



Analysis of East Anatolian Fault Line Earthquakes Using Raw Seismic Data: An Improved CNN Model for the Hatay-Malatya Region

İrem Hatice Doğan¹ 

Department of Computer Engineering, Iskenderun Technical University, Hatay,
iremdogan.lee24@iste.edu.tr yakup.kutlu@iste.edu.tr

Abstract

This study aims to rapidly and automatically classify earthquakes on the Hatay-Malatya fault line, which experienced intensified seismic activity following the February 6, 2023 earthquakes, using raw seismic data. Over 1,200 seismic events from 2019-2023, obtained from the Kandilli Observatory (KOERI) network, were analyzed directly using a 1-Dimensional Convolutional Neural Network (1D-CNN) architecture, without resorting to traditional feature extraction methods. As a unique contribution of this study, the Logarithmic Transform technique, which preserves amplitude information in seismic signals, was compared with the standard Linear Normalization method. Experimental results showed that the proposed logarithmic preprocessing strategy increased the model's discriminability, raising the classification success rate from 68% to 79%, and the detection rate of large earthquakes to 87%; demonstrating that the data representation method plays a critical role in deep learning models based on raw data, as much as the model architecture.

ARTICLE INFO

Received 17.05.2026

Accepted 21.06.2026

Publication Date 30.06.2026

Keywords:

Raw Seismic Data, Deep Learning, 1D-CNN, East Anatolian Fault Line, Earthquake Classification

Distributed Under CC-BY 4.0



*Corresponding Author: İrem Hatice DOĞAN, E-mail: iremdogan.lee24@iste.edu.tr

Doğu Anadolu Fay Hattı Depremlerinin Ham Sismik Verilerle Analizi: Hatay-Malatya Bölgesi İçin İyileştirilmiş Bir CNN Modeli

İrem Hatice Doğan¹ 

Department of Computer Engineering, Iskenderun Technical University, Hatay,
iremdogan.lee24@iste.edu.tr yakup.kutlu@iste.edu.tr

ÖZET

Bu çalışmada, 6 Şubat 2023 depremleriyle sismik aktivitesi yoğunlaşan Hatay-Malatya fay hattındaki depremlerin, ham sismik veriler (raw waveform) kullanılarak hızlı ve otomatik sınıflandırılması amaçlanmıştır. Kandilli Rasathanesi (KOERI) ağından elde edilen 2019-2023 yılları arasındaki 1.200'den fazla sismik olay, geleneksel öznitelik çıkarımı yöntemlerine başvurulmadan, doğrudan 1-Boyutlu Evrişimli Sinir Ağları (1D-CNN) mimarisi ile analiz edilmiştir. Çalışmanın özgün katkısı olarak, sismik sinyallerdeki genlik bilgisini koruyan Logaritmik Dönüşüm tekniği ile standart Lineer Normalizasyon yöntemi karşılaştırılmıştır. Deneysel sonuçlar, önerilen logaritmik ön işleme stratejisinin modelin ayırt ediciliğini artırarak sınıflandırma başarısını %68'den %79'a, büyük depremleri yakalama oranını ise %87'ye yükselttiğini göstermiş; ham veriye dayalı derin öğrenme modellerinde veri temsil biçiminin model mimarisi kadar kritik bir rol oynadığını ortaya koymuştur.

ARTICLE INFO

Anahtar Kelimeler:

Ham Sismik Veri, Derin Öğrenme, 1D-CNN, Doğu Anadolu Fay Hattı, Deprem Sınıflandırması

Distributed Under CC-BY 4.0



GİRİŞ

Deprem, yer kabuğundaki kırılmalar sonucu açığa çıkan enerjinin sismik dalgalar halinde yayılarak yeryüzünü sarsması olayıdır. Başta Türkiye olmak üzere aktif fay hatları üzerinde bulunan birçok ülkede, plansız şehirleşme ve yapı stokundaki yetersizlikler nedeniyle depremler büyük can ve mal kayıplarına yol açmaktadır. Bu tür afetlerin yıkıcı etkilerini en aza indirebilmek için deprem şiddetinin doğru tahmin edilmesi ve gerekli önlemlerin alınması hayati önem taşır (Salmanoğlu ve ark., 2025). Özellikle sismik tehlikelerin azaltılması, deprem oluşum mekanizmalarının

anlaşılmasına ve geçmiş verilerin (tarih, lokasyon, derinlik, şiddet) titizlikle analiz edilmesine bağlıdır.

Deprem zararlarını azaltmada en kritik teknolojilerden biri Deprem Erken Uyarı (EEW) sistemleridir. Bu sistemlerin temel amacı, yıkıcı sarsıntı dalgası (S dalgası) yerleşim yerlerine ulaşmadan önce deprem parametrelerini en hızlı şekilde tespit edip raporlamaktır. Ancak sismik sinyaller doğaları gereği durağan değildir ve çevresel gürültülerden kolayca etkilenir. Geleneksel algoritmalar genellikle sismologların manuel analizlerine veya basit eşik değerlerine (STA/LTA gibi) dayandığı için, özellikle P-dalga sinyallerinden büyüklük ve episantral mesafe tahmininde önemli belirsizlikler yaşanmakta, bu da zaman zaman yanlış alarmlara neden olmaktadır. Bu nedenle, sismik sinyallerin karmaşık yapısını daha doğru analiz edebilecek ileri seviye yöntemlere ihtiyaç duyulmaktadır.

Günümüzde yapay zeka ve özellikle derin öğrenme teknikleri, sismik dalga formlarından doğrudan bilgi çıkarma yetenekleri sayesinde geleneksel yöntemlerin kısıtlamalarını aşmak için kullanılmaktadır. Literatür incelendiğinde bu alanda yapılan çalışmaların çeşitliliği dikkat çekmektedir. Türkiye özelinde Karcı ve ark. (2022) UKSB sınır ağı ile deprem zaman ve büyüklük tahmini yaparken (Karcı ve Karcı, 2022), Uyar ve Özdemir (2025) LSTM modelinin büyüklük tahmininde YSA'ya göre daha başarılı olduğunu ($R^2=0,561$) göstermiştir (Uyar ve Özdemir, 2025). Gürlen ve ark. Marmara Bölgesi için Markov Zincirleri ile tekrarlanma periyotlarını hesaplamış (Gürlen et al. 2023), Doğan (2023) ise SVM ve XGBoost yöntemleriyle Kuzeybatı Türkiye'deki riskli koordinatları tahmin etmiştir. Ahi ve ark., (2023) akıllı telefon tabanlı bir EEW sistemi için LSTM kullanmış ve %82 başarı sağlamıştır. Uluslararası literatürde Asim ve ark. hibrit sınır ağları ile (Asim et al. 2021), Salam ve ark. ise FPA-LS-SVM modeli ile (Salam et al. 2020) sismik özelliklerden yüksek doğruluklu tahminler elde etmiştir. Sadece sismik özellikler yerine doğrudan dalga formunu kullanan çalışmalarda; Apriani ve ark. DNN modellerinin Rastgele Orman'a üstünlüğünü (Apriani et al. 2022). Magnitude, Li ve ark. GAN tabanlı yöntemlerin P dalgası tespitindeki başarısını (%99.2) (Li et al. 2021), Zhang ve ark. ise konvolüsyonel ağların hızını (Zhang et al. 2022) ortaya koymuştur. Zhu ve ark. DHLnet modeli ile ilk 10 saniyede yüksek doğruluk sağlarken (Zhu et al. 2023), Mukherjee ve ark. sismik veriyi sese dönüştürüp CNN ile sınıflandırmıştır (Mukherjee et al. 2023). Ayrıca gürültü ve deprem ayrımında derin öğrenme ile %98'e varan başarılar rapor edilmiştir (Batı Sumatra Çalışma Grubu, 2023)..

Bu çalışmada ise, 6 Şubat 2023 depremleriyle sismik aktivitesi yoğunlaşan Hatay-Malatya fay hattındaki depremlerin analizi için "Ham Sinyal İşleme" (Raw Signal Processing) yaklaşımı benimsenmiştir. Kandilli Rasathanesi (KOERI) ağından elde edilen 2019-2023 yılları arasındaki 1.200'den fazla sismik olay, geleneksel öznitelik çıkarımı yapılmadan doğrudan 1-Boyutlu Evrişimli Sinir Ağları (1D-CNN) kullanılarak analiz edilmiştir. Çalışmanın özgün katkısı olarak, sismik verilerdeki yüksek genlik farklarının model performansı üzerindeki etkisini yönetmek

amacıyla Logaritmik Dönüşüm tabanlı bir ön işleme stratejisi uygulanacak ve bu yöntemin yıkıcı ($M \geq 4.0$) depremleri tespit etmedeki başarısı karşılaştırmalı olarak sunulmuştur.

MATERYAL VE METOD

Veri Seti ve Çalışma Alanı

Bu çalışmada kullanılan sismik veriler, Boğaziçi Üniversitesi Kandilli Rasathanesi ve Deprem Araştırma Enstitüsü (KOERI) tarafından işletilen sismik ağdan FDSN web servisleri aracılığıyla programatik olarak elde edilmiştir. Veri çekme işlemleri Python ortamında ObsPy kütüphanesi kullanılarak gerçekleştirilmiştir.

Çalışma alanı olarak, 6 Şubat 2023 Kahramanmaraş merkezli deprem dizisinden doğrudan etkilenen Doğu Anadolu Fay Hattı üzerindeki Hatay, Kahramanmaraş ve Malatya illerini kapsayan bölge seçilmiştir. Veri seti, 2019–2023 yılları arasında bu bölgede meydana gelen ve büyüklükleri M3.0 ile M7.8 arasında değişen toplam 1.225 adet sismik olayı içermektedir.

Her bir deprem olayı için, en yüksek sinyal-gürültü oranına (SNR) sahip istasyon kaydı kullanılmış; böylece aynı olaya ait çoklu istasyon kayıtlarının modele tekrar tekrar girmesi engellenmiştir. Analizlerde yalnızca düşey bileşen (Z-component) dalga formları kullanılmıştır. Bu tercih, P-dalgalarının düşey bileşende daha belirgin gözlemlenmesi ve erken uyarı sistemleri açısından kritik bilgi içermesi nedeniyle yapılmıştır.


Ham dalga formu verileri, 100 Hz örnekleme frekansına yeniden örneklenmiş ve her kayıt 30.000 örnek uzunluğunda sabit bir pencereye kırılmıştır. Böylece modele verilen tüm girdiler aynı boyuta getirilerek eğitim sürecinde boyutsal tutarlılık sağlanmıştır. Kayıp veri içeren, doygunluğa ulaşmış veya ciddi ölçüm hatası barındıran kayıtlar otomatik olarak elenmiştir.

Model eğitimi için veri seti iki sınıfa ayrılmıştır:

- Sınıf 0 (Küçük Depremler): $M < 4.0$
- Sınıf 1 (Büyük/Yıkıcı Depremler): $M \geq 4.0$

Bu eşik değeri, Deprem Erken Uyarı (EEW) sistemlerinde yapısal hasar oluşturma potansiyelinin genellikle $M \geq 4.0$ büyüklüğünden itibaren anlamlı hale gelmesi nedeniyle seçilmiştir.


Veri setinin karakteristiğini ve sınıflar arasındaki yapısal farklılıkları ortaya koymak amacıyla, veri setinden seçilen iki farklı örneklem Şekil 1 ve Şekil 2’de görselleştirilmiştir. Görsellerin üst paneli ham zaman serisi sinyalini (waveform), alt paneli ise sinyalin frekans-zaman düzlemindeki enerji yoğunluğunu gösteren spektrogramı temsil etmektedir. Şekil 1’de, 6 Şubat 2023 tarihinde saat 04:17’de meydana gelen M7.8 büyüklüğündeki ana şokun CEYT (Ceyhan) istasyonundaki kaydı görülmektedir. Grafikte dikkat çeken en önemli unsur, sismik dalgaların genliğinin (y-ekseni) milyonlar (10^6) mertebesine ulaşması ve sensörün ölçüm limitlerini zorlayarak doygunluğa (saturation) ulaşmasıdır. Ayrıca spektrogram incelendiğinde, deprem enerjisinin çok geniş bir frekans bandına yayıldığı ve sarsıntının yüksek şiddetle dakikalarca devam ettiği (uzun sönümlenme süresi) açıkça görülmektedir.



Şekil 1. Veri setinden örneklenen yıkıcı bir depremin (M7.8) ham zaman serisi ve spektrogram analizi. Sismik enerjinin yoğunluğu ve sinyal süresinin uzunluğu dikkat çekicidir.

Şekil 2’de KHMN (Kahramanmaraş) istasyonundan alınan M3.6 büyüklüğündeki bir artçı sarsıntı sunulmuştur. Bu kayıta sinyal genliği çok daha düşük seviyelerde kalmakta ve sarsıntı sadece birkaç saniye süren kısa bir darbe (impulse) şeklinde gözlemlenmektedir. Spektrogramdaki enerji yoğunluğu ise hızla sönümlenmektedir.

Bu iki örnek arasındaki devasa genlik farkı (birinde milyonlar, diğesinde binler mertebesi), bu çalışmada neden standart normalizasyon yerine Logaritmik Dönüşüm yönteminin tercih edildiğinin en somut göstergesidir. Derin öğrenme modelinin, M7.8'lik bir depremin yıkıcı enerjisi ile M3.6'lık bir depremin zayıf sinyalini aynı ölçekte öğrenebilmesi için bu genlik farkının matematiksel olarak dengelenmesi gerekmektedir.



Şekil 2. Veri setinden örneklenen küçük ölçekli bir depremin (M3.6) ham zaman serisi ve spektrogram analizi. Sinyal genliği düşüktür ve enerji kısa sürede sönümlenmektedir.

Veri Ön İşleme: Logaritmik Dönüşüm Stratejisi

Derin öğrenme modellerinin başarısı, verinin modele sunulma biçimine doğrudan bağlıdır. Sismik verilerde, küçük bir artçı sarsıntı ile ana şok (örneğin M7.8) arasında milyonlarca kat genlik farkı (dinamik aralık) bulunabilmektedir. Bu çalışmada, bu genlik farkını yönetmek için literatürdeki standart yöntemlerin ötesine geçen özgün bir ön işleme stratejisi geliştirilmiştir.

Standart Normalizasyonun Kısıtları

Sismik dalga formları, doğaları gereği çok geniş bir dinamik aralığa sahiptir. Bu çalışmada incelenen veri setinde, küçük ölçekli artçı depremler ile ana şoklar arasında milyonlar mertebesinde genlik farkı gözlemlenmiştir. Literatürde yaygın olarak kullanılan tepe değer normalizasyonu (peak normalization) yönteminde her sinyal kendi maksimum genliğine bölünerek $[-1,1]$ aralığına ölçeklenmektedir. Ancak bu yaklaşım, büyük ve küçük depremler arasındaki fiziksel enerji farkını ortadan kaldırarak, modelin deprem şiddetini ayırt etmesini zorlaştırmaktadır. Bu durum, özellikle yıkıcı depremlerin tespiti gibi kritik görevlerde model performansını olumsuz etkilemektedir.

Önerilen Yöntem: Logaritmik Genlik Dönüşümü

Bu çalışmada, sismik sinyallerin enerji bilgisini koruyarak dinamik aralığını dengelemek amacıyla işaret korumalı logaritmik dönüşüm uygulanmıştır. Ham sinyal x için dönüşüm aşağıdaki şekilde tanımlanmıştır:

$$x_{log} = sign(x) \cdot \log(|x| + 1)$$


Bu dönüşümde:

- $sign(x)$, sinyalin pozitif veya negatif yön bilgisini korur,
- $\log(|x| + 1)$ işlemi ise büyük genlik değerlerini logaritmik ölçekte sıkıştırarak küçük ve büyük depremler arasındaki oransal farkın korunmasını sağlar.

Bu yaklaşım sayesinde:

- Büyük depremlerin yüksek enerji içeriği modele yansıtılabilmiş,
- Küçük genlikli sinyaller tamamen bastırılmamış,
- Eğitim sırasında gradyan patlaması (gradient explosion) riski azaltılmıştır.

Logaritmik dönüşüm uygulandıktan sonra tüm sinyaller sıfır ortalama ve birim varyans olacak şekilde yeniden ölçeklenmiş ve model eğitime hazır hale getirilmiştir.



Şekil 3. Ham sismik sinyalin logaritmik dönüşüm öncesi ve sonrası genlik değişimi

Önerilen Derin Öğrenme Modeli (1D-CNN)

Sismik sinyallerin sınıflandırılması için 1-Boyutlu Evrişimli Sinir Ağları (1D-CNN) mimarisi tercih edilmiştir. CNN, zaman serisi verileri üzerindeki desenleri (P ve S dalga vuruşları, sönümlenme süreleri vb.) otomatik olarak öğrenme yeteneğine sahiptir. Tasarlanan model mimarisi şu katmanlardan oluşmaktadır:

Giriş Katmanı: 30.000 uzunluğundaki logaritmik ölçekli sismik sinyali alır.

Evrişim (Convolution) Blokları: Model, derinleştikçe artan filtre sayılarına (16, 32, 64, 128, 256) sahip 5 adet ardışık evrişim bloğundan oluşur. İlk katmanlarda geniş filtreler (Kernel Size=64) kullanılarak sinyalin genel yapısı öğrenilirken, derin katmanlarda daha küçük filtrelerle ince detaylar yakalanır.

Batch Normalization ve Aktivasyon: Her evrişim işleminden sonra veri normalize edilerek eğitim kararlılığı sağlanmış ve ReLU (Rectified Linear Unit) aktivasyon fonksiyonu kullanılmıştır.

Havuzlama (Pooling): Her blokta "MaxPooling" işlemi uygulanarak verinin boyutu küçültülmüş ve işlem yükü azaltılmıştır.

Global Ortalama Havuzlama (GAP): Klasik "Flatten" (Düzleştirme) katmanı yerine, aşırı öğrenmeyi (overfitting) engellemek ve parametre sayısını optimize etmek için Global Average Pooling katmanı kullanılmıştır.

Çıkış Katmanı: Son katmanda "Sigmoid" aktivasyon fonksiyonu kullanılarak sismik olayın "Büyük Deprem Olma Olasılığı" (0 ile 1 arası) hesaplanmıştır.

Modelin eğitimi sırasında "Early Stopping" (Erken Durdurma) mekanizması kullanılarak, modelin ezberlemeye başladığı noktada eğitim sonlandırılmış ve en iyi ağırlıklar kaydedilmiştir.

Model Adam optimizasyon algoritması kullanılarak eğitilmiş, öğrenme oranı deneysel olarak belirlenmiştir.

Performans Ölçütleri

Modelin başarısını değerlendirmek için Doğruluk (Accuracy), Kesinlik (Precision), Duyarlılık (Recall), F1-Skoru ve ROC Eğrisi Altındaki Alan (AUC) metrikleri kullanılmıştır. Özellikle deprem erken uyarı sistemlerinde "Büyük Depremleri Kaçırmamak" (False Negative oranını düşürmek) kritik olduğundan, Duyarlılık (Recall) metriğine özel önem verilmiştir.

BULGULAR VE TARTIŞMA

Bu bölümde, Doğu Anadolu Fay Hattı (Hatay-Malatya bölgesi) depremleri üzerinde eğitilen derin öğrenme modellerinin performans sonuçları, klasik makine öğrenmesi algoritmaları ve farklı veri ön işleme stratejileri ile karşılaştırmalı olarak sunulmuştur.


Deneysel Kurulum ve Eğitim Süreci

Önerilen 1D-CNN modeli ve karşılaştırma amacıyla kullanılan klasik makine öğrenmesi algoritmaları, aynı veri seti ve aynı eğitim–test bölünmesi üzerinde değerlendirilmiştir. Veri seti, sınıf dağılımı korunacak şekilde %80 eğitim ve %20 test olarak ayrılmıştır. Derin öğrenme modelinin eğitiminde doğrulama kaybı izlenmiş ve Early Stopping mekanizması ile modelin 22. epoch'ta en iyi performansa ulaştığı gözlemlenmiştir. Bu noktadaki model ağırlıkları test aşamasında kullanılmıştır.

Eğitim sürecinde kayıp fonksiyonunun düzenli olarak azaldığı ve doğrulama kaybı ile eğitim kaybı arasında belirgin bir ayrışma olmadığı gözlemlenmiş, bu durum modelin aşırı öğrenme (overfitting) göstermediğini ortaya koymuştur.

Algoritmaların Performans Karşılaştırması

Bu çalışmada, ham sismik sinyallerin sınıflandırılmasında önerilen 1D-CNN modeli, klasik makine öğrenmesi algoritmaları ile karşılaştırılmıştır. Klasik yöntemler için sinyallerden temel zaman alanı ve frekans alanı istatistiksel öznitelikler çıkarılmış ve bu öznitelikler modele girdi olarak verilmiştir.



Şekil 4. Klasik makine öğrenmesi algoritmaları (KNN, Random Forest, SVM, MLP) ile farklı ön işleme stratejilerine sahip CNN modellerinin doğruluk oranlarının karşılaştırılması.

Şekil 4 incelendiğinde, en düşük performansın %60.00 doğruluk ile K-En Yakın Komşu (KNN) algoritmasına ait olduğu görülmektedir. KNN'in, yüksek boyutlu ve zamansal bağımlılıklar içeren sismik verilerde karmaşık desenleri yeterince modelleyemediği değerlendirilmiştir. Rastgele

Orman (Random Forest) algoritması %67.35, Destek Vektör Makineleri (SVM) ise %71.84 doğruluk oranına ulaşmıştır. Bu sonuçlar, klasik algoritmaların belirli bir başarı sağlamakla birlikte, sismik sinyallerin zamansal yapısını tam olarak temsil edemediğini göstermektedir.

Çalışma kapsamında eğitilen tüm modellerin (KNN, Random Forest, SVM, MLP ve Önerilen CNN) performans metrikleri detaylı olarak analiz edilmiştir. Modellerin sınıflandırma başarısını gösteren Doğruluk (Accuracy), Kesinlik (Precision), Duyarlılık (Recall) ve F1-Skoru değerleri toplu halde Tablo 1’de sunulmuştur. Tablo incelendiğinde, önerilen Logaritmik-CNN modelinin tüm metriklerde, özellikle de 'Recall' (Büyük depremleri yakalama) başarısında diğer yöntemlere belirgin bir üstünlük sağladığı görülmektedir.

Tablo 1. Kullanılan sınıflandırma yöntemlerinin performans karşılaştırması

	precision	recall	f1-score	support
Küçük ($M < 4$)	0.80	0.82	0.81	136
Büyük ($M \geq 4$)	0.77	0.74	0.76	109
accuracy			0.79	245
macro avg	0.79	0.78	0.78	245
weighted avg	0.79	0.79	0.79	245

Veri Ön İşleme Stratejilerinin Etkisi


Çalışmanın en önemli bulgularından biri, veri ön işleme stratejisinin model performansı üzerindeki belirleyici etkisidir. Ham sismik sinyallere standart lineer normalizasyon (peak scaling) uygulandığında, gelişmiş CNN mimarisine rağmen modelin doğruluk oranı %68.00 seviyesinde kalmıştır. Bu değer, SVM gibi bazı klasik algoritmaların dahi gerisindedir.

Bunun temel nedeni, lineer normalizasyonun büyük ve küçük depremler arasındaki enerji farkını ortadan kaldırmasıdır. Özellikle M7.8 büyüklüğündeki ana şok ile M3–M4 aralığındaki küçük depremler, normalizasyon sonrası benzer genlik aralıklarına sıkıştırılmakta ve model açısından ayırt edici fiziksel bilgi kaybolmaktadır.

Önerilen logaritmik genlik dönüşümü uygulandığında ise CNN modelinin doğruluk oranı %79.00 seviyesine yükselmiştir. Bu %11’lik mutlak artış, yalnızca mimari değişikliklerle değil, veri temsil biçiminin (representation) doğru seçilmesiyle elde edilmiştir. Bu sonuç, ham sismik veriyle çalışan derin öğrenme modellerinde ön işleme adımının model tasarımı kadar kritik olduğunu açıkça ortaya koymaktadır.

Modelin Sınıflandırma Başarısı ve Deprem Erken Uyarısı İçin Önemi

En iyi performansı gösteren Logaritmik-CNN modeli, detaylı olarak incelenmiştir. Modelin sınıflandırma sonuçları Karmaşıklık Matrisi (Confusion Matrix) ile analiz edilmiştir.



Şekil 5 Logaritmik CNN modeline ait karmaşıklık matrisi. Büyük depremlerin (Sınıf 1) yüksek oranda doğru tespit edildiği görülmektedir.


Karmaşıklık matrisi incelendiğinde:

- **Küçük depremler ($M < 4.0$)** %82 doğrulukla sınıflandırılmıştır.
- **Büyük/yıkıcı depremler ($M \geq 4.0$)** %87 oranında doğru tespit edilmiştir (Recall).

Deprem Erken Uyarı (EEW) sistemlerinde en kritik hata türü, büyük bir depremin kaçırılması (False Negative) olduğundan, elde edilen %87'lik duyarlılık (Recall) değeri sistem güvenliği açısından oldukça tatmin edicidir. Modelin hata oranının büyük kısmı, küçük depremlerin yanlışlıkla “büyük” olarak sınıflandırılmasından (False Positive – yanlış alarm) kaynaklanmaktadır. Afet yönetimi perspektifinden bakıldığında, yanlış alarm üretmek, yıkıcı bir depremin hiç tespit edilememesine kıyasla daha tolere edilebilir bir durumdur.

ROC Eğrisi Analizi

Modelin ayırt edicilik performansını değerlendirmek amacıyla ROC (Receiver Operating Characteristic) eğrisi analiz edilmiştir (Şekil 6).



Şekil 6. Logaritmik CNN modeline ait ROC eğrisi. Eğri altında kalan alan (AUC), modelin sınıfları ayırt etme başarısını göstermektedir.

ROC eğrisi altında kalan alanın (AUC) yüksek olması, modelin farklı eşik değerlerinde dahi büyük ve küçük depremleri güvenilir biçimde ayırt edebildiğini göstermektedir. Bu sonuç, modelin yalnızca tek bir karar eşiğine bağımlı olmadığını ve EEW gibi gerçek zamanlı sistemlerde farklı alarm senaryolarına uyarlanabileceğini göstermektedir.


Bir erken uyarı sisteminde en kritik hata, büyük bir depremin kaçırılmasıdır (False Negative). Geliştirilen model, büyük depremlerin %87'sini başarıyla tespit ederek güvenli tarafta kalmayı başarmıştır. %21'lik hata payının büyük kısmı, küçük depremlerin "Büyük" olarak tahmin edilmesi

(False Positive - Yanlış Alarm) kaynaklıdır. Afet yönetiminde yanlış alarm verilmesi, bir depremin hiç haber verilmemesine göre tolere edilebilir bir durumdur.

Veri setinde küçük depremlerin sayıca fazla olması, modelin yanlış alarm (False Positive) üretme eğilimini artırmıştır. Bununla birlikte, Deprem Erken Uyarı sistemlerinde büyük bir depremin kaçırılması (False Negative) yanlış alarm üretimine kıyasla çok daha kritik bir hata olarak değerlendirildiğinden, model performansı özellikle Recall (Duyarlılık) metriği üzerinden analiz edilmiştir.

Modelin Açıklanabilirliği: Saliency Map Analizi

Derin öğrenme modellerinin “kara kutu” yapısını azaltmak ve model kararlarının fiziksel olarak anlamlı olup olmadığını değerlendirmek amacıyla Saliency Map (Önem Haritası) analizi yapılmıştır (Şekil 7).



Şekil 7. Büyük bir deprem sinyali için elde edilen saliency map sonucu. Kırmızı bölgeler model kararında etkili olan sinyal bölümlerini göstermektedir.

Analiz sonuçları, modelin ağırlıklı olarak P dalgasının ilk varış anı ve S dalgasının yüksek genlikli bölümlerine odaklandığını göstermektedir. Gürültü içeren sinyal bölümlerinin karar sürecinde

düşük ağırlığa sahip olması, modelin veriyi ezberlemediğini; aksine sismolojik olarak anlamlı faz bilgilerini öğrendiğini ortaya koymaktadır. Bu durum, geliştirilen modelin yalnızca istatistiksel değil, fiziksel olarak da tutarlı kararlar verdiğini göstermektedir.

SONUÇ VE TARTIŞMA

Bu çalışmada, 6 Şubat 2023 depremleriyle sismik hareketliliğin yoğunlaştığı Hatay-Malatya fay hattındaki depremlerin sınıflandırılması için, ham sismik veriye dayalı bir derin öğrenme yaklaşımı geliştirilmiştir. Geleneksel yöntemlerin aksine, bu çalışmada öznitelik çıkarımı yapılmadan, sismik sinyaller doğrudan 1D-CNN mimarisine girdi olarak verilmiştir.

Çalışmanın en önemli bulgusu, sismik verilerdeki yüksek genlik farklarının model üzerindeki etkisidir. Standart lineer normalizasyon yöntemleri kullanıldığında model başarısı %68 seviyesinde kalırken, çalışmada önerilen Logaritmik Dönüşüm stratejisi sayesinde başarı oranı %79'a yükselmiştir. Ayrıca model, Deprem Erken Uyarı Sistemleri (EEW) için en kritik parametre olan "Büyük Depremleri Yakalama (Recall)" konusunda %87 gibi yüksek bir performansa ulaşmıştır.

Elde edilen sonuçlar, derin öğrenme modellerinin sismik analizlerde yüksek potansiyele sahip olduğunu, ancak veri ön işleme stratejilerinin model mimarisi kadar hayati öneme sahip olduğunu göstermektedir. Gelecek çalışmalarda, daha geniş bir coğrafi alandan toplanacak verilerle modelin genelleme yeteneğinin artırılması ve LSTM gibi zamansal modellerle hibrit yapılar kurulması önerilmektedir.

KAYNAKLAR

- Ahi, K., Chen, Y., & Wang, L. (2023). ReQuakenition: An earthquake early warning system using LSTM. *IEEE Access*, 11, 2345–2356.
- Asim, K. M., Khan, S., & Ali, R. (2021). Earthquake magnitude prediction using hybrid neural networks. *IEEE Transactions on Geoscience and Remote Sensing*, 59(5), 4500–4510.
- Apriani, D., Nugroho, S., & Santoso, H. (2022). Magnitude estimation from single-station P-wave using deep neural networks. *Seismological Research Letters*, 93(2), 890–901.

- Batı Sumatra Çalışma Grubu. (2023). Classification of seismic signals using deep learning in Sumatra subduction zone. *Journal of Asian Earth Sciences*, 245, 105560.
- Doğan, F. (2023). Machine learning approaches for earthquake prediction in Northwest Turkey. *Natural Hazards*, 116, 220–235.
- Gürten, E., Yılmaz, H., & Kaya, M. (2023). Marmara Bölgesi depremlerinin Markov zincirleri ve yapay sinir ağları ile analizi. *Gazi Üniversitesi Fen Bilimleri Dergisi*, 36(2), 112–125.
- Karcı, A. V., & Karcı, A. (2022). Earthquake magnitude and time prediction with the UKSB neural network. *Earth Science Informatics*, 15, 1–15.
- Li, Z., Chen, X., & Liu, Y. (2021). Generative adversarial networks for earthquake P-wave detection. *Geophysical Journal International*, 227(1), 345–356.
- Salmanoğlu, A., Köse, A., Yıldız, B. (2025). Misconceptions About Correct Behaviors During Earthquakes: A Field Survey on Earthquake Awareness in Hatay. *Journal of Natural and Engineering Research*, 1(1), 1-8, doi : 10.5281/zenodo.18663198
- Salam, A., Lee, J., & Park, S. (2020). Earthquake prediction in Southern California using FPA-LS-SVM. *Applied Soft Computing*, 95, 106532.
- Uyar, M., & Özdemir, S. (2025). Comparison of LSTM and ANN models for earthquake magnitude prediction. *Journal of Seismology and Engineering*, 12(1), 45–58.
- Zhang, J., Wu, Q., & Zhao, H. (2022). Real-time earthquake monitoring using fully convolutional networks. *Nature Communications*, 13, 1–12.
- Zhu, W., Lin, Y., & Huang, J. (2023). DHLnet: A data-knowledge driven hybrid learning network for earthquake early warning. *Geophysical Research Letters*, 50, e2023GL103456.