Zone

Highlights
* Stress accumulation modeling using GNSS data
* Earthquake prediction of small and medium-sized earthquakes using LSTM
* Relationship between GNSS movements and seismic activity

Manuscript
Research Article

Received: 26.05.2025
Revised: 03.08.2025
Accepted: 08.08.2025
Printed: 30.12.2025

DOI
10.46464/tdad.1706258

Corresponding Author
Fulya Battal Samiloglu
Email:
fulya.battal@gmail.com

1. GİRİŞ

Depremler, dünya genelinde büyük can ve mal kayıplarına yol açan doğa kaynaklı tehlikelerdir. Bu afetlerin zamanlaması ve büyüklüğünün önceden tahmin edilebilmesi, afet risk yönetimi ve erken uyarı sistemlerinin etkinliğini artırmak açısından kritik öneme sahiptir. Özellikle aktif fay zonlarında gerçekleştirilen disiplinler arası çalışmalar, sismik tehlikenin öngörülmesine katkı sağlamakta ve potansiyel risklerin azaltılmasını amaçlamaktadır. Deprem oluşum mekanizmalarının karmaşık doğası nedeniyle, jeofizik, jeodezi, yapay zekâ ve veri bilimi gibi alanları bütüncül şekilde birleştiren yaklaşımlar ön plana çıkmaktadır. Bu bağlamda, Küresel Konumlama Uydu Sistemi (GNSS) verilerinin deprem tahminine yönelik modellere entegrasyonu, son yıllarda önemli bir araştırma alanı haline gelmiştir (Quinteros Cartaya ve diğ. 2025).

GNSS teknolojisi, yer kabuğundaki milimetrik düzeydeki deformasyonları yüksek hassasiyetle ölçebilme kapasitesi sayesinde, aktif tektonik bölgelerde gerinim birikiminin izlenmesini ve fay zonları boyunca stres dağılımının modellenmesini mümkün kılmaktadır (Kreemer ve diğ. 2003). GNSS zaman serilerinin derin öğrenme algoritmalarıyla birlikte değerlendirilmesi ise, deprem büyüklüğü ve olasılığına yönelik tahmin modellerinin geliştirilmesinde etkili olmuştur (Hsu ve Pratomo 2022, Yavaş ve diğ. 2024). Türkiye'nin çeşitli bölgelerinde yapılan uygulamalı araştırmalar da GNSS verilerinin bu potansiyelini doğrulamaktadır. Örneğin, İzmir çevresinde yürütülen çalışmalarda kabuk deformasyonları GPS verileriyle analiz edilerek sismotektonik yapının dinamikleri ortaya konmuştur (Özener ve diğ. 2013). Karlıova Üçlü Bileşimi ve Doğu Anadolu Fay Sistemi üzerine yapılan araştırmalar, GNSS verilerinin sismik boşlukların belirlenmesi ve stres transferinin mekânsal dağılımının izlenmesi açısından güvenilir sonuçlar verdiğini göstermektedir (Kurt ve diğ. 2013, Aktuğ ve diğ. 2016). Bu bulgular, GNSS'nin sadece yer değiştirme izleme aracı olarak değil, aynı zamanda sismik riskin bilimsel temelli öngörülmesinde de stratejik bir veri kaynağı olduğunu göstermektedir.

Bu doğrultuda, GNSS verileriyle elde edilen kabuk deformasyonu ve stres birikimi bilgileri, günümüzde yapay zekâ tabanlı yöntemlerle desteklenerek çok daha etkili analizlerin yapılmasına olanak sağlamaktadır. Yapay zekâ tabanlı yöntemler son yıllarda deprem tahmininde sıkça kullanılmaya başlanmıştır. Özellikle zaman serisi analizlerinde kullanılan uzun kısa süreli bellek (LSTM) ağları, geçmiş verilerden öğrenerek gelecek sismik olayları öngörmede umut vaat etmektedir (Hsu ve Pratomo 2022, Yavaş ve diğ. 2024). Derin öğrenme modellerinin yanı sıra, rastgele orman (Random Forest), destek vektör makineleri (SVM) ve grafik tabanlı sinir ağları gibi yöntemlerle yapılan çeşitli çalışmalar, deprem büyüklüğü ve zamanlaması tahmininde yüksek doğruluk oranları elde edildiğini göstermektedir (Zhang ve diğ. 2019, Banna ve diğ. 2021, Bilal ve diğ. 2022). Bu bağlamda, bu çalışmada önerilen fiziksel stres modeli ile yapay zeka tabanlı LSTM yaklaşımı bir araya getirilerek, hem fiziksel hem de istatistiksel temelli bir deprem tahmin yöntemi sunulmaktadır.

Türkiye'nin en aktif fay zonlarından biri olan Kuzey Anadolu Fay Zonu (KAFZ), yüksek büyüklüklü depremleri üretebilen ve yıkıcı etkileri olan aktif fay zonudur. KAFZ, tarihsel ve aletsel dönemde büyüklüğü (M) 7 ve üzeri çok sayıda deprem üretmiştir (Barka 1996, Şengör ve diğ. 2003, Çağlayan ve diğ. 2019). Bolu yerleşim bölgesinde henüz kırılmamış bir alanın bulunduğu ve bu alanın gelecekte büyük bir deprem riski taşıdığı vurgusu yapılmaktadır (Seyitoğlu ve diğ. 2015). KAFZ üzerinde gerçekleşen büyük depremler, bölgedeki tektonik hareketlerin ve ilişkili stres birikiminin izlenmesi gerektiğini göstermektedir. Zhou ve diğ. (2022), GNSS verilerinin yapay zeka tabanlı modellerle bütünleştirilmesinin, özellikle stres birikimi ve yer kabuğu hareketlerinin izlenmesinde yüksek doğruluk sağladığını göstermiştir. Zaman serisi temelli analizlerde en çok tercih edilen modellerden biri olan LSTM, özellikle GNSS kaynaklı uzun dönemli gözlem verilerinin işlenmesinde öne çıkmaktadır (Asim ve diğ. 2018, Zhang ve diğ. 2019).

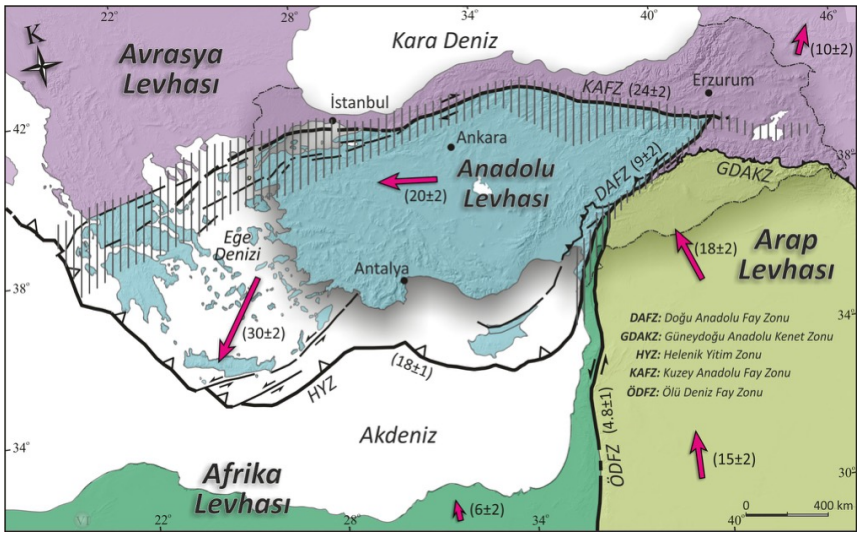
Bu çalışmada, Bolu ili ve çevresinde yer alan Kuzey Anadolu Fay Zonu'na ait aletsel dönem deprem kayıtları ile GNSS verileri, LSTM mimarisi kullanılarak derin öğrenme tabanlı yöntemlerle analiz edilmiştir. GNSS verileri ile stres birikimi arasındaki ilişki değerlendirilmiş ve bu ilişkinin fay zonu boyunca meydana gelebilecek sismik aktivitelerin modellenmesinde kullanılabilirliği araştırılmıştır. Ayrıca, sismik aktivitenin öngörülmesine yönelik modelleme yaklaşımının geliştirilmesi ve bu doğrultuda daha kapsamlı bir tahmin sisteminin oluşturulmasına yönelik uygulamalar da ele alınmıştır.

2. ÇALIŞMA ALANI

Dünyanın en aktif sağ yanal doğrultu atımlı fay sistemlerinden biri olan Kuzey Anadolu Fay Zonu, Avrasya ve Anadolu levhaları arasındaki sınırı oluşturmaktadır (Barka 1992, Şengör ve diğ. 2003, Çağlayan ve diğ. 2019) (Şekil 1). Çok sayıda fay segmentinden oluşan bu zon tarihsel ile aletsel dönemde birçok büyük depreme kaynaklık etmiştir (Tablo 1) (AFAD 2025). GNSS verileri, KAFZ boyunca yıllık 15-25 mm arasında değişen sağ yönlü kayma hızlarını ortaya koymakta; bu hareketlilik, fay zonu boyunca gerinim birikimine ve zamanla oluşan deformasyonlara neden olmaktadır (McClusky ve diğ. 2000, Reilinger ve diğ. 2006).

Tablo 1: *Kuzey Anadolu Fay Zonu üzerinde aletsel dönemde meydana gelen ve aletsel büyüklüğü 7.0 ve daha büyük olan depremler (AFAD 2025)*
Table 1: *Earthquakes with instrumental magnitudes of 7.0 and above that occurred during the instrumental period along the North Anatolian Fault Zone (AFAD 2025)*

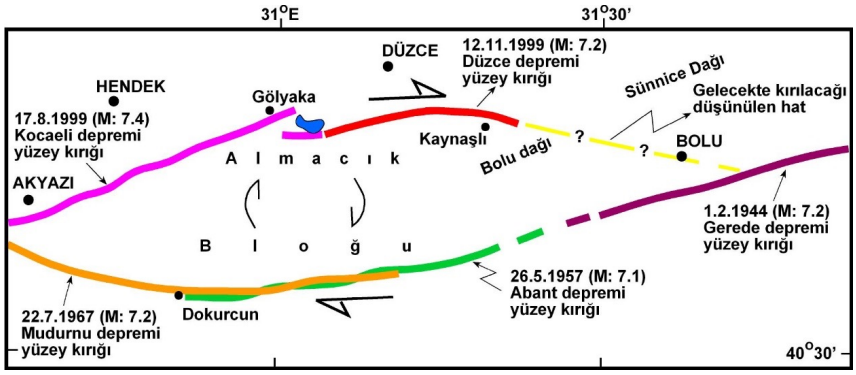
Deprem Adı	Tarih	Zaman	Enlem	Boylam	Derinlik	Büyüklük
Tekirdağ Depremi	09.08.1912	01:29	40.7500	27.2000	10	7.4
Tokat Depremi	24.01.1916	06:55	40.2700	36.8300	10	7.1
Erzincan Depremi	26.12.1939	23:57	39.8000	39.5100	20	7.9
Tokat-Erbaa Depremi	20.12.1942	14:03	40.8700	36.4700	10	7.0
Çankırı Depremi	26.11.1943	22:20	41.0500	33.7200	10	7.2
Bolu-Gerede Depremi	01.02.1944	03:22	40.9000	32.6000	10	7.3
Yenice Gönen Depremi	18.03.1953	19:06	39.9900	27.3600	10	7.2
Abant Depremi	26.05.1957	06:33	40.6700	31.0000	10	7.1
Manyas Depremi	06.10.1964	14:31	40.3000	28.2300	34	7.0
İzmit Depremi	17.08.1999	03:02	40.7700	30.0040	15	7.6
Düzce Depremi	12.11.1999	18:57	40.8060	31.2260	11	7.1



Şekil 1: *Türkiye ve yakın çevresinin litosferik levhalarını gösterir sadeleştirilmiş tektonik harita (Çağlayan ve diğ. 2019)*
Figure 1: *Simplified tectonic map showing the lithospheric plates of Turkiye and its surrounding region (Çağlayan et al. 2019)*

Bu bağlamda, Bolu ve çevresi, çalışmanın odak alanı olarak seçilmiştir. Bunun üç temel nedeni bulunmaktadır: (i) bölge, 1944 Gerede, 1967 Mudurnu ve 1999 Düzce depremleri gibi M ≥ 7 büyüklüğündeki yıkıcı depremlerin merkezine yakın konumdadır; (ii) yapılan jeolojik ve jeofiziksel araştırmalar, bazı segmentlerin henüz kırılmamış olduğunu ve dolayısıyla gelecekte büyük deprem riski taşıdığını ortaya koymaktadır (Seyitoğlu ve diğ. 2015); (iii) Bolu, Gerede, Sakarya, Zonguldak, Karabük ve Hendek gibi noktalarda konumlanan GNSS istasyonları, bölgedeki yer deformasyonlarının milimetrik hassasiyetle izlenmesine olanak sağlamaktadır (HGM 2024).

Bu nedenlerle, Bolu çevresi yalnızca geçmiş sismik aktivitenin izlenmesi açısından değil, aynı zamanda kırılmamış segmentlerin neden olduğu stres birikiminin gelecekteki sismik davranışlara etkisini anlamak açısından da stratejik bir öneme sahiptir. Özellikle 12 Kasım 1999 Düzce depremi sonrası yapılan değerlendirmelerde, Almacık Bloğu'nun kuzeydoğu kesiminde kırılmadan kalmış fay segmentlerinin varlığına dikkat çekilmiş ve bu bölgenin gelecekte büyük bir deprem üretme potansiyeline sahip olduğu vurgulanmıştır (Seyitoğlu ve diğ. 2015). Bu alan hem jeodezik gözlemler hem de sismotektonik değerlendirmeler için kritik bir örnek alan niteliği taşımaktadır (Şekil 2).

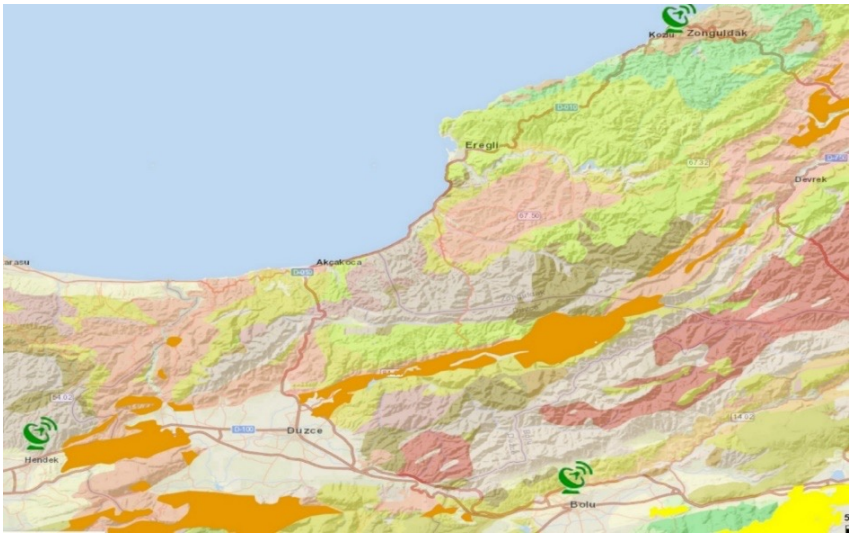


Şekil 2: *Çalışma bölgesinde gerçekleşen son depremlerin yüzey kırıkları ve Almacık Bloğu (Seyitoğlu vd. 2015).*
Figure 2: *Surface ruptures of the recent earthquakes in the study area and the Almacık Block (Seyitoğlu ve diğ. 2015).*

Bölgedeki jeodezik çalışmalar, GNSS ölçümlerinin fay zonu boyunca gerinim birikimini belirlemede kritik bir rol oynadığını göstermektedir (Kreemer ve diğ. 2003). GNSS temelli deformasyon hız haritaları, fay segmentlerinin kilitlenme derecesi ve sismik kırılma potansiyeline ilişkin önemli göstergeler sunmaktadır. Son yıllarda meydana gelen 2020 Elazığ ve 2023 Kahramanmaraş depremleri kapsamında gerçekleştirilen çalışmalarda, co-seismic ve interseismic deformasyonların incelenmesinde GNSS ve InSAR verilerinin birlikte kullanılması yaygın bir yaklaşım haline gelmiştir. Bu bütünleşik veri kullanımı, fay zonu boyunca gerilimin mekânsal dağılımının ve deformasyon desenlerinin daha ayrıntılı biçimde modellenmesine olanak sağlamaktadır. Cheloni ve diğ. (2025), GNSS ve InSAR verilerini birlikte kullanarak Doğu Anadolu Fay Zonu'ndaki kırık sonu bölgelerinde gerinim birikimini yüksek çözünürlükte haritalamış ve potansiyel olarak sismik açıdan daha aktif segmentlerin ayırt edilmesine katkı sunmuştur.

Bölgedeki GNSS istasyonları, stres birikimi ve yüzey deformasyonlarının izlenmesinde önemli roller üstlenmektedir. Bolu istasyonu (BOLU/BOL1), 2008 yılından itibaren kesintisiz veri kaydı sağlayan en eski GNSS ölçüm noktalarından biri olarak öne çıkmaktadır. Bu istasyon 2018 yılına kadar aktif olarak veri toplamış, bu tarihten itibaren ise BOL1 adıyla veri kaydına devam ederek sürekliliği sağlamıştır. Hendek istasyonu (HNDK) ise, Bolu'ya kıyasla referans noktası olarak kullanılmış ve bölgedeki deformasyon analizlerinde temel bir karşılaştırma noktası işlevi görmüştür. Öte yandan, Zonguldak istasyonu (ZONG), Avrasya Plakası üzerinde sabit bir referans noktası olarak değerlendirilmiş ve bu sabitliğin sağladığı avantajla GNSS verilerinin yerel hareketleri yorumlamakta güvenilir bir temel oluşturduğu kabul edilmiştir. Sağlanan istasyon verileri mutlak konum verilerini içermektedir. Bu sayede verilerin eksik olduğu günler bulunsa bile mutlak konum sonraki günlerde sağlandığı için hareket hesaplamalarında bir sorun oluşturmamıştır.

Bu bağlamda, Bolu ve Hendek GNSS istasyonlarından elde edilen veriler temel alınarak, stres birikimi ile sismik aktivite arasındaki ilişki analiz edilmiş; GNSS zaman serilerinin eğilimleri değerlendirilmiştir. İlgili istasyon konumları ve jeolojik birimler Şekil 3'te gösterilmektedir.



Şekil 3: *GNSS istasyonlarının haritadaki konumları*
Figure 3: *Positions of GNSS stations*

3. YÖNTEM

Bu çalışmada, Bolu ve Hendek bölgelerindeki Küresel Konumlama Uydu Sistemi (GNSS) istasyonlarından elde edilen konum verileri ile aletsel dönem sismik aktivite kayıtları kullanılarak, uzun vadeli deprem tahmini hedeflenmiştir. Veriler, detaylı bir ön işleme sürecinden geçirilmiş; stres birikimi ile sismik aktivite arasındaki ilişkileri açıklamak amacıyla fiziksel temelli bir stres modeli geliştirilmiştir. Bu stres zaman serileri, zaman serisi tahmininde sıkça kullanılan Uzun Kısa Süreli Bellek (LSTM) modeliyle analiz edilmiştir.

Derin öğrenme modelinin performansını artırmak amacıyla hiperparametre optimizasyonu ve ağırlıklı kayıp fonksiyonu uygulanmıştır. Ancak, GNSS verilerinin kapsadığı dönem boyunca çalışma alanında $M > 5.0$ büyüklüğünde bir depremin meydana gelmemiş olması, modelin büyük magnitüdlü olayları öngörme kapasitesini sınırlamıştır. Bu durum, LSTM mimarisinin nadir olaylara karşı düşük öğrenme başarımıyla ilişkilendirilmiştir. Literatürde, benzer kısıtların CNN-LSTM (Kavianpour ve diğ. 2021b) ve Transformer tabanlı modellerde de raporlandığı görülmektedir. Bu nedenle, ilerleyen çalışmalarda bu tür modellerin karşılaştırmalı olarak test edilmesi, derin öğrenme tabanlı yaklaşımların sismik tahmin doğruluğu üzerindeki etkisinin daha sistematik biçimde değerlendirilmesine olanak sağlayabilir.

3.1) Veri Seti ve Ön İşleme Süreci

Bu çalışmada analiz edilen veriler, GNSS ölçümleri ve aletsel dönem deprem kayıtları olmak üzere iki temel kaynaktan elde edilmiştir. GNSS verileri, Harita Genel Müdürlüğü (HGM) tarafından sağlanmış ve Bolu ile Hendek istasyonlarına ait günlük konum değişim bilgilerini içermiştir. Aletsel dönem deprem verileri ise, Afet ve Acil Durum Yönetimi Başkanlığı (AFAD) tarafından yayımlanan kataloglardan temin edilmiş; bu veriler, çalışma bölgesinde 1910 ile 2023 yılları arasında meydana gelen ve büyüklüğü $M \geq 1$ olan depremleri içermiştir.

Veri ön işleme süreci, GNSS ve aletsel dönem sismik verilerin derin öğrenme modelleriyle uyumlu hâle getirilmesini amaçlamaktadır. Bu kapsamda, öncelikle eksik veya tekrarlayan gözlemlerin temizlenmesi için gerekli kodlamalar geliştirilmiş. Kullanılan veri setlerinde bu tür hatalara rastlanmamıştır. Veri temizliğinin ardından, GNSS ölçümleri ile sismik parametreler zaman serisi analizine uygun biçimde normalize edilmiştir. LSTM gibi derin öğrenme algoritmaları, farklı ölçeklerdeki giriş verilerine duyarlı olduğundan, modelin daha kararlı öğrenebilmesi için tüm girdilere Min-Max normalizasyon yöntemi uygulanmıştır. Bu yöntem, verileri [0,1] aralığına indirgerken öğrenme sürecindeki ölçek kaynaklı dengesizlikleri azaltmakta ve model performansının iyileştirilmesine katkı sağlamaktadır. (Zheng ve diğ. 2013).

Bununla birlikte, GNSS verileri Dünya Merkezli Dünya Sabit (ECEF – Earth-Centered Earth-Fixed) koordinat sisteminden Doğu-Kuzey-Yukarı (ENU – East-North-Up) yerel koordinat sistemine dönüştürülmüştür. Bu dönüşüm, bölgesel deformasyonların ve yerel yer değiştirme vektörlerinin daha hassas biçimde analiz edilmesine olanak sağlamaktadır (Hofmann-Wellenhof ve diğ. 2001, Kuna ve diğ. 2020).

Tüm bu ön işleme adımları sonucunda elde edilen zaman serisi verileri, derin öğrenme yaklaşımlarından biri olan LSTM mimarisi ile analiz edilmek üzere hazırlanmıştır. LSTM, zaman içerisindeki örüntüleri öğrenme kapasitesi sayesinde, karmaşık ve doğrusal olmayan zaman serilerinin modellenmesinde yaygın olarak kullanılan bir yöntemdir (Hochreiter ve Schmidhuber 1997). Stres birikimi ile sismik aktivite arasındaki ilişkilerin modellenmesine yönelik LSTM tabanlı yaklaşımlara ilişkin ayrıntılar bir sonraki bölümde sunulmuştur.

3.2) Stres Modeli ve Sismik Aktivite ile İlişkisi

Bu çalışmada kullanılan stres modeli, GNSS verilerinden elde edilen göreceli yer değiştirmelerin, elastik yer kabuğu varsayımı altında bir tür şekil değiştirme (strain) olarak ele alınmasına dayandırılmıştır. GNSS zaman serilerinden türetilen doğu-batı ve kuzey-güney yönündeki konum değişimleri ise, iki istasyon arasındaki göreli hareket üzerinden zamana bağlı şekil değişimlerini temsil edecek şekilde değerlendirilmiştir.

Hooke Kanunu çerçevesinde, elastik deformasyonlar altında kayma gerilmesi (shear stress) ile kayma şekil değiştirmesi (shear strain) arasında doğrusal bir ilişki tanımlanmıştır. Bu ilişki Denklem 1'de gösterilmiştir:

$$\tau = G \cdot \gamma \tag{1}$$

Burada, τ kayma gerilmesini (shear stress), γ kayma şekil değiştirmesini (shear strain) ve G kayma modülünü (shear modulus) temsil eden parametreler olarak tanımlanmıştır (Hobbs ve diğ. 1976). Bu çerçevede, modelde strain benzeri büyüklüklerin sabit bir katsayı (modül) ile çarpılması yoluyla stres birikimi tahmini gerçekleştirilmiştir. Söz konusu katsayı, bölgeye özgü elastik özellikleri yansıtacak şekilde optimize edilmiş ve LSTM modeline giriş olarak sağlanan stres zaman serilerinin elde edilmesinde kullanılmıştır.

Kuzey Anadolu Fay Zonu'nun sağ-yanal doğrultu atımlı karakteri, fay boyunca oluşan kırılmaların büyük ölçüde kayma gerilmesi birikimine bağlı olduğunu ortaya koymuştur. Literatürde, KAFZ üzerindeki büyük depremlerin çoğunlukla sağ-yanal doğrultu atımlı kayma mekanizmasıyla meydana geldiği ve bu deformasyonun fay boyunca stres birikimine neden olduğu çeşitli çalışmalarla gösterilmiştir (Bozkurt 2001, Hubert-Ferrari ve diğ. 2002).

Sismik aktivitenin, özellikle büyük depremlerin, fay zonu boyunca biriken stresi ani şekilde boşalttığı da bilinmektedir. Bu durum, "stres düşümü" (stress drop) olarak tanımlanmakta ve deprem sırasında elastik enerjinin serbest kalmasına karşılık gelmektedir (Kanamori ve Anderson 1975). Dolayısıyla, stres birikimi zamanla artmakta ancak belirli eşiklerin aşılmasıyla sismik kırılmalar yoluyla azalmaktadır.

Bu çalışmada, plaka hareketleriyle litosfer içerisinde biriken elastik deformasyon enerjisinin, sismik aktiviteler sonucu azaldığını varsayan lineer bir model yaklaşımı uygulanmıştır. Stres birikiminin zaman içerisindeki değişimini tanımlayan model, Denklem 2'de verilen matematiksel ifade ile tanımlanmıştır:

$$S_t = S_{t-1} + \frac{G\Delta M_t}{L} - K.xM_t \tag{2}$$

Burada

- S_t t anındaki stres seviyesidir,
- ΔM_t t ve t-1 aralığında hareket değişimi,
- L istasyonlar arasındaki toplam mesafe
- xM_t t anında gözlemlenen sismik aktivite,
- G Elastisite Modulu
- K stress düşüşü katsayısıdır.

Modeli basitleştirme amacıyla tüm denklem G/L katsayısına bölünerek (3) nolu Denklem elde edilmiştir.

$$S_t{}^p = S_{t-1}{}^p + \Delta M_t - k.xM_t \tag{3}$$

Burada;

- $S_t{}^p$ t anındaki G/L katsayısı ile düzeltilmiş stres seviyesidir,
- k stresin sismik aktiviteye tepkisini belirleyen bir katsayıdır.

Böylece stres ve gerinim arasındaki elastisite katsayısı ilişkisi normalize edilerek tek bir katsayı ilişkisi kurulmuştur. Bu LSTM modelinin en düşük kayıp noktalarını ararken tek katsayının değiştirilmesi kolaylığını sağlamıştır.

Bu model çerçevesinde, GNSS verileriyle izlenen bu stres artış ve azalış döngüsü, Hooke kanunu üzerinden modellenmiş ve zaman serisi hâline getirilmiştir. Böylece, fiziksel modele dayalı bir stres tahmini, makine öğrenmesi yaklaşımıyla birleştirilerek deprem büyüklüğü tahmini sürecine entegre edilmiştir. GNSS verileri ve sismik hareketlerle hesaplanan bu stres serileri, LSTM modelinin temel girişlerinden birini oluşturarak zamana bağlı sismik aktivitenin öngörülmesinde kullanılmıştır.

3.3) LSTM Modeli ile Deprem Büyüklüğü Tahmini

Uzun Kısa Süreli Bellek modelleri, zaman serisi tahminlerinde uzun vadeli bağımlılıkları öğrenme kapasitesi nedeniyle bu çalışmada tercih edilmiştir. LSTM mimarisi, klasik RNN'e (Tekrarlayan Sinir Ağı- Recurrent Neural Networks) kıyasla bir bellek hücresi ile giriş, unutma ve çıkış kapılarından oluşacak şekilde yapılandırılmıştır. Bu yapı sayesinde model, önemli bilgileri uzun süre hafızada tutabilmiş; aynı zamanda gereksiz bilgileri dışlayarak bilgi akışını optimize edebilmiştir (Hochreiter ve Schmidhuber 1997). Bu özellikleri doğrultusunda, zaman içinde gelişen stres birikimi ve sismik aktivite gibi jeofizik süreçlerin modellenmesinde kullanılmaya elverişli bulunmuştur.

Literatürde, derin öğrenme modelleri ile stres-zaman ilişkisini kurarak bu veriler üzerinden deprem büyüklüğü tahmini yapılmasına yönelik çeşitli çalışmalara rastlanmıştır. Derin öğrenme tabanlı yapay sinir ağlarının, özellikle zaman serisi verileri ile çalışırken anlamlı çıktılar ürettiği gözlemlenmiştir. Tekrarlayan Sinir Ağları ailesine ait olan LSTM modelleri

ise uzun vadeli bağımlılıkları öğrenme kapasitesi nedeniyle tercih edilmiştir (Hochreiter ve Schmidhuber 1997). Örneğin, Zhang ve diğ. (2019) ve Bao ve diğ. (2021) tarafından geliştirilen modeller, zaman serisi olarak modellenen fiziksel parametrelerin yapay sinir ağlarıyla işlenebileceğini ortaya koymuştur. Ayrıca, Banna ve diğ. (2021), dikkat mekanizmalarıyla geliştirilmiş çift yönlü LSTM modeli ile deprem öngörülerinde yüksek doğruluk elde edildiğini raporlamıştır. Bu bağlamda, çalışmada kullanılan stres modelinin LSTM ile entegrasyonu, literatürdeki yaklaşımlara bir yenilik getirmiştir.

LSTM modelleri, yapay zeka alanında derin öğrenme yaklaşımları içerisinde değerlendirilmiş ve bu çalışmada, denetimli öğrenme (supervised learning) kapsamında zaman serisi verilerinin işlenmesi amacıyla kullanılmıştır. Literatürde, LSTM'lerin geleneksel RNN'lerden farklı olarak uzun vadeli bağımlılıkları öğrenme kapasitesi nedeniyle doğal dil işleme (NLP), finansal zaman serisi tahmini, biyomedikal sinyal analizi ve sismik veri analizi gibi çeşitli alanlarda yaygın biçimde uygulandığı rapor edilmiştir.

3.3.1) LSTM Hücresinin Yapısı;

Bir LSTM hücresi, RNN hücrelerinden farklı olarak bilgi akışını kontrol eden üç temel kapı mekanizması ile yapılandırılmıştır. Bu kapılar; unutma kapısı (forget gate), giriş kapısı (input gate) ve çıkış kapısı (output gate) olarak sıralanmıştır.

Unutma kapısı, geçmişten gelen bilgiler arasından hangilerinin silineceğini belirlemiş ve bu işlem sigmoid aktivasyon fonksiyonu ile gerçekleştirilmiştir. Böylece model, önceki zaman adımlarındaki bazı bilgileri eleyerek bilgi yükünü azaltmıştır. Giriş kapısı, yeni bilgilerin hücre durumuna hangi ölçüde aktarılacağını tanımlamış; bu aşamada sigmoid ve tanh (hiperbolik tanjant) aktivasyon fonksiyonları birlikte çalışarak hücre durumu güncellenmiştir. Son olarak çıkış kapısı, hücre durumundan hangi bilgilerin dışa aktarılacağını belirlemiş ve sonraki zaman adımlarındaki tahminlerde kullanılacak bilgi bu şekilde filtrelenmiştir.

Bu kapı mekanizmalarının birlikte çalışmasıyla, LSTM modellerinin zaman serisi verilerindeki uzun vadeli bağımlılıkları etkili biçimde öğrendiği ve özellikle karmaşık örüntüler içeren veri kümelerinde yüksek performans gösterdiği gözlemlenmiştir.

3.3.2) LSTM Modelindeki Önemli Parametreler

LSTM modelinin performansını etkileyen temel hiperparametreler (epok, toplu işleme boyutu, geriye dönük adım sayısı, düşürme oranı, öğrenme oranı ve kayıp fonksiyonu), modelin doğruluğu, genelleme yeteneği ve eğitim süresi üzerinde doğrudan etkili olmuştur. Bu hiperparametrelerin doğru seçimi, modelin hem eğitim hem de test aşamalarında başarılı sonuçlar üretmesine katkı sağlamıştır.

Öncelikle, epok (epoch) sayısı, modelin tüm eğitim verisi üzerinde kaç kez çalıştığını ifade eden bir parametre olarak değerlendirilmiştir. Epok sayısının çok yüksek olduğu durumlarda modelin eğitim verisini ezberleyerek aşırı öğrenme (overfitting) sorunu yaşadığı gözlemlenmiştir. Buna karşılık, düşük epok sayısı ise modelin yeterli düzeyde öğrenememesine ve doğruluk oranlarının düşmesine yol açmıştır.

Toplu işleme boyutu (batch size), modelin her iterasyonda kaç örnek üzerinden güncelleme yaptığını belirleyen bir hiperparametre olarak ele alınmıştır. Küçük batch boyutları, daha iyi genelleme performansı sağlamış ancak hesaplama süresini uzatmıştır. Öte yandan, büyük batch boyutları modelin daha hızlı öğrenmesine katkı sağlarken genelleme kabiliyetini sınırlamıştır.

Geriye dönük adım sayısı (lookback), modelin tahmin yaparken geçmiş kaç zaman adımını dikkate aldığına ilişkin bir hiperparametre olarak değerlendirilmiştir. Bu değer düşük olduğunda model, kısa vadeli değişimleri daha etkili biçimde öğrenmiştir. Öte yandan, yüksek lookback değerleri, uzun vadeli bağımlılıkların yakalanmasına imkân tanımış ancak hesaplama yükünü artırmıştır.

Düşürme oranı (dropout), modelin aşırı öğrenme eğilimini azaltmak amacıyla eğitim sırasında bazı nöronların rastgele devre dışı bırakılması için kullanılmıştır. Bu oran genellikle 0.2 ile 0.5 arasında seçilmiştir. Ancak yüksek düşürme oranları, modelin öğrenme sürecini yavaşlatmış ve doğruluğu olumsuz yönde etkilemiştir.

Öğrenme oranı (learning rate), modelin ağırlıklarını güncellerken adım büyüklüğünü belirleyen önemli bir hiperparametre olarak değerlendirilmiştir. Küçük öğrenme oranları, öğrenme sürecini daha istikrarlı ancak daha yavaş hâle getirmiştir. Buna karşılık, büyük öğrenme oranları modelin dengesiz ve kararsız davranmasına yol açmıştır. Literatürde, 0.001 veya 0.0001 gibi küçük değerlerle başlandığı örneklere sıkça rastlanmaktadır (Bengio 2012, Kingma ve Ba 2015, Goodfellow ve diğ. 2016).

Son olarak, kayıp fonksiyonu (loss function), modelin tahmin hatasını ölçmek amacıyla kullanılan önemli bir hiperparametre olarak değerlendirilmiştir. LSTM ile gerçekleştirilen regresyon problemlerinde, yaygın olarak kullanılan kayıp fonksiyonları arasında Ortalama Kare Hatası (Mean Squared Error), Ortalama Mutlak Hata (Mean Absolute Error) ve Log-Cosh fonksiyonu bulunmuştur. Ortalama kare hatası, büyük hatalara karşı daha duyarlı bir yaklaşım sunmuştur; ortalama mutlak hata, sapmaları doğrudan ölçen bir yöntem olarak kullanılmıştır. Log-Cosh fonksiyonu ise hata değerlerini log-cosh formülüyle işleyerek uç değerlerin etkisini azaltmış ve modelin daha dengeli öğrenmesine katkı sunmuştur. Bu hiperparametreler, modelin genel başarısı ve öğrenme performansı üzerinde doğrudan etkili olmuştur. Ancak bu parametrelerin en iyi sonucu verdiği değerleri doğrudan hesaplayacak analitik bir yöntem bulunmadığından, genellikle sayısal sonuçların kıyaslanmasına dayalı arama yöntemleri tercih edilmiştir. Literatürde en sık kullanılan yöntemler arasında ızgara arama (Grid Search) ve Bayesyen optimizasyonu yer almaktadır (Bergstra ve Bengio 2012, Snoek ve diğ. 2012, Feurer ve diğ. 2015).

Bu çalışmada geliştirilen LSTM modeli, GNSS hareket verileri ile stres modeli çıktıları birleştirilerek, olası sismik aktivitelerin büyüklüğünü tahmin etmek amacıyla eğitilmiştir. Modelin giriş ve çıkış bileşenleri aşağıdaki şekilde yapılandırılmıştır:

- Girdi: GNSS verileri (ENU koordinatları), stres modeli çıktıları, geçmiş sismik aktivite kayıtları
- Çıkış: Tahmin edilen deprem büyüklüğü
- Katmanlar:
  - İlk LSTM katmanı: Zaman serisi özelliklerini çıkarmak için kullanılmıştır.
  - Düşürme Oranı katmanı (%20): Aşırı öğrenmeyi önlemek için rastgele bağlantılar devre dışı bırakılmıştır.
  - İkinci LSTM katmanı: Derinlemesine özellik çıkarımı sağlanmıştır.
  - Dense katmanı (tam bağlı katman): Son çıktıyı oluşturmak için kullanılmıştır.

Model, ağırlıklandırılmış ortalama kare hata fonksiyonu (Weighted Mean Squared Error) kullanılarak eğitilmiş ve parametre güncellemeleri, Adam optimizasyon algoritması aracılığıyla gerçekleştirilmiştir (Kingma ve Ba 2014).

3.4) Optimize Edilen Diğer Parametreler

Kod içerisinde yalnızca hiperparametreler değil, modelin öğrenme sürecini etkileyen bazı ek parametreler de optimize edilmiştir. Bu parametreler (başlangıç stres değeri, stres katsayısı, pencere boyutu, agregat değerler) modelin fiziksel süreçleri daha gerçekçi biçimde temsil etmesi amacıyla dikkatle seçilmiş ve çeşitli senaryolarla test edilmiştir. Bu kapsamda ilk olarak, başlangıç stres değeri (initial_stress), stres seviyesinin başlangıç noktasını tanımlamak üzere belirlenmiştir. Farklı başlangıç değerleriyle yapılan denemeler sonucunda, modelin performansını en üst düzeye çıkaran optimum stres değeri elde edilmiştir.

İkinci olarak, stres katsayısı (k), zaman içerisinde stres seviyesindeki değişimi tanımlayan bir parametre olarak kullanılmıştır. Farklı değerleri, deprem aktivitesiyle olan korelasyona göre değerlendirilmiş ve en iyi sonuçları veren katsayılar seçilmiştir.

Pencere boyutu (window_size) ise modelin geçmişteki kaç zaman adımını dikkate alarak tahmin yaptığına karşılık gelmektedir. Zaman serisi analizi kapsamında çeşitli pencere uzunlukları test edilmiş ve hem öğrenme başarısı hem de genel tahmin doğruluğu bakımından en uygun değer belirlenmiştir.

Son olarak, önceki agregat değerler (Prev_Agg_xM ve Prev_Agg_xM_windows_shift) parametreleri, modelin geçmiş sismik hareketleri nasıl değerlendireceğini belirlemiştir. Bu değişkenler, modelin zaman serisi içerisindeki geçmiş bilgiyi daha etkili biçimde kullanması amacıyla optimize edilmiştir.

Bu ek parametreler, model doğruluğu ve tahmin kararlılığını artırma hedefiyle yapılandırılmış ve optimize edilmiştir.

3.5) Model Eğitimi ve Doğrulama Süreci

Zaman serisi verilerinin analizi ve model doğrulaması için kullanılan geleneksel çapraz doğrulama yöntemleri yetersiz kalmıştır. Bu nedenle, geçmiş bilgiyi kullanarak geleceği tahmin etmeyi hedefleyen özel yaklaşımlar geliştirilmiştir. Bu bağlamda, Zaman Serisi Bölme (Time Series Split) yöntemi, verileri sıralı bir biçimde eğitim ve test kümelerine ayıran bir çapraz doğrulama tekniği olarak uygulanmıştır (Hyndman ve Athanasopoulos 2018).

Zaman serisi bölme yöntemi, belirlenen "n bölme" (n_splits) parametresine göre veriyi kademeli olarak bölerek eğitim ve test setlerini oluşturmuştur. Her bölmede, eğitim kümesi genişletilmiş; test kümesi ise yalnızca eğitim kümesinin sonrasındaki veri noktalarını içerecek şekilde tanımlanmıştır. Bu sayede modelin gelecekteki gözlemleri tahmin etme performansı daha gerçekçi biçimde değerlendirilmiştir. Örneğin, n_splits değeri 5 olan ve 10 veri noktasından oluşan bir zaman serisi, Tablo 2'de gösterildiği şekilde bölünmüştür:

Tablo 2: *n_splits değerleri*
Table 2: *n_splits values*

Katlama	Eğitim Kümesi	Test Kümesi
1. Katlama	$\{x_1, x_2\}$	$\{x_3\}$
2. Katlama	$\{x_1, x_2, x_3\}$	$\{x_4\}$
3. Katlama	$\{x_1, x_2, x_3, x_4\}$	$\{x_5\}$
4. Katlama	$\{x_1, x_2, x_3, x_4, x_5\}$	$\{x_6\}$
5. Katlama	$\{x_1, x_2, x_3, x_4, x_5, x_6\}$	$\{x_7\}$

Bu yapıda, her bir adımda eğitim kümesi bir önceki adıma göre genişletilmiş, test kümesi ise yalnızca eğitim kümesinden sonraki ilk veri noktasını içermiştir. Bu yaklaşım, zaman serisi verilerinin doğasına uygun bir çapraz doğrulama yöntemi sunmuş ve modelin gelecekteki veriler üzerindeki genelleme yeteneğine dair daha güvenilir bir performans ölçütü elde edilmesini sağlamıştır.

Zaman serisi bölme yöntemi, finansal zaman serileri, iklim verileri, IoT sensör verileri, arıza tahmini ve talep tahmini gibi birçok zaman serisi analizinde yaygın olarak kullanılmıştır (Bergmeir ve Benítez 2012, Hyndman ve Athanasopoulos 2018). Bu çalışmada da sismik verilerle oluşturulan LSTM modelinin doğrulama sürecinde bu yöntem tercih edilmiştir.

3.6) LSTM Modelinde Kayıp fonksiyonu

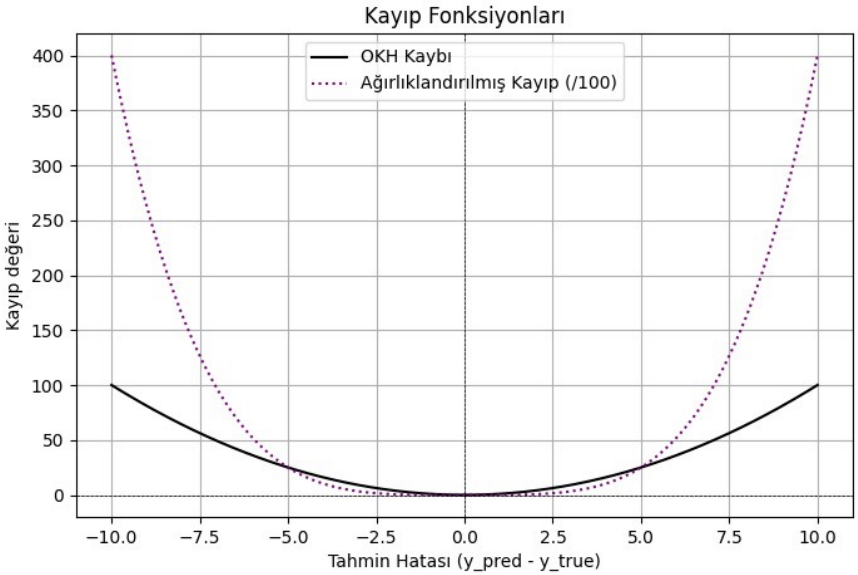
Literatürde en yaygın olarak kullanılan kayıp fonksiyonlarından biri, karesel ortalama hatasıdır (MSE – Mean Squared Error) (Denklem 4).

$$L_{MSE} = \frac{1}{N}\sum_{i=1}^{N}(y_i^{pred} - y_i^{true})^2 \quad (4)$$

Bu kayıp fonksiyonu, özellikle büyük hataları daha fazla cezalandırma özelliği nedeniyle modelin genel doğruluğunu artırmak amacıyla tercih edilmiştir. MSE'nin avantajı, modelin küçük hatalara karşı daha duyarlı hâle gelmesini sağlamasıdır. Ancak, uç değerlerin (outlier) varlığı durumunda modelin performansı olumsuz yönde etkilenmiştir.

Sismik verilerin tahmininde, özellikle büyük değerlerin doğru şekilde öngörülmesi önemli bir hedef olarak ele alınmıştır. Bu nedenle, kayıp fonksiyonunda büyük sismik değerlerin etkisini artırmak amacıyla özel bir kayıp fonksiyonu tercih edilmiştir (Denklem 5). Ağırlıklı kayıp fonksiyonu (Weighted Loss) olarak adlandırılan bu fonksiyonun tahmin ve gerçek verilerle ilişkisi Şekil 4'te verilmiştir.

$$L_{WMSE} = \frac{1}{N}\sum_{i=1}^{N}(y_i^{true})^2(y_i^{pred} - y_i^{true})^2 \quad (5)$$



Şekil 4: *Kayıp fonksiyonları*
Figure 4: *Loss functions*

Şekil 4'te, MSE kayıp fonksiyonu ile ağırlıklı kayıp fonksiyonunun karşılaştırması sunulmuştur. Kıyaslamanın daha anlaşılır olması amacıyla, ağırlıklı kayıp fonksiyonu değerleri 100'e bölünerek grafiksel olarak görselleştirilmiştir. Grafik analizleri, ağırlıklı kayıp fonksiyonunun büyük sismik değerler için daha yüksek kayıp ürettiğini; buna karşın, gerçek değerlerin azaldığı durumlarda ise bu kaybın klasik ortalama kare hata (MSE) değerinin altında kaldığını göstermektedir. Bu durum, modelin özellikle büyük ölçekli sismik hareketleri öncelikli olarak tahmin etme eğiliminde olduğunu ortaya koymaktadır.

3.7) Yazılımlar

Bu çalışmada, Python'ın Pandas ve GeoPandas kütüphaneleri veri işleme süreçlerinde etkin bir şekilde kullanılmıştır. Pandas, eksik ve hatalı verilerin tespiti, normalizasyon ve standartlaştırma işlemleriyle temel veri manipülasyonlarını gerçekleştirmiştir. Literatürde, Pandas'ın esnek veri manipülasyon yeteneklerinin büyük veri setleri üzerindeki analiz sürecini hızlandırdığı ifade edilmiştir (Zhang ve diğ. 2019). GeoPandas ise GNSS verilerinin coğrafi bağlamda modellenmesi ve dönüşüm işlemlerinde önemli bir rol üstlenmiştir. GNSS hareket vektörleri, coğrafi görselleştirme ve mekânsal analizler için GeoPandas geometrik nesnelerine dönüştürülmüş; bu sayede fay hattı boyunca potansiyel deprem risk bölgelerinin haritalanması gerçekleştirilmiştir.

Son olarak veri kümesi eğitim, doğrulama ve test setlerine bölünmüş; model doğruluğunu artırmaya yönelik olarak çapraz doğrulama teknikleri uygulanmıştır. Bu süreç, zaman serisi analizinde RNN ve LSTM gibi derin öğrenme modellerinin kullanılmasına olanak tanımış ve sismik aktivitelerin tahmininde katkı sağlamıştır (Asim ve diğ. 2018). Pandas ve GeoPandas'ın entegre kullanımı, veri işleme sürecini kolaylaştırmış ve elde edilen sonuçların güvenilirliğine olumlu yönde etki etmiştir.

4. VERİ

4.1) Sismik Veriler

Bu çalışmada, Kuzey Anadolu Fay Zonu ve çevresinde meydana gelen sismik aktiviteleri detaylı biçimde incelemek amacıyla, Boğaziçi Üniversitesi, Kandilli Rasathanesi ve Deprem Araştırma Enstitüsü (KRDAE) ve Afet ve Acil Durum Yönetimi Başkanlığı (AFAD) tarafından sağlanan geniş kapsamlı bir veri seti kullanılmıştır. Veriler, 1910-2023 yılları arasında meydana gelen ve büyüklükleri 1 ile 8 arasında değişen depremleri içermiştir. Her bir deprem için oluş zamanı, dış merkez noktalarının enlem ve boylam koordinatları ile büyüklük bilgileri kaydedilmiştir (Tablo 3).

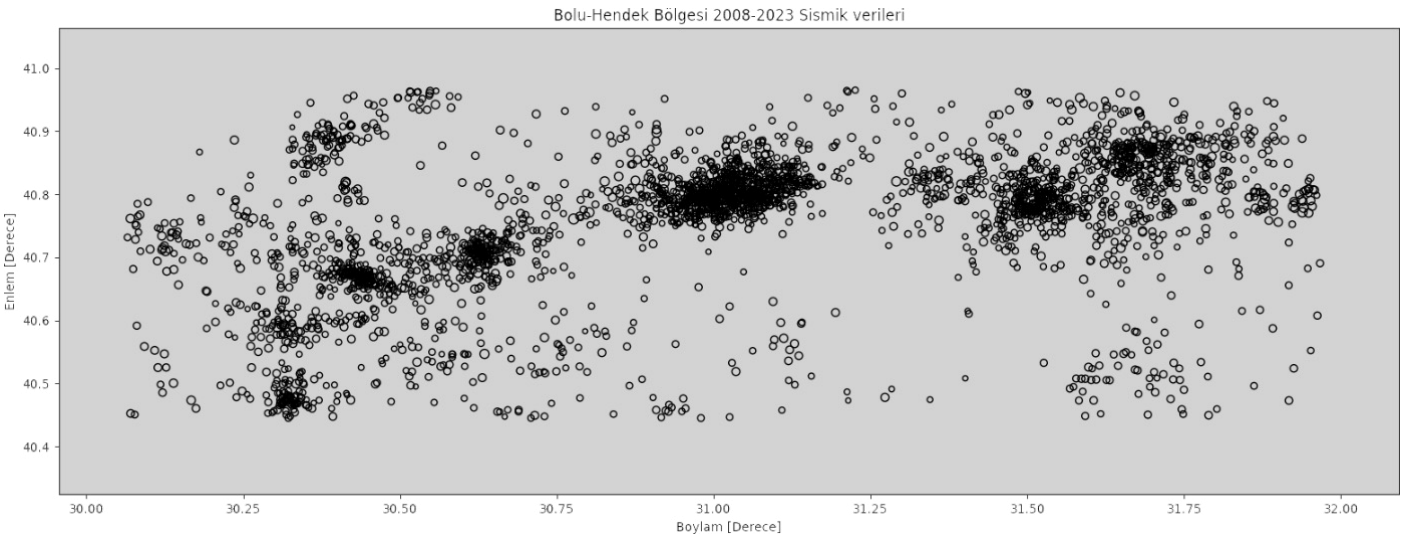
Tablo 3: *Çalışma alanına ait geçmiş depremlere örnekler (AFAD 2025)*
Table 3: *Illustrative examples of historical earthquakes in the study area (AFAD 2025)*

Tarih	Boylam	Enlem	Derinlik (km)	KOKH	Tip	Büyüklük	Konum
01/04/2025 08:08:44	31.7175	40.8619	8.42	0.11	ML	1.3	Merkez (Bolu)
30/03/2025 08:17:36	32.2569	40.8769	7.1	0.34	ML	1.2	Mengen (Bolu)
20/03/2025 06:18:46	31.7072	40.8744	6.9	0.23	ML	1.2	Merkez (Bolu)
09/03/2025 21:50:06	31.6797	40.8756	10.25	0.39	ML	1.2	Merkez (Bolu)
08/03/2025 16:17:05	31.7219	40.8633	9.53	0.25	ML	1.2	Merkez (Bolu)
06/03/2025 20:56:01	31.57	40.7803	11.85	0.46	ML	1.2	Merkez (Bolu)
28/02/2025 03:01:49	31.6689	40.8744	9.58	0.31	ML	1.5	Merkez (Bolu)
24/02/2025 15:12:40	31.6408	40.8261	9.53	0.35	ML	1.3	Merkez (Bolu)
14/02/2025 22:20:27	31.6189	40.7561	6.2	0.62	ML	1.1	Merkez (Bolu)
12/02/2025 18:02:36	31.635	40.7914	6.53	0.41	ML	1.2	Merkez (Bolu)
10/02/2025 13:12:24	31.5178	40.7914	7.0	0.34	ML	1.2	Merkez (Bolu)
09/02/2025 12:38:41	31.6217	40.8728	2.25	0.33	ML	1.3	Merkez (Bolu)
07/02/2025 03:12:12	31.6522	40.8778	3.2	0.41	ML	1.2	Merkez (Bolu)
05/02/2025 06:21:43	31.7092	40.8253	7.84	0.36	ML	1.4	Merkez (Bolu)
02/02/2025 14:07:46	31.6873	40.8119	8.42	0.25	ML	1.2	Merkez (Bolu)
31/01/2025 21:55:07	31.6556	40.8821	8.91	0.34	ML	1.2	Merkez (Bolu)
30/01/2025 13:51:48	31.6567	40.8617	11.26	0.32	ML	1.8	Merkez (Bolu)

Bu çalışmada kullanılan deprem verileri, AFAD'ın Türkiye ve çevresindeki sismik aktiviteleri incelemek amacıyla kurmuş olduğu ağı kullanarak elde ettiği çevrimiçi veri kaynağından temin edilmiştir. Bu veriler, yüksek sismik aktiviteye sahip bölgelerde meydana gelen depremlerin mekânsal ve zamansal analizleri için temel bir kaynak olarak kullanılmıştır. Ancak, elde edilen verilerin homojenleştirilmesi ve farklı büyüklük türleri arasındaki uyumun sağlanması, veri doğruluğunu artırmak ve tahmin modellerinin güvenilirliğini yükseltmek açısından kritik bir adım olarak değerlendirilmiştir (Kalafat ve diğ. 2011, Cambaz ve diğ. 2019). Bu nedenle, eğitim sürecinde farklı yıllardaki sismik aktivitelerin mekânsal ve zamansal dağılımları analiz edilerek model doğruluğunun artırılması hedeflenmiştir.

Bu kapsamda, kullanılan büyüklük türü de veri yapısıyla uyumlu olacak şekilde belirlenmiştir. Bu çalışmada büyüklük türü olarak ML (Yerel Büyüklük) kullanılmıştır. Bunun temel nedeni, çalışma alanı olan Bolu ve çevresinde analiz edilen dönem içerisinde büyük moment büyüklüğüne sahip depremlerin sınırlı sayıda olmasıdır. Bu durum, moment büyüklüğü (Mw) gibi kırılan fay alanı ve kayma momentine dayalı parametrelerin hesaplanmasını istatistiksel olarak anlamlı kılmamaktadır. Öte yandan ML, özellikle küçük ve orta büyüklükteki depremlerin kısa mesafeli kayıtlarla hassas biçimde ölçülmesine olanak tanıyan bir büyüklük türü olarak öne çıkmaktadır (Hutton ve Boore 1987). Ayrıca, Türkiye'deki ulusal sismik ağların (AFAD ve KRDAE) veri tabanlarında yaygın olarak ML büyüklüğü raporlaması, bu seçimi uygulamada da desteklemektedir (Kalafat ve diğ. 2011). Bu nedenlerle, çalışma bölgesinin sismik özellikleri ve veri yapısı göz önünde bulundurularak ML büyüklük türü tercih edilmiştir.

Sonuç olarak, veri kaynaklarının sürekliliği ve hassasiyeti sayesinde bu çalışma, deprem dinamiklerinin anlaşılması ve tahmine dayalı modellerin geliştirilmesine olanak sağlayan bir temel sunmuştur. Şekil 5'te sunulan verilerin coğrafi dağılımı, Kuzey Anadolu Fay Zonu'nun özelliklerinin anlaşılmasına ve potansiyel sismik etkilerin değerlendirilmesine katkı sağlamıştır.



Şekil 5: *Bolu-Hendek Bölgesindeki sismik veriler*
Figure 5: *Seismic data from the Bolu-Hendek Region*

4.2) Konum Verileri

Bu çalışmada, GNSS istasyonlarından elde edilen koordinat verileri ile sismik aktivitelerin birleştirilerek analiz edilmesi amacıyla kapsamlı bir Python uygulaması geliştirilmiştir. Bu uygulama, GNSS verilerinin Dünya merkezli koordinat sistemi (ECEF) ile Doğu-Kuzey-Yukarı (ENU) koordinat sistemine dönüştürülmesini mümkün kılmıştır. Söz konusu dönüşüm, hareketlerin belirli bir referans noktasına göre yerel düzlemde analiz edilmesini sağlamıştır. ECEF koordinatlarının ENU sistemine aktarılması ve zamanla değişimlerinin hesaplanması, istasyonların dinamik hareketlerini ve fay hatlarıyla ilişkili yüzey deformasyonlarını incelemek açısından kritik bir adım olarak değerlendirilmiştir.

Uygulama, GNSS istasyonlarının zaman içindeki göreceli hareketlerini analiz etmek ve bu hareketleri sismik aktivitelerle ilişkilendirmek amacıyla tasarlanmıştır. Hareket verileri, günlük ve aylık ölçeklerde incelenmiş; istasyonların birbirlerine göre olan konumsal değişimleri belirlenmiştir. Çalışma alanının Anadolu ve Avrasya plakaları arasında yer alması nedeniyle, Avrasya plakası üzerinde bulunan Zonguldak ili GNSS istasyonu referans olarak alınmış; Anadolu plakası üzerindeki fay zonuna en yakın olan Bolu ve Hendek istasyonlarının günlük hareket verileri elde edilmiştir. Ayrıca, sismik olayların etkisini daha doğru değerlendirebilmek amacıyla, ML (magnitüd) değerleri mesafeye göre ağırlıklandırılmış ve fay hattına yakın olaylara daha yüksek öncelik verilmiştir. Bu yöntem, sismik enerjinin mekânsal dağılımının daha net bir şekilde analiz edilmesine katkı sağlamıştır.

Sismik olaylar ve GNSS hareket verileri, ortak bir zaman dilimi ve coğrafi bağlamda entegre edilmiştir. Sismik olaylar belirli bir zaman aralığında toplanmış ve GNSS istasyon hareketleriyle eşleştirilmiştir. Bu entegre veri seti, istasyon hareketlerinin sismik aktivitelere verdiği tepkileri analiz etmek ve fay hatlarının potansiyel kırılma risklerini değerlendirmek amacıyla kullanılmıştır. Ayrıca veri seti, zamansal ve mekânsal ilişkilendirme için bir temel sağlamış ve makine öğrenimi modellerinin eğitimi için hazırlanmıştır.

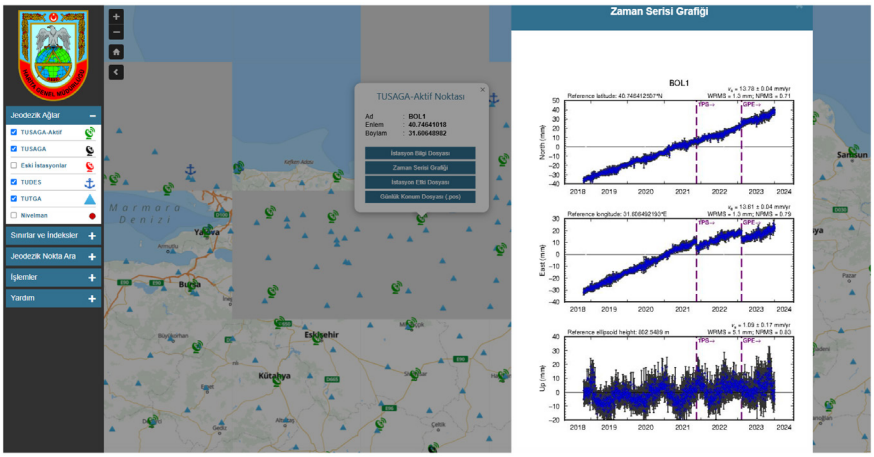
Sismik olaylar ve GNSS hareket verileri, aynı zaman dilimi ve coğrafi bağlamda birleştirilerek bu iki veri seti arasındaki ilişkilerin detaylı şekilde analiz edilmesine olanak tanımıştır. Sismik olaylar, 2008-2023 zaman aralığında toplanmış ve GNSS istasyonlarının zamansal hareket dinamikleriyle eşleştirilmiştir. Bu entegre veri yapısı, fay hatları üzerindeki potansiyel kırılma risklerini değerlendirmek amacıyla kullanılmıştır. Ayrıca, zamansal ve mekânsal bağlamda güçlü bir analiz temeli oluşturulmuş ve veri seti makine öğrenimi modellerinin eğitimi için optimize edilmiştir. Bu kapsamlı yaklaşım, sismik tahmin doğruluğunun artırılmasına ve fay hatlarındaki stres birikimlerinin daha etkili biçimde değerlendirilmesine katkı sağlamıştır.

Geliştirilen uygulama, GNSS verilerinin hassas biçimde işlenmesi, dönüştürülmesi ve analiz edilmesinin yanı sıra sismik olayların etkilerinin birlikte değerlendirilmesine olanak tanıyan bir araç olarak kullanılmıştır. Pandas ve GeoPandas gibi Python tabanlı veri işleme kütüphaneleriyle geliştirilen bu sistem, özellikle Kuzey Anadolu Fay Zonu'ndaki sismik aktivitelerin ve yüzey hareketlerinin bütüncül biçimde analiz edilmesini hedeflemiştir. Elde edilen entegre veri seti ve analiz çıktıları, deprem tahmin modellerinin geliştirilmesine yönelik çalışmalara altyapı sağlamıştır.

GNSS verileri, yeryüzündeki noktaların hassas konumlarını ve zaman içerisindeki yer değiştirmelerini ölçmek amacıyla Küresel Konumlama Uydu Sistemi istasyonlarından elde edilmiştir. Bu çalışmada kullanılan veriler, Harita Genel Müdürlüğü (HGM) tarafından sağlanmış olup çalışma alanını kapsayan Bolu, Gerede, Sakarya (Karasu), Zonguldak, Karabük ve Hendek istasyonlarından günlük olarak toplanmıştır. Veriler, GNSS istasyonlarının X, Y ve Z doğrultularındaki yer değiştirme bileşenlerini içermekte olup genellikle WGS84 koordinat sisteminde ifade edilmiştir. WGS84, GNSS uygulamalarında yaygın olarak kullanılan bir jeodezik referans sistemi olup tüm dünyayı kapsayan bir referans elipsoidine dayanmaktadır.

GNSS verileri, istasyon koordinatları, zamanla oluşan yer değiştirme vektörleri ile bu vektörlerin büyüklük ve yönlerini içeren bilgiler sağlamıştır. Harita Genel Müdürlüğü'nden elde edilen bu veriler, 2008 yılından itibaren düzenli biçimde kayıt altına alınmış ve coğrafi analizlerde kullanılmıştır. GNSS verileri, sismik aktivitelerin izlenmesi, plaka hareketlerinin modellenmesi ve yüzey deformasyonlarının belirlenmesi gibi jeofizik çalışmalar açısından önemli bir kaynak oluşturmuştur. Bu çalışmada, ilgili istasyonlardan elde edilen veriler deprem tahmin modellerine uygun formatlara dönüştürülmüş ve yer değiştirme trendleri ile olası sismik aktivite arasındaki ilişki incelenmiştir.

Bu çalışmada elde edilen veriler, Şekil 6'da gösterildiği üzere Harita Genel Müdürlüğü tarafından sağlanmış ve IGb14 referans çerçevesinde ifade edilmiştir. X, Y, Z (Dünya Merkezli Dünya Sabit – ECEF) koordinatlarında depolanan veriler, yerel analizlerde kullanılmak üzere ENU (East-North-Up) koordinat sistemine dönüştürülmüştür. ENU koordinatları, yerel düzlemde doğu, kuzey ve yukarı yönlerindeki hareketlerin analiz edilmesine olanak tanımıştır.

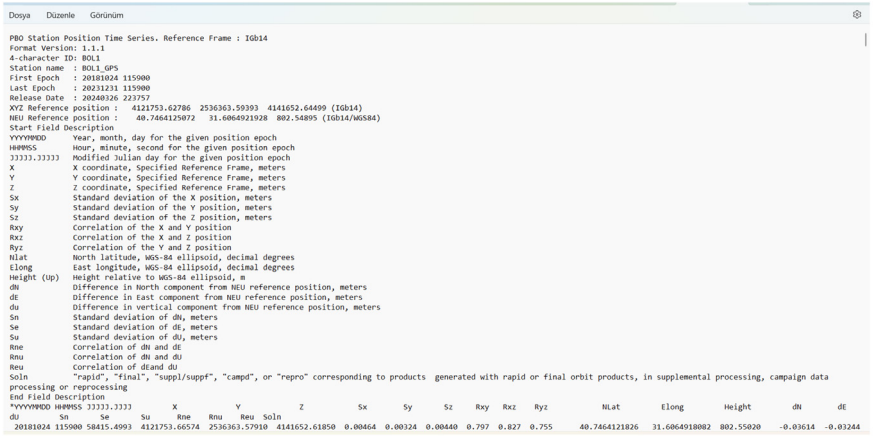


Şekil 6: *Harita Genel Müdürlüğü web sayfasından elde edilen zaman serisi verileri (HGM 2024)*
Figure 6: *Time series data obtained from the General Directorate of Mapping website (HGM 2024)*

Veri seti, Kuzey Anadolu Fay Zonu'nda yer alan Bolu, Gerede, Sakarya (Karasu), Zonguldak, Karabük ve Hendek istasyonlarından toplanmıştır. Her bir istasyon için enlem, boylam, yükseklik ve zaman damgalarıyla kaydedilen veriler, GNSS ağının doğruluğunu artırmak amacıyla X, Y, Z bileşenleri ile ENU (East-North-Up) koordinat sistemine dönüştürülmüştür. Ayrıca, standart sapmalar ile bileşenler arası korelasyon katsayıları hesaplanarak ölçüm doğruluğu değerlendirilmiştir. GNSS verilerinin bu şekilde yapılandırılması, tektonik deformasyonların modellenmesi için sağlam bir temel sunmuştur (Reilinger ve diğ. 2006).

Konum verileri, Harita Genel Müdürlüğü Jeodezi Dairesi Başkanlığı tarafından sağlanan Türkiye Ulusal Sabit Jeodezik İstasyon Ağı (TUSAGA-AKTİF) üzerinden indirilmiştir (HGM 2024). Bolu ilinde 2008-2018 yılları arasında çalışan

eski istasyon (BOLU) verileri ile 2018 yılında çalışmaya başlayan yeni istasyon (BOL1) verileri (Şekil 7) birleştirilerek kullanılmıştır. BOLU istasyonu (40.733539 enlem, 31.602032 boylam) ile BOL1 istasyonu (40.74641018 enlem, 31.60648982 boylam) arasındaki mesafe yaklaşık 1.5 km olarak hesaplanmıştır. İstasyonların birbirine olan yakınlığı nedeniyle iki konum arasında anlamlı bir yer deformasyonu olmadığı kabul edilmiş; bu doğrultuda, 2018 sonrasında BOL1 istasyonunda ölçülen yerdeğiştirme değerleri, önceki BOLU istasyon verilerine eklenerek veri seti bütünleştirilmiştir.

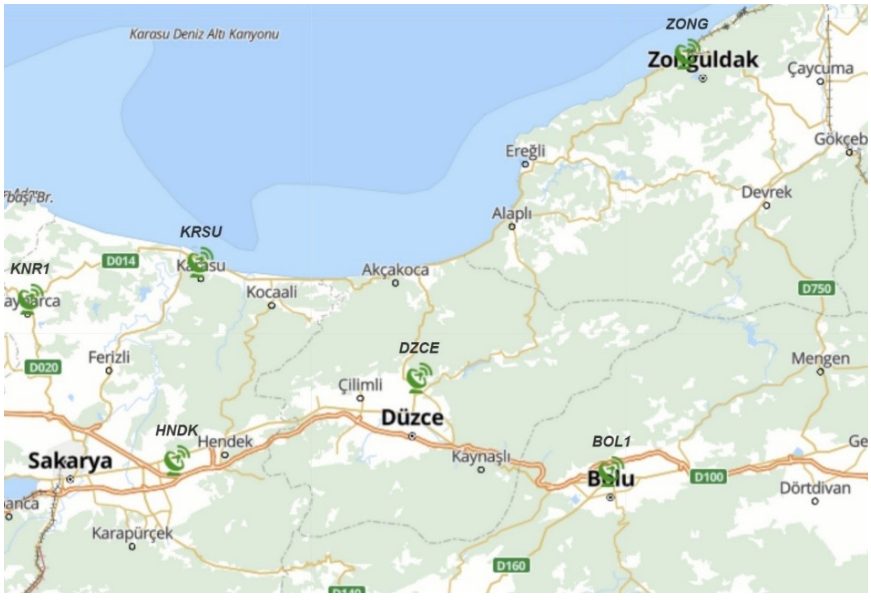


```
Dosya   Düzenle   Görünüm

PBO Station Position Time Series. Reference Frame : IGb14
Format Version: 1.1.1
4-character ID: BOL1
Station name  : BOL1_GPS
First Epoch   : 20181024 115900
Last Epoch    : 20231231 115900
Release Date  : 20240326 223757
XYZ Reference position :   4121753.62786  2536363.59393  4141652.64499 (IGb14)
NEU Reference position :     40.7464125072   31.6064921928  802.54895 (IGb14/WGS84)
Start Field Description
YYYYMMDD      Year, month, day for the given position epoch
HHMMSS        Hour, minute, second for the given position epoch
JJJJJ.JJJJJ   Modified Julian day for the given position epoch
X             X coordinate, Specified Reference Frame, meters
Y             Y coordinate, Specified Reference Frame, meters
Z             Z coordinate, Specified Reference Frame, meters
Sx            Standard deviation of the X position, meters
Sy            Standard deviation of the Y position, meters
Sz            Standard deviation of the Z position, meters
Rxy           Correlation of the X and Y position
Rxz           Correlation of the X and Z position
Ryz           Correlation of the Y and Z position
Nlat          North latitude, WGS-84 ellipsoid, decimal degrees
Elong         East longitude, WGS-84 ellipsoid, decimal degrees
Height (Up)   Height relative to WGS-84 ellipsoid, m
dN            Difference in North component from NEU reference position, meters
dE            Difference in East component from NEU reference position, meters
du            Difference in vertical component from NEU reference position, meters
Sn            Standard deviation of dN, meters
Se            Standard deviation of dE, meters
Su            Standard deviation of dU, meters
Rne           Correlation of dN and dE
Rnu           Correlation of dN and dU
Reu           Correlation of dEand dU
Soln          "rapid", "final", "suppl/suppf", "campd", or "repro" corresponding to products  generated with rapid or final orbit products, in supplemental processing, campaign data
processing or reprocessing
End Field Description
*YYYYMMDD HHMMSS JJJJJ.JJJJ          X           Y           Z          Sx       Sy       Sz     Rxy   Rxz   Ryz          NLat         Elong        Height        dN        dE
du          Sn      Se      Su      Rne     Rnu     Reu  Soln
 20181024 115900 58415.4993  4121753.66574  2536363.57910  4141652.61850  0.00464  0.00324  0.00440  0.797  0.827  0.755     40.7464121826   31.6064918082  802.55020    -0.03614  -0.03244
```

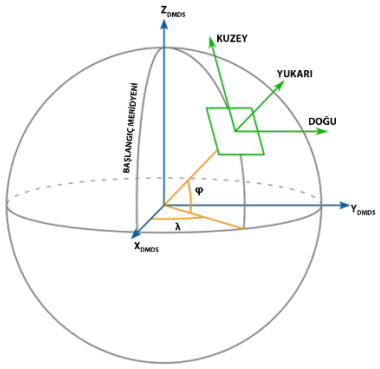
Şekil 7: *Harita Genel Müdürlüğü web sayfasından elde edilen zaman serisi veri içeriğine örnek (Bolu istasyonu) (HGM 2024)*
Figure 7: *An example of the time series data content obtained from the General Directorate of Mapping website for the Bolu station (HGM 2024)*

Bu çalışmada, Bolu ve Hendek bölgesinin göreceli hareketi analizlerde kullanılmıştır. ENU koordinatlarının hesaplanabilmesi için referans bir konuma ihtiyaç duyulmuştur. Bu amaçla, Avrasya plakasında yer alan Bolu-Hendek bölgesine en yakın TUSAGA istasyonu verilerinin kullanılması uygun görülmüştür (Şekil 8). Belirlenen zaman aralığında gerekli verileri sağlayabilen en yakın istasyon, Zonguldak ilindeki ZONG istasyonu olmuştur.



Şekil 8: *Bolu ve Hendek bölgelerindeki TUSAGA-Aktif istasyonları*
Figure 8: *TUSAGA-Active stations in the Bolu and Hendek regions*

ECEF koordinatlarından ENU koordinatlarına dönüşüm, Bolu ve Hendek istasyonları için ayrı ayrı gerçekleştirilmiştir. ZONG istasyonunun 2008-2023 tarih aralığındaki günlük konumları referans alınarak, Bolu ve Hendek istasyonlarının ENU koordinatları hesaplanmıştır (Şekil 9). Bu dönüşüm sürecinde, öncelikle istasyonların ECEF koordinatları arasındaki farklar belirlenmiştir.



Şekil 9: *ECEF ve ENU koordinatları (Kuna ve diğ. 2020)*
Figure 9: *ECEF and ENU coordinates (Kuna ve diğ. 2020)*

$$\Delta X = X - X_0$$
$$\Delta Y = Y - Y_0$$
$$\Delta Z = Z - Z_0$$

X,Y,Z koordinatları hedef istasyonun, X_0,Y_0,Z_0 koordinatları ise referans istasyonun ECEF sistemindeki konumlarını ifade etmektedir. Göreceli ECEF koordinatlarından ENU koordinatlarının hesaplanmasında, referans istasyonun enlem ve boylam değerlerine dayalı olarak oluşturulan dönüşüm matrisi kullanılmıştır.

$$\begin{bmatrix} E \\ N \\ U \end{bmatrix} = \begin{bmatrix} -\sin\lambda_0 & \cos\lambda_0 & 0 \\ -\sin\phi_0\cos\lambda_0 & -\sin\phi_0\sin\lambda_0 & \cos\phi_0 \\ \cos\phi_0\cos\lambda_0 & \cos\phi_0\sin\lambda_0 & \sin\phi_0 \end{bmatrix} \begin{bmatrix} \Delta X \\ \Delta Y \\ \Delta Z \end{bmatrix}$$

Burada E, N ve U hedef istasyonun doğu, kuzey ve yukarı koordinatlardaki konum verisi, λ_0 ve ϕ_0 referans istasyonun sırasıyla boylam ve enlem değerlerini temsil etmektedir. ZONG istasyonu için bu değerler, ECEF koordinatlarından türetilmiştir. Bu amaçla, ECEF'ten jeodezik (geodetic) koordinatlara dönüşümde iteratif çözümleme yöntemi uygulanmıştır. Bu işlemde, yaygın olarak kullanılan yöntemlerden biri olan Newton-Raphson tabanlı iteratif çözüm tercih edilmiştir (Hofmann-Wellenhof 2001). Çözümleme sürecinde ilk olarak boylam hesaplaması gerçekleştirilmiştir (Denklem 6):

$$\lambda = tan^{-1}(Y/X) \quad (6)$$

İlk Enlem Tahmini (Denklem 7):

$$\varphi_0 = tan^{-1}(Z / \sqrt{(X^2 + Y^2)}) \quad (7)$$

Bu enlem tahminiyle iteratif olarak aşağıdaki parametreler hesaplanmıştır (Denklem 8, 9, 10):

$$N = a / \sqrt{(1 - e^2 \sin^2\varphi)} \quad (8)$$

$$h = (\sqrt{(X^2 + Y^2)} / cos\varphi) - N \quad (9)$$

$$\varphi_{i+1} = tan^{-1}((Z + N\, e^2 \sin\varphi_i) / \sqrt{(X^2 + Y^2)}) \quad (10)$$

Burada, a: Yarı büyük eksen, f: basıklık, b: Yarı küçük eksen, e: eksentriklik değerleridir. WGS84 referans sistemine göre

$$a = 6{,}378{,}137.0 \text{ m}$$

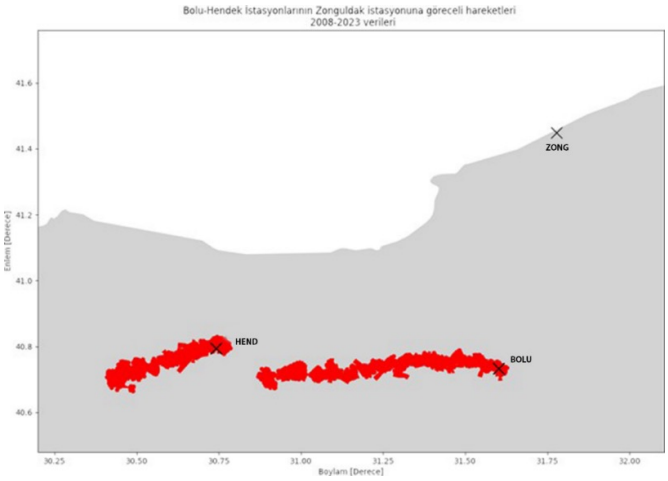
$$f = 1/298.257223563$$

olarak kabul edilmiştir. b ve e değerleri aşağıdaki gibi hesaplanmaktadır (Denklem 11, 12).

$$b = a(1 - f) \quad (11)$$

$$e^2 = (a^2 - b^2) / a^2 \quad (12)$$

Bu çözümlemeler sonucunda elde edilen hareket verilerinin büyütülmüş vektörel gösterimi Şekil 10'da sunulmuştur. ZONG istasyonu, referans nokta olarak belirlendiği için hareket göstermemiştir. Şekil incelendiğinde Bolu istasyonunun Hendek istasyonuna doğru bir yaklaşma eğiliminde olduğu gözlemlenmiştir. Bu çalışmada, Bolu istasyonunun Hendek istasyonuna göre göreceli hareketi sismik verilerle birlikte değerlendirilmiştir.



Şekil 10: *BOLU ve HNDK istasyonlarının ZONG istasyonuna göreceli hareketi*
Figure 10: *Relative motion of the BOLU and HNDK stations with respect to the ZONG station*

5. BULGULAR

Bu çalışmada, hareket verileri ve sismik veriler birleştirilirken bir stres modeli kullanılmıştır. Bu modelde, iki istasyon arasındaki hareket farkı stresin artmasına neden olmuş; sismik hareketler ise stresin azalmasına katkı sağlamıştır. Böylece, sismik hareketlerin tahmini amacıyla stres birikimi dikkate alınmıştır. Ancak, istasyonların göreceli hareketinden kaynaklanan stres birikiminin veya sismik olayları tetikleyen kırılmaların stresi ne ölçüde azalttığını tahmin etmek oldukça zordur. Plakaların üç boyutlu yapılarının ve malzeme özelliklerinin tam olarak bilinmemesi, bu etkileşimlerin stres birikimine olan katkısını belirlemeyi güçleştirmiştir. Bu nedenle, stres birikiminin bölgeye özgü biçimde tespit edilebilmesi amacıyla makine öğrenmesi tekniklerinin kullanımı araştırılmıştır. LSTM modeli, zaman içerisinde yapısı değişen zaman serilerinin tahmininde başarılı sonuçlar vermesiyle tercih edilmiştir. Bu doğrultuda, sismik verilerin tahmininde en iyi sonuçları sağlayan parametre değerleri belirlenmeye çalışılmıştır. Bu parametrelerden ikisi, hareketin strese katkısını ve sismik olayların stresi azaltma etkisini temsil eden katsayılar olarak modellenmiştir. Bu çalışmada,

stres, sismik hareketler ve sismik hareketlerin birikimli toplam değerleri girdi olarak kullanılarak, sismik hareketlerin ve birikimli sismik hareketlerin tahmin edilmesine yönelik bulgular değerlendirilmiştir. Aşağıdaki alt başlıklarda, farklı girdi-çıktı yapılarına ve hiperparametre değerlerine göre elde edilen sonuçlar sunulmuştur.

5.1) Sismik Verilerin Doğrudan Tahmini

Sismik verileri doğrudan tahmin etmek için eğitilen LSTM model parametreleri Tablo 4'te verilmiştir. Modelin performansını optimize etmek amacıyla, farklı hiperparametre kombinasyonları üzerinde sistematik bir arama gerçekleştirilmiştir. Bu süreçte, ızgara arama ve bayesian optimizasyonu gibi yaygın olarak kullanılan hiperparametre optimizasyon yöntemlerinden yararlanılmıştır. Özellikle epoch sayısı, batch size, lookback (geçmiş zaman adımı sayısı), nöron sayısı ve dropout oranı gibi kritik hiperparametreler, modelin eğitim ve test verileri üzerindeki performansı dikkate alınarak belirlenmiştir. Bu parametrelerin her biri, modelin hem eğitim sürecindeki öğrenme kapasitesi hem de test verileri üzerindeki genelleme yeteneği üzerinde doğrudan etkili olmuştur. Bu nedenle, farklı hiperparametre kombinasyonları denenmiş; deneysel sonuçlar doğrultusunda aşırı öğrenme (overfitting) ve düşük öğrenme (underfitting) sorunlarından kaçınılacak optimal değerler tercih edilmiştir. Tablo 4'te sunulan bu değerler, modelin eğitim verisi üzerinde yüksek doğruluk elde etmesine ve test verisi üzerinde genelleme yeteneğini korumasına katkı sağlamıştır.

Tablo 4: *LSTM modeli eğitim parametreleri*
Table 4: *LSTM Model Training Parameters*

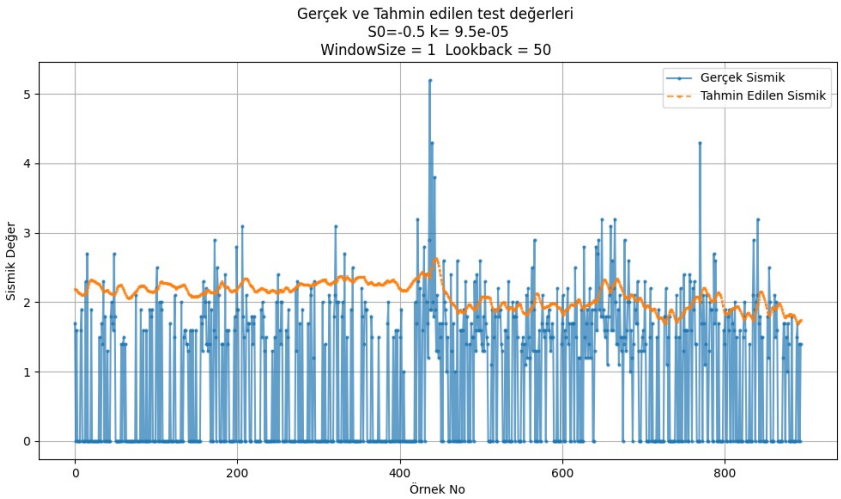
Model parametresi	Değer
Kayıp Fonksiyonu	Ağırlıklı Kayıp Fonksiyonu
Geçmiş Zaman Adımı Sayısı	50
Epok Sayısı	25
Toplu İşleme Boyutu	64
Nöron Sayısı	150
Zaman Serisi Bölme Değeri	5

Ayrıca, düşürme (dropout) oranı %20 olarak belirlenmiş ve bu sayede modelin aşırı öğrenme eğilimi azaltılarak daha tutarlı bir performans elde edilmesi amaçlanmıştır. Özellikle lookback parametresi zaman serisindeki geçmiş bilginin tahmin gücü üzerindeki etkisini belirlemek amacıyla çeşitli uzunluklarda test edilmiştir. Yapılan bu sistematik hiperparametre optimizasyonu, modelin sismik aktiviteleri tahmin etme başarımını artırmak amacıyla dikkatli ve deneysel bir şekilde yürütülmüştür. Literatürde de belirtildiği üzere, LSTM modellerinin performansı bu tür hiperparametre seçimlerine son derece duyarlıdır ve özenle yapılmış ayarlamalar model doğruluğu üzerinde belirleyici rol oynamaktadır (Chollet, 2018). Modelde girdi değişkenleri olarak sismik veriler ve stres değerleri kullanılmış; çıktı değişkeni olarak ise sismik veriler belirlenmiştir. Stres değerleri için başlangıç stres (S_0) ve sismik aktivitenin katkı oranı (k) parametreleri , LSTM modelinde en düşük kayıp değerini sağlayan kombinasyonları belirlemek amacıyla değerlendirilmiştir. S_0 değeri için -5 ile 20 aralığında, k değeri için 1 ile 20 aralığında tarama yapılmış ve Tablo 5'te sunulan sonuçlar elde edilmiştir.

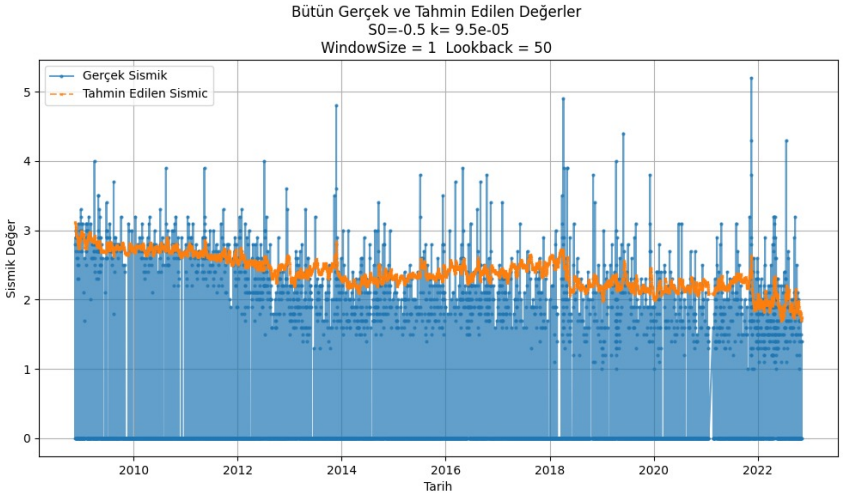
Tablo 5: *En düşük kayıp değerini veren parametre değerleri*
Table 5: *The parameter values that yield the lowest loss*

Parametre	Değer
Başlangıç Stres Değeri (S_0)	-0.5
Sismik Aktivite katkısı (k)	9.5×10^{-5}
Ağırlıklı Kayıp Değeri (Weighted Loss)	0.001193
Ortalama hata karesi (MSE)	3.7375

Şekil 11'de, test verilerinin gerçek ve tahmin edilen değerleri karşılaştırılmıştır. Model, 2-3 büyüklük aralığındaki verilerin tahmininde görece başarılı sonuçlar üretmiş; ancak daha yüksek ya da düşük sismik değerlerin tahmininde yetersiz kalmıştır. Seçilen kayıp fonksiyonu, büyük sismik aktivitelerin tahminine öncelik vermeyi hedeflemiş olsa da, 3 ve üzeri büyüklükteki depremlerin tahmininde istenen başarı elde edilememiştir. Tüm verilerin LSTM modeliyle tahmini sonucunda elde edilen çıktılar Şekil 12'de sunulmuştur. Bu grafik doğrultusunda, modelin sismik aktivitelerin genel eğilimine uyum sağladığı, ancak nadir gerçekleşen yüksek büyüklükteki olayların doğrudan tahmin edilemediği görülmüştür. Büyük değerlere daha duyarlı olan kayıp fonksiyonunun ürettiği değer yaklaşık 1.2×10^{-3} olarak gerçekleşmektedir. Büyük depremlerin tahmininin başarılı olduğu durumda bu değerin 10^{-6} seviyesinde olması beklenmektedir. Bu nedenle modelin başarısız olduğu söylenebilir.

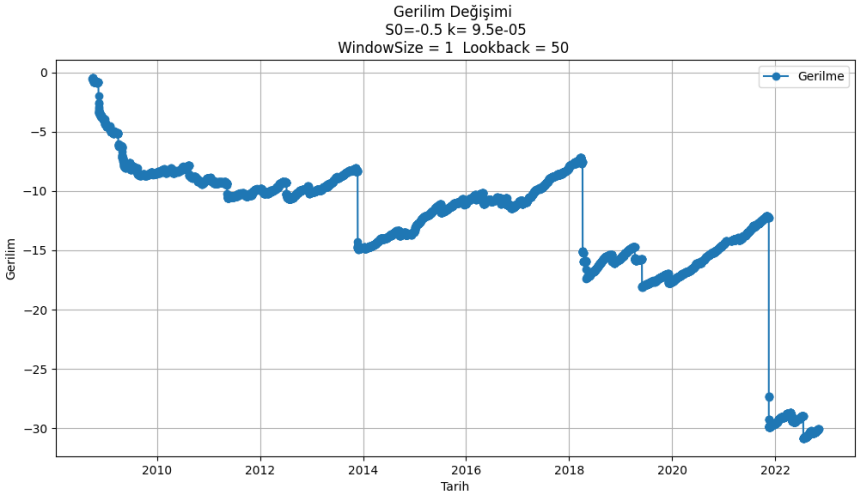


Şekil 11: *Sismik değerlerin doğrudan tahmin edildiği model – Test verileri*
Figure 11: *Model with Direct Prediction of Seismic Values – Test data*



Şekil 12: *Sismik değerlerin doğrudan tahmin edildiği model – Tüm veriler*
Figure 12: *Model with Direct Prediction of Seismic Values – All data*

Şekil 13'te, LSTM modelinde en düşük kayıp değerlerini sağlayan stres değişimi sunulmuştur. Bu süreçte, harekete bağlı olarak stres artışı gözlemlenirken, sismik aktivitelerin stresi azalttığı (negatif yönde) bir değişim ortaya çıkmıştır. Bu sonuç, sismik aktivitelerin genel düşüş eğilimi ile tutarlı bulunmuştur. 2023 yılına yaklaşıldıkça sismik aktivitelerin büyüklüğünde bir azalma gözlemlenmiş ve bu azalma, stres seviyelerindeki düşüş ile uyumlu olarak değerlendirilmiştir. Bu bağlamda, sismik aktivite yoğunluğunun stres değişimine etkisi ayrıca incelenmiş ve bu değerlendirme bir sonraki bölümde sunulmuştur.



Şekil 13: *Sismik değerlerin doğrudan tahmin edildiği model – Stres değişimi*
Figure 13: *Model with Direct Prediction of Seismic Values – Stress change*

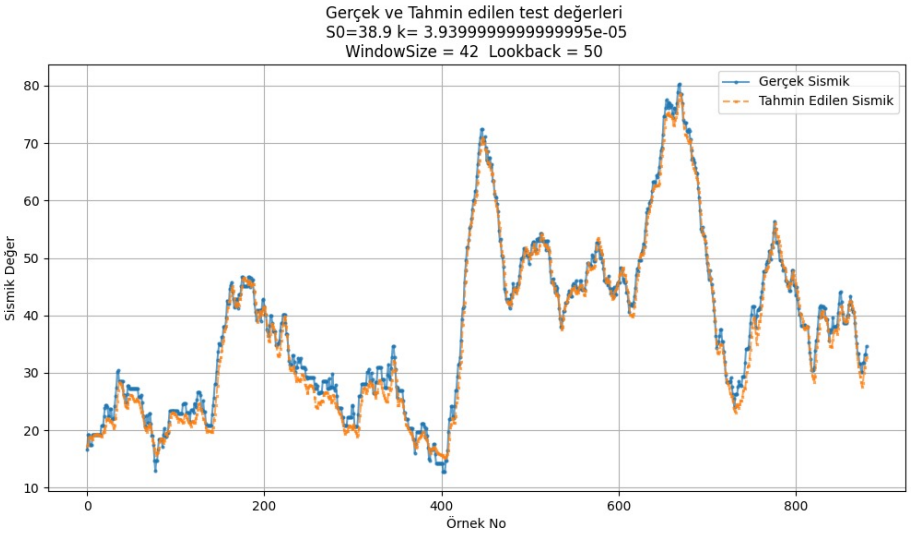
5.2) Birikimli Sismik Aktivite Tahmini

Bu bölümde, sismik aktivitelerin belirli bir pencere içinde toplanarak elde edilen değerlerin tahminine yönelik analiz gerçekleştirilmiştir. Söz konusu toplam değerler, her bir sismik olaydan önceki pencere içerisine giren sismik olayların toplanmasıyla elde edilmiştir (Rolling sum). Bu toplamlar, sismik olaylar sonucunda açığa çıkan enerjinin birikimli bir temsili olarak değerlendirilmiştir. Bu tahmin sürecinde, Tablo 3'te sunulan hiperparametrelere ek olarak pencereleme (rolling sum window) değeri de parametre olarak kullanılmıştır. LSTM modelinde kaybı en aza indiren stres parametrelerinin belirlenmesi amacıyla, parametre arama süreci yeniden yürütülmüştür. S_0 için -10 ila 60 aralığında, k katsayısı için 1×10^{-6} ila 50×10^{-6} aralığında ve pencere genişliği için 2 ila 100 aralığında tarama yapılmıştır. Bu arama sürecine ilişkin sonuçlar Tablo 6'da sunulmuştur.

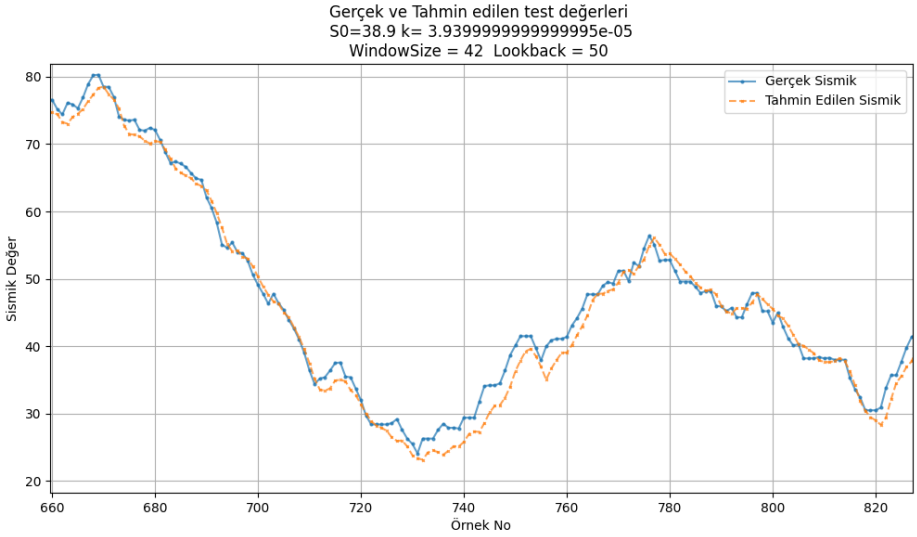
Tablo 6: *En düşük kayıp değerini veren parametre değerleri- Birikimli sismik veri*
Table 6: *Parameter values that yield the lowest loss – Cumulative seismic data*

Parametre	Değer
Başlangıç Stres Değeri (S_0)	38.9
Sismik Aktivite katkısı (k)	3.94×10^{-5}
Ağırlıklı Kayıp Değeri (Weighted Loss)	0.0001037
Ortalama hata karesi (MSE)	143.24
Pencere genişliği	42

Şekil 14'te, test verilerinin gerçek ve tahmin edilen değerleri karşılaştırılmıştır. Bu şeklin belirli bir aralığına ait yakınlaştırılmış grafik ise Şekil 15'te sunulmuştur. Yakınlaştırılmış verilere göre, modelin tahmin performansının test verileriyle genel olarak uyumlu olduğu gözlemlenmiştir.



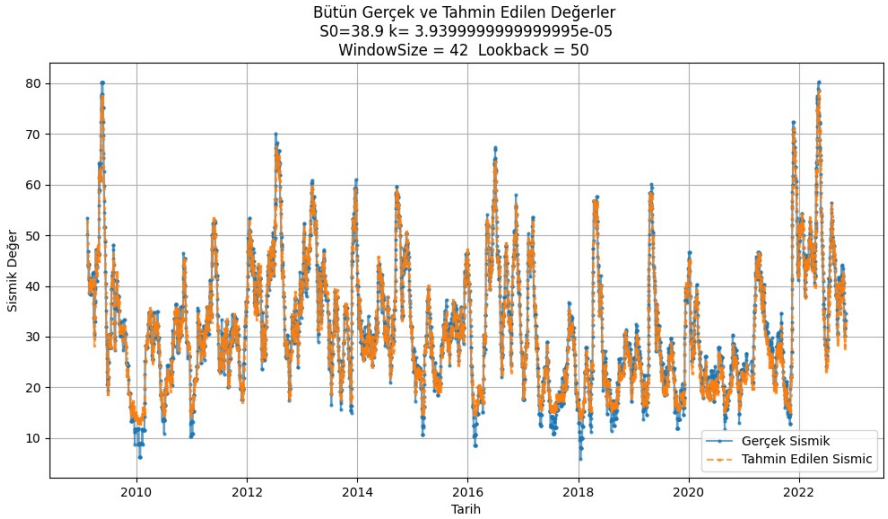
Şekil 14: *Birikimli Sismik değerlerin tahmin edildiği model – Test verileri*
Figure 14: *Model for Predicting Cumulative Seismic Values – Test Data*



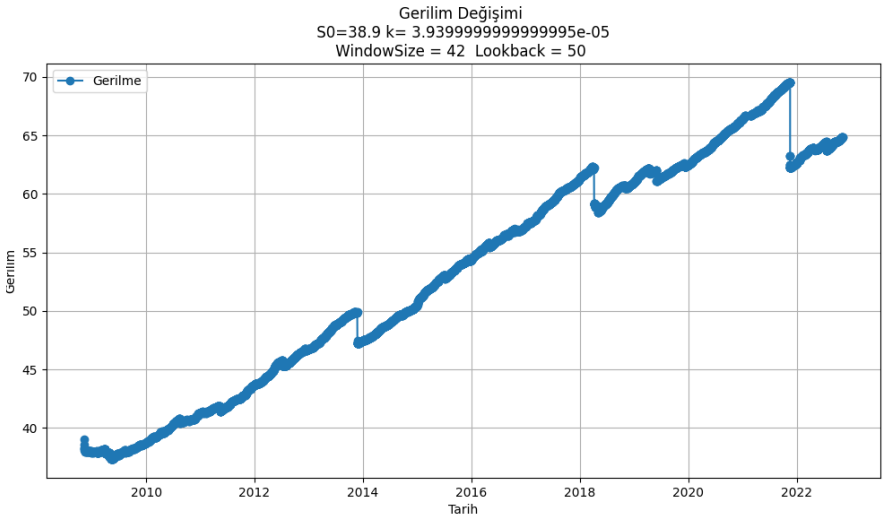
Şekil 15: *Birikimli sismik değerlerin tahmin edildiği model – Yakınlaştırılmış test verileri*
Figure 15: *Model for predicting cumulative seismic values – Zoomed-in Test Data*

Şekil 16'da, tüm verilerin LSTM modeli ile tahmin edilmesi sonucunda elde edilen çıktı sunulmuştur. Modelde kullanılan ağırlıklandırılmış kayıp fonksiyonu, büyük birikimli sismik aktivitelerin tahminine öncelik vermiştir. Ancak modelin düşük büyüklükteki değerlerdeki performansı sınırlı kalmış ve bu durum ortalama hata karesinin yüksek olmasına neden olmuştur.

Şekil 17, stres birikiminin Bolu-Hendek istasyonlarının göreceli hareketine bağlı olarak zaman içinde arttığını ve sismik aktivitelerin bu birikimi azalttığını ortaya koymuştur. Bu değişim, LSTM modelinin en iyi tahmin performansını gösterdiği parametrelerin belirlenmesiyle elde edilmiştir. Grafik analizine göre, stres seviyesinin yaklaşık 70 birime ulaştığı dönemde 5'ten büyük bir depremin meydana geldiği gözlemlenmiştir. 2021 yılı 17 Kasım tarihinde gerçekleşen 5.2 büyüklüğündeki depremi aynı bölgede gerçekleşen 4.3 ve 3.8 büyüklüğündeki depremler takip etmiştir. Bu sismik aktiviteleri grafikteki 70 birim stres değerinden 62 birime düşüş olarak görmekteyiz. Aynı şekilde, 2023 yılı içerisinde stresin yeniden bu seviyeye yaklaştığı tespit edilmiştir. Bu gözlem, benzer büyüklükte bir sismik aktivitenin oluşma olasılığına dair ön bilgi sağlamıştır.



Şekil 16: *Sismik değerlerin tahmin edildiği model – Tüm veriler*
Figure 16: *Model for Predicting Seismic Values – All Data*



Şekil 17: *Birikimli sismik değerlerin tahmin edildiği model – Gerilim değişimi*
Figure 17: *Model for predicting cumulative seismic values – Stress Change*

6. TARTIŞMA

Bu çalışma, Bolu ve çevresindeki Kuzey Anadolu Fay Zonu'na ait GNSS hareket verileri ile aletsel dönem deprem kayıtlarını kullanarak, LSTM tabanlı derin öğrenme modelleri aracılığıyla deprem büyüklüğü tahmini gerçekleştirmeyi amaçlamıştır. Elde edilen bulgular, küçük ve orta büyüklükteki depremlerin tahmininde GNSS verileri ile stres birikimine dayalı modellemenin istatistiksel olarak anlamlı sonuçlar üretebildiğini göstermiştir. Ancak, büyük depremlerin tahmini konusunda modelin doğruluk düzeyi sınırlı kalmıştır. Bu durum, büyük depremlerin nadir meydana gelmesi ve karmaşık oluşum dinamikleri nedeniyle gözlemlenen veri eksikliği ile ilişkilendirilmiştir.

Modelin doğrudan deprem büyüklüğü tahmininde sınırlı performans sergilemesine karşın, birikimli sismik aktivitenin tahminine dayalı ikinci yaklaşımda doğruluk düzeyinde anlamlı bir iyileşme elde edilmiştir. Özellikle stres birikiminin belirli eşik değerlerini aşması durumunda, daha yüksek büyüklükteki depremlerle ilişkili olabilecek sinyaller gözlemlenmiştir. Stres seviyesinin 70 birime ulaştığı dönemlerde, M ≥ 5.0 büyüklüğünde depremlerin meydana geldiği kaydedilmiştir. Ancak, bu seviyenin üzerindeki stres birikimlerine ait örnek sayısının yetersiz olması, daha büyük depremlerle ilgili model öngörülerinin test edilmesini sınırlamıştır.

Modelin büyük depremleri öngörmedeki sınırlı başarısı, yalnızca GNSS verilerinin kullanımına bağlı olarak tam anlamıyla açıklanamamıştır. Büyük depremlerin, çoğu zaman doğrusal olmayan ve ani gelişen fiziksel süreçlerle ilişkili olduğu bilinmektedir. Bu nedenle, yalnızca yüzey hareketlerine dayalı stres modellemesi bazı durumlarda yetersiz kalmıştır. Literatürde de benzer şekilde, büyük depremlerin tahmininde jeolojik, sismolojik ve hidrotermal verilerin birlikte kullanılması gerektiği ifade edilmiştir (Reilinger ve diğ. 2006 , Huang ve diğ. 2018, Kavianpour ve diğ. 2021a).

Bu çalışma kapsamında elde edilen bulgular doğrultusunda, gelecekteki araştırmalara yönelik bazı yönelimler belirlenmiştir. İlk olarak, modelin büyük deprem geçmişine sahip farklı bölgelerde yeniden eğitilerek test edilmesi ve bu sayede öngörü başarısının karşılaştırmalı biçimde değerlendirilmesi

mümkün olmuştur. Ayrıca, Transformer ve CNN-LSTM gibi daha gelişmiş derin öğrenme mimarilerinin değerlendirilmesi, tahmin performansının iyileştirilmesi açısından dikkate alınabilecek bir yaklaşım olarak öne çıkmıştır. Mikro-deprem verileri ile sık aralıklı GNSS ağlarından elde edilen yüksek çözünürlüklü verilerin entegrasyonu sayesinde modellerin mekânsal ve zamansal doğruluğu üzerinde olumlu etkiler gözlemlenmiştir. Son olarak, sismik aktivitenin yalnızca stres birikimi ile değil, aynı zamanda yerel fay geometrileri, kayaç özellikleri ve derinlik gibi parametrelerle birlikte ele alınması, çok katmanlı tahmin modellerinin geliştirilmesine zemin hazırlamıştır.

Bu çalışma, GNSS tabanlı derin öğrenme yaklaşımlarının deprem büyüklüğü tahmininde uygulanabilirliğini ortaya koymuş ve bu alandaki literatüre katkı sağlamıştır. Özellikle stres temelli fiziksel modellerin yapay zeka ile entegrasyonu, geleneksel tahmin yöntemlerine kıyasla daha dinamik ve veriye dayalı bir yaklaşım sunmuştur.

7. SONUÇLAR

Bu çalışma, GNSS istasyonlarından elde edilen hareket verileri ile aletsel dönem sismik aktivite verilerini bütünleştirerek, Kuzey Anadolu Fay Zonu üzerindeki stres birikiminin zamansal dinamiklerini modellemiş ve bu stresin sismik olaylarla ilişkisini incelemiştir. Çalışma kapsamında, GNSS kaynaklı strain verileri ile deprem büyüklüklerine dayalı stres hesaplamaları birleştirilmiş; zaman içinde değişen stres düzeyleri, LSTM tabanlı derin öğrenme modelleri aracılığıyla tahmin edilmiştir.

Elde edilen sonuçlar, stres ile sismik aktivite arasındaki doğrusal olmayan ilişkilerin LSTM modeli tarafından öğrenilebildiğini ortaya koymuştur. Model, özellikle küçük ve orta büyüklükteki depremlerin tahmininde göreli olarak başarılı sonuçlar üretmiştir. Ancak, büyük ölçekli depremlerin tahmininde modelin performansı sınırlı kalmış; bu durum, veri setindeki dengesizlik ve büyük depremlerin düşük gözlemlenme sıklığı ile ilişkilendirilmiştir.

Dinamik stres modellemesinin GNSS verileriyle birlikte kullanılması, fay zonlarının zamansal davranışlarının modellenmesine yönelik çalışmalarda anlamlı katkılar sunmuştur. Ayrıca, stres birikiminin belirli eşik değerlere ulaştığı dönemlerde sismik aktivitenin arttığına ilişkin bulgular elde edilmiştir. Bu gözlemler, stres düzeyinin potansiyel bir ön belirleyici değişken olarak değerlendirilebileceğine yönelik çıkarımlara zemin hazırlamıştır.

Çalışma bulguları, GNSS verilerinin sismik öngörü amacıyla kullanılmasında önemli bir potansiyelin bulunduğunu göstermiş ve derin öğrenme yöntemlerinin bu alandaki uygulanabilirliğine yönelik ampirik destek sunmuştur. Elde edilen model, fay zonundaki stres birikimi ile sismik aktivite arasındaki ilişkiyi hem istatistiksel hem de yapay zeka temelli bir yaklaşımla ortaya koymuştur. Şekil 17'de stres birikimi ve sismik aktiviteye bağlı stres boşalmaları izlenebilmektedir. Stress seviyesinin 50 birime yaklaştığı dönemde 4.8 büyüklüğünde (24.11.2013) deprem oluşmuştur. Stress seviyesi sonrasında 62 birime yaklaşmış ve 4.9 büyüklüğünde deprem (07.04.2018) gerçekleşmiştir. Stres seviyesinin 70 birime ulaşmasıyla sırasıyla 5.2, 4.3 ve 3.8 (17.11.2021) büyüklüğünde depremler gerçekleşmiş ve stres seviyesi tekrar 62 değerine dönmüştür. Bundan sonraki süreçte stres değeri tekrar yükselmeye devam etmiştir. Günümüzdeki stres değerlerini elde edebilmek ve gelecekteki deprem büyüklüğü ilgili tahmin yürütmek için 2023 yılın sonundan günümüze kadar olan GNSS verilerinin de elde edilmesi gerekmektedir.

Bu çalışmada elde edilen sonuçlar doğrultusunda, modelin farklı tektonik bölgelerde uygulanarak sınanması ve mikro sismik veriler ile sık konumlandırılmış GNSS ağlarının entegrasyonu aracılığıyla doğruluğun artırılması yönünde bir potansiyel belirlenmiştir. Ayrıca, jeolojik, sismolojik ve termal parametrelerin modele entegre edilmesiyle daha kapsamlı tahmin sistemlerinin oluşturulabileceğine ilişkin değerlendirmelere ulaşılmıştır.

KAYNAKLAR

AFAD, 2025. Deprem Kataloğu, T.C. İçişleri Bakanlığı Afet ve Acil Durum Yönetimi Başkanlığı, Erişim adresi: https://deprem.afad.gov.tr/event-catalog.

Aktug B., Ozener H., Dogru A., Sabuncu A., Turgut B., Halicioglu K., Yilmaz O., Havazli E., 2016. Slip rates and seismic potential on the East Anatolian Fault System using an improved GPS velocity field, Journal of Geodynamics, Volumes 94-95, Pages 1-12, ISSN 0264-3707, https://doi.org/10.1016/j.jog.2016.01.001.

Asim M., Khan R.A., Uddin M., 2018. Analysis of seismic data using recurrent neural networks, Microsystem Technologies, 24(12), 4959-4968, https://doi.org/10.1007/s00542-018-4085-7.

Banna M.H.A., Tuba R.T., Tuba M., AlZain M.A., 2021. A bidirectional LSTM with attention mechanism for earthquake prediction, IEEE Access, 9, 141883-141892.

Bao Y., Li H., Zhang Y., Wu Y., 2021. Deep learning-based earthquake prediction using geoelectric signals, IEEE Access, 9, 149182-149194.

Barka A.A., 1992. The North Anatolian Fault Zone. Annales Tectonicae, 6; 164-195.

Barka A., 1996. Slip distribution along the North Anatolian fault associated with the large earthquakes of the period 1939 to 1967, Bulletin of the Seismological Society of America, 86(5), 1238-1254.

Bengio Y., 2012. Practical recommendations for gradient-based training of deep architectures, In Neural Networks: Tricks of the Trade, Lecture Notes in Computer Science, Springer.

Bergmeir C., Benítez J.M., 2012. On the use of cross-validation for time series predictor evaluation, Information Sciences, 191, 192-213.

Bergstra J., Bengio Y., 2012. Random search for hyper-parameter optimization, Journal of Machine Learning Research, 13, 281-305.

Bilal M.A., Ji Y., Wang Y., Akhter M.P., Yaqub M., 2022. An early warning system for earthquake prediction from seismic data using batch normalized graph convolutional neural network with attention mechanism (BNGCNNAtt.), Sensors, 22(17); 6482.

Bozkurt E., 2001. Neotectonics of Turkey-a synthesis, Geodinamica Acta, 14(1-3), 3-30, https://doi.org/10.1080/09853111.2001.11105302.

Cambaz D., Kalafat D., Örgülü G., Kekovalı K., Kadirioğlu F.T., Özel N.M., Erdoğan S., 2019. Türkiye'deki deprem kayıtlarının güncellenmesi ve analizi üzerine Kandilli Rasathanesi veritabanı uygulamaları, Jeofizik Dergisi, 34(2), 45-57.

Cheloni D., Tolomei C., Salvi S., Atzori S., Serpelloni E., 2025. Doğu Anadolu Fay Zonu boyunca GNSS ve InSAR verileriyle sismojenik segmentlerin gerinim alanlarının modellenmesi, Remote Sensing, 17(13), 2270.

Chollet F., 2018. Deep Learning with Python, Manning Publications, Shelter Island, NY.

Çağlayan A., Işık V., Saber R., 2019. An assessment of Holocene seismic activity on 1944 Earthquake Segment, North Anatolian Fault Zone (Turkey), Geosciences Journal, 1-18.

Feurer M., Klein A., Eggensperger K., Springenberg J.T., Blum M., Hutter F., 2015. Efficient and robust automated machine learning, Advances in Neural Information Processing Systems (NeurIPS), 28.

Goodfellow I., Bengio Y., Courville A., 2016. Deep Learning, MIT Press, pp 295-310.

HGM, 2024. Türkiye Ulusal Sabit Jeodezik İstasyon Ağı-TUSAGA, Erişim adresi: https://www.harita.gov.tr/sunum/.

Hobbs B.E., Means W.D., Williams P.F., 1976. An Outline of Structural Geology, Wiley, New York.

Hochreiter S., Schmidhuber J., 1997. Long short-term memory, Neural Computation, 9(8), 1735-1780.

Hofmann-Wellenhof B., Lichtenegger H., Collins J., 2001. Global Positioning System: Theory and Practice, Springer.

Hsu C.Y., Pratomo B.A., 2022. LSTM-based deep learning for earthquake early warning system using seismic waveform data, IEEE Access, 10, 34727-34735.

Hubert-Ferrari A., Barka A., Jacques E., Nalbant S.S., Meyer B., Armijo R., Tapponnier P., King G.C.P., 2002. Seismic hazard in the Marmara Sea region: new constraints from fault slip rates and historical earthquakes, Geophysical Journal International, 153(3), 597-622.

Hutton L.K., Boore D.M., 1987. The ML scale in southern California, Bulletin of the Seismological Society of America, 77(6), 2074-2094.

Hyndman R.J., Athanasopoulos G., 2018. Forecasting: Principles and Practice (2nd ed.).

Kalafat D., Kekovalı K., Pınar A., Yılmazer M., Kara M., 2011. A revised and extended earthquake catalog for Turkey since 1900 (M ≥ 4.0), Journal of Seismology, 15(3), 609-625.

Kanamori H., Anderson D.L., 1975. Theoretical basis of some empirical relations in seismology, Bulletin of the Seismological Society of America, 65(5), 1073-1095.

Kavianpour S., Eshghi K., Naseri S., 2021a. Seismic data analysis using deep learning approaches: A comprehensive review, Journal of Seismology and Earthquake Engineering, 23(1), 67-89.

Kavianpour S., Far M.H., Amini A., 2021b. Earthquake prediction using a hybrid CNN–LSTM model based on seismic time series data, Natural Hazards, 107, 1547-1569.

Kingma D.P., Ba J.L., 2014. Adam: A method for stochastic optimization, arXiv preprint arXiv:1412.6980.

Kingma D.P., Ba J.L., 2015. Adam: A method for stochastic optimization, International Conference on Learning Representations (ICLR).

Kreemer C., Holt W.E., Haines A.J., 2003. An integrated global model of present-day plate motions and plate boundary deformation, Geophysical Journal International, 154(1), 8-34, https://doi.org/10.1046/j.1365-246X.2003.01917.x.

Kuna D., Narsetty S., Naveen P., 2020. Preliminary analysis of standalone Galileo and NavIC in the context of positioning performance for low latitude region, Procedia Computer Science, 171, 225-234, https://doi.org/10.1016/j.procs.2020.04.024.

Kurt H., Cemen I., Wysession M., 2013. Seismicity and strain accumulation around the Karlıova Triple Junction (Turkey), Journal of Geodynamics, 65, 56-66.

McClusky S., Balassanian S., Barka A., Demir C., Ergintav S., Georgiev, I., Gurkan O., Hamburger M., Hurst K., Kahle H., Kastens K., Kekelidze G., King R., Kotzev V., Lenk O., Mahmoud S., Mishin A., Nadariya M., Ouzounis A., Paradissis D., Peter Y., Prilepin M., Reilinger R., Sanli I., Seeger H., Tealeb A., Toksöz M.N., Veis G., 2000. GPS constraints on plate kinematics and dynamics in the eastern Mediterranean and Caucasus, Journal of Geophysical Research: Solid Earth, 105(B3), 5695-5719. https://doi.org/10.1029/1999JB900351.

Özener H., Aktuğ B., Doğru A., Taşcı L., 2013. Geodetic and seismological investigation of crustal deformation near İzmir (Western Anatolia), Journal of Asian Earth Sciences, 74; 1-12.

Quinteros Cartaya Y., Flores C.E., García A., Moreno M., 2025. A deep learning-based approach for near real-time earthquake detection and magnitude estimation using high-rate GNSS time series, Seismological Research Letters, 96(3), 1123-1140.

Reilinger R., McClusky S., Vernant P., Lawrence S., Ergintav S., Çakmak R., Dinçer F., 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(B5), https://doi.org/10.1029/2005JB004051.

Seyitoğlu G., Ecevitoğlu B., Kaypak B., Esat K., Çağlayan A., Gündoğdu O., Güney Y., Işık V., Pekkan E., Tün M., Avdan U., 2015. A missing-link in the tectonic configuration of the Almacık Block along the North Anatolian Fault Zone (NW Turkey): Active faulting in the Bolu plain based on seismic reflection studies, Geophysical Journal International, 201(3), 1814-1833.

Snoek J., Larochelle H., Adams R.P., 2012. Practical Bayesian optimization of machine learning algorithms, Advances in Neural Information Processing Systems (NeurIPS), 25, 2951-2959.

Şengör A.M.C., Özeren S., Genç T., Zor E., 2003. East Anatolian high plateau as a mantle-supported, north–south shortened domal structure, Geophysical Research Letters, 30(24); TUR 8-1–TUR 8-4.

Yavaş C.E., Chen L., Kadlec C., Ji Y., 2024. Predictive modeling of earthquakes in Los Angeles with machine learning and neural networks, Scientific Reports, 14(1),24440.

Zhang Y., Wang Y., Jiang H., 2019. Application of a hybrid model based on deep learning for earthquake prediction, IEEE Access, 7; 114274-114286, https://doi.org/10.1109/ACCESS.2019.2935351.

Zheng Y., Liu F., Hsieh H.P., 2013. U-Air: When urban air quality inference meets big data, Proceedings of the 19th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, 1436-1444.

Zhou Y., Zhang Z., Liu Z., Chen W., 2022. Deep learning-based GNSS time series modeling for crustal deformation analysis, Journal of Geophysical Research: Solid Earth, 127(5), e2021JB023663, https://doi.org/10.1029/2021JB023663.

ARAŞTIRMA VERİSİ (Research Data)

Çalışma kapsamında kullanılan günlük konum verisi (Türkiye Ulusal Sabit Jeodezik İstasyon Ağı-TUSAGA verisi) HGM Jeodezi Dairesi Başkanlığı'ndan, deprem verileri AFAD'dan temin edilmiştir.

ÇIKAR ÇATIŞMASI / İLİŞKİSİ (Conflict of Interest / Relationship)

Araştırma kapsamında herhangi bir kişiyle ve/veya kurumla çıkar çatışması/ilişkisi bulunmamaktadır.

YAZARLARIN KATKI ORANI BEYANI (Author Contributions)

- Çalışmanın tasarlanması (Designing of the study): F.B.S., V.I., B.A.
- Literatür araştırması (Literature research): F.B.S.
- Saha çalışması, veri temini/derleme (Fieldwork, collection/compilation of data): F.B.S.
- Verilerin işlenmesi/analiz edilmesi (Processing/analysis of data): F.B.S., A.T.S.
- Şekil/Tablo/Yazılım hazırlanması (Preparation of figures/tables/software): F.B.S.
- Bulguların yorumlanması (Interpretation of findings): F.B.S., V.I., B.A.
- Makale yazımı, düzenleme, kontrol (Writing, editing and checking of manuscript): F.B.S., V.I., B.A.