



# Kahramanmaraş Sütçü İmam University

## Journal of Engineering Sciences



Geliş Tarihi : 09.04.2024  
Kabul Tarihi : 23.05.2024

Received Date : 09.04.2024  
Accepted Date : 23.05.2024

### DEPREM SEVİYE SINIFLANDIRMASI İÇİN HİBRİT BİR CONVLSTM MODELİ: KARŞILAŞTIRMALI BİR ANALİZ

#### A HYBRID CONVLSTM MODEL FOR EARTHQUAKE LEVEL CLASSIFICATION: A COMPARATIVE ANALYSIS

Anıl UTKU<sup>1</sup> (ORCID: 0000-0002-7240-8713)

<sup>1</sup> Munzur Üniversitesi, Bilgisayar Mühendisliği Bölümü, Tunceli, Türkiye

\*Sorumlu Yazar / Corresponding Author: Anıl UTKU, anilutku@munzur.edu.tr

#### ÖZET

Deprem, yer kabuğunda depolanan enerjinin açığa çıkması sonucu yer yüzeyinin aniden sarsılmasıdır. Depremler genellikle yer altı kayalarının aniden kırılması ve bir fay boyunca hızlı itmesi nedeniyle meydana gelir. Binaların ve altyapının düzgün inşa edilmediği ve nüfusun hazırlıklı olmadığı bir ortamda, orta şiddette bile olsa bir deprem yıkıcı olabilir. Yapay zekâ yöntemleri, deprem tahmini gibi doğal afetlerin öngörülmesinde önemli bir rol oynamaktadır. Bu amaçla geliştirilen hibrit ConvLSTM modeli ile yer kabuğundaki karmaşık enerji dinamikleri ve hareketleri, büyük miktardaki jeolojik verilerden analiz edilerek deprem olasılıklarının tahmin edilmesi amaçlandı. ConvLSTM, LR, RF, SVM, XGBoost, MLP, CNN ve LSTM gibi popüler yöntemlerle USGS tarafından sunulan gerçek zamanlı deprem verileri kullanılarak karşılaştırıldı. Deneysel sonuçlar, ConvLSTM'in 0,9951 doğruluk ve 0,9993 AUC ile karşılaştırılan modellerden daha başarılı olduğunu göstermiştir.

**Anahtar Kelimeler:** Deprem, derin öğrenme, makine öğrenmesi, cnn, lstm

#### ABSTRACT

An earthquake is a sudden shaking of the earth's surface as a result of the release of energy stored in the earth's crust. Earthquakes usually occur due to sudden breaking of underground rocks and rapid movement along a fault. In an environment where buildings and infrastructure are not properly constructed and the population is not prepared, an earthquake of even moderate intensity can be devastating. Artificial intelligence methods play an important role in predicting natural disasters, such as earthquake prediction. The hybrid ConvLSTM model developed for this purpose aimed to predict earthquake probabilities by analyzing complex energy dynamics and movements in the earth's crust from large amounts of geological data. ConvLSTM was compared with popular methods such as LR, RF, SVM, XGBoost, MLP, CNN and LSTM using real-time earthquake data provided by USGS. Experimental results showed that ConvLSTM outperformed the compared models with 0.9951 accuracy and 0.9993 AUC.

**Keywords:** Earthquake, deep learning, machine learning, cnn, lstm

## GİRİŞ

Depremler, dünya çapında birçok insanın can ve mal kaybı yaşamasına neden olan doğal afetlerdir (Chaudhary ve Piracha, 2021). Depremler yer sarsıntısı, toprağın sıvılaşması, heyelan, yeryüzünde çatlak, çığ ve tsunami gibi durumlara da neden olabilir. Depremlerin sebep olduğu hasar depremin büyüklüğü, yoğunluğu, süresi, toprak yapısı, zamanı, binalarda kullanılan malzeme kalitesi ve afet yönetimi gibi faktörlere bağlıdır (Shafapourtehrany vd., 2023). Deprem sırasında, yer kabuğunda biriken enerji aniden serbest kalarak kaya kütlelerinin fay hatları boyunca hızla hareket etmesine ve yer değiştirmesine neden olur (Bytchkov, 2024). Bu hareket, S ve P sismik dalgaları şeklinde yeryüzünde yayılan titreşimler üretir. S dalgaları, titreşimlerin dalga yayılma yönüne dik olarak hareket etmesine neden olur (He vd., 2020). S dalgaları, yatay sarsıntının meydana gelmesini sağlar. Deprem esnasında ilk olarak hissedilen ve ilk ani sarsıntıya neden olan P dalgaları ise titreşimlerin dalga yayılımıyla aynı yönde hareket etmesini sağlar (Zakka vd., 2024).

Sismograf ve Richter ölçeği, depremleri karakterize etmek için kullanılan araçlardır. Sismograf, depremlerin neden olduğu titreşimleri veya yer hareketlerini ölçmek ve kaydetmek için kullanılan bir cihazdır (Huang vd., 2022). Sismograf depremin yoğunluğu, süresi ve sıklığı hakkında bilgi vermektedir. Richter ölçeği ise sismograflar tarafından kaydedilen deprem dalgalarını analiz ederek depremin büyüklüğünü ölçmektedir (Giridhar vd., 2021).

Ülkemizde 6 Şubat 2023 tarihinde Kahramanmaraş'ın Pazarcık ve Elbistan ilçelerinde 9 saat arayla meydana gelen 7.7 ve 7.6 büyüklüğündeki depremler, 11 ilde 53 binden fazla kişinin hayatını kaybetmesine ve 107 binden fazla kişinin yaralanmasına neden oldu. Ayrıca 17 Ağustos 1999'da Kocaeli'nin Gölcük ilçesinde meydana gelen 7.4 büyüklüğündeki deprem, 17 binden fazla insanın hayatını kaybetmesine ve 44 bine yakın insanın yaralanmasına neden oldu. Deprem kuşağında bulunan ülkemizde, depreme yönelik acil durum planlamalarının geliştirilmesi, yerel yönetimler ve ilgili kurumlar tarafından bina kontrollerinin yapılması ve yapı denetim süreçlerinin kontrolüyle birlikte depremlerde yaşanabilecek can ve mal kayıpları engellenebilir.

Depremler, her yıl küresel ölçekte önemli sayıda can kayıplarına ve büyük maddi hasarlara yol açan, son derece yıkıcı doğal afetlerdir (Nievas vd., 2020). Depremler meydana gelmeden önce ve depremlerden sonrasında yönelik etkin stratejiler geliştirmek ve afet yönetimi bilincini yaygınlaştırmak, depremin etkilerinin azaltılması ve güvenliğin sağlanması açısından önemlidir (Priyadi vd., 2021). Depremlerin, önceden tahmin edilmesine yönelik çalışmalar uzun yıllardır devam etmektedir. Depremleri tahmin etmek için kullanılan geleneksel modeller sınırlı verilerle iyi çalışırken, günümüzde mevcut olan devasa sismoloji verisetleri üzerinde yeterince başarılı olamamaktadır. Bu sebeple yapay zekâ yöntemleri, deprem tahmininde ön plana çıkmaktadır. Depremlerin meydana gelmeden önce tespit edilmesi, deprem başlamadan kısa bir süre önce etkilenmesi muhtemel bölgelere mobil cihazlar aracılığıyla bildirim gönderilmesini ve bu sayede çeşitli önlemlerin alınmasını ifade eder (Colombelli vd., 2020). Faya yakın sismometreler tarafından depremin enerjisi tespit edilerek yapay zekâ yöntemleri ile depremin olası boyutu belirlenebilir. Sunulabilecek erken uyarılar, insanların güvenli alanlara gidebilmelerine, elektrik ve doğal gaz gibi tehlike oluşturabilecek enerji hatlarının kontrol edilebilmesine ve acil durum planlarının devreye sokulmasını sağlayabilir.

Bu çalışmada, depremlerin dünyanın neresinde ve hangi tarihte gerçekleşeceğini tahmin etmek amacıyla hibrit bir ConvLSTM modeli geliştirildi. Çalışmada, Amerika Birleşik Devletleri Jeoloji Araştırmaları Kurumu (United States Geological Survey - USGS) tarafından sunulan 27 Aralık 2023 ile 26 Ocak 2024 tarihleri arasında dünya genelinde meydana gelen 9451 depremden oluşan bir veriseti kullanıldı. CNN ve LSTM'in öne çıkan özelliklerinden faydalanmak amacıyla geliştirilen ConvLSTM modeli, geleneksel makine öğrenmesi ve derin öğrenme modelleriyle uygulamalı olarak karşılaştırıldı.

Bu çalışmanın literatüre olan katkıları aşağıdaki gibi sıralanabilir:

- Depremlerin meydana gelme zamanlarını ve nerede meydana gelebileceklerini daha yüksek bir doğrulukta tahmin edebilmek amacıyla hibrit bir derin öğrenme modeli geliştirildi.
- USGS tarafından sunulan ve 9451 depremden oluşan, güncel bir veriseti kullanıldı. Literatürde bu veriseti kullanılarak yapılmış bir çalışma yoktur.
- ConvLSTM'in etkinliği Random Forest (RF), Logistic Regression (LR), Support Vector Machine (SVM), Convolutional Neural Network (CNN), eXtreme Gradient Boosting (XGBoost), Multi-Layer Perceptron (MLP) ve Long-Short Term Memory (LSTM) gibi makine öğrenmesi ve derin öğrenme modelleriyle karşılaştırıldı.

## İLGİLİ ÇALIŞMALAR

Bu bölümde, makine öğrenmesi ve derin öğrenme yöntemleri kullanılarak yapılmış literatürdeki çalışmalar incelenmiştir.

Ommi ve Hashemi, kuzey Zagros bölgesinin deprem olasılıklarının belirlenmesine yönelik Artificial Neural Network (ANN), RF ve SVM'in karşılaştırmalı bir analizini sunmuştur (Ommi ve Hashemi, 2022). Çalışmada 1995-2022 yılları arasındaki sismik veriler kullanılmıştır. Deneysel sonuçlar, ANN'in sismik olayların yaklaşık %97'sini doğru bir şekilde tahmin ederek karşılaştırılan yöntemlerden daha başarılı olduğunu göstermiştir.

Utku ve Akcayol, deprem zamanlarının tahminine yönelik hibrit CNN-GRU modelini önermiştir (Utku ve Akcayol, 2024). Önerilen model, RF, ARIMA, CNN ve GRU ile karşılaştırılmıştır. Çalışmada, 1965-2016 yılları arasındaki deprem verileri kullanılmıştır. Depremlerin meydana gelme zamanları arasındaki süre farkları kullanılarak bir sonraki depremin meydana gelme zamanının tahmin edilmesi amaçlanmıştır. Deneysel sonuçlar, önerilen hibrit modelin karşılaştırılan modellerden daha düşük hata oranlarına sahip olduğunu göstermiştir.

Zhou vd. binaların depremde hasar görme durumlarının tahminine yönelik çoklu doğrusal regresyon, SVM ve Back Propagation Neural Network modellerinin uygulamalı bir analizini sunmuştur (Zhou vd., 2024). Çalışmada Ludian depreminin binalara verdiği hasar verilerinden oluşan bir veri seti kullanılmıştır. Kullanılan veri seti yapı kategorisi, topoğrafik durum ve sismik parametrelerden oluşmaktadır. Deneysel sonuçlar, Back Propagation Neural Network modelinin 0,05'ten daha düşük RMSE değeriyle karşılaştırılan modellerden daha başarılı olduğunu göstermiştir.

Sadhukhan vd. Japonya, Endonezya ve Hindu-Kush Himalaya bölgelerinin sismik verilerini kullanarak deprem büyüklüğünün tahminine yönelik LSTM tabanlı bir model geliştirmiştir (Sadhukhan vd., 2023). Çalışmada Bi-directional Long Short-Term Memory (Bi-LSTM), transformatör model ve LSTM'in uygulaması sunulmuştur. Deneysel sonuçlar, LSTM'in Japonya için 0,06 Mean Absolute Error (MAE), Bi-LSTM'in Endonezya için 0,073 ve transformatör modelin Hindu-Kush Himalaya bölgesi için 0,062 MAE değerine sahip olduğunu göstermiştir.

Kavianpour vd. depremlerin büyüklük ve meydana gelme sayılarını tahmin etmek amacıyla CNN-Bi-LSTM modelini önermiştir (Kavianpour vd., 2023). Çalışmada, Çin'deki farklı bölgelerden elde edilen bir veri seti kullanılmıştır. LR, CNN, LSTM, MLP, RF ve SVM'in sonuçları önerilen modelle karşılaştırılmıştır. Deneysel sonuçlar, önerilen modelin karşılaştırılan modellerden daha başarılı olduğunu göstermiştir.

Abebe vd. Afrika boynuzu bölgesindeki deprem büyüklüklerini tahmin etmek amacıyla Bi-LSTM ve transformatör modellerini kullanarak hibrit bir model geliştirmiştir (Abebe vd., 2023). Geliştirilen modelin sonuçları, Bi-LSTM ve LSTM ile karşılaştırılmıştır. Deneysel sonuçlar, geliştirilen hibrit modelin 0,276 MAE değeriyle karşılaştırılan modellerden daha başarılı olduğunu göstermiştir.

Muhammad vd. deprem tahminine yönelik Deep Neural Network (DNN) tabanlı bir model sunmuştur (Muhammad vd., 2023). Veriseti olarak Şili, Hindukuş ve Güney Kaliforniya'nın sismik verileri kullanılmıştır. Çalışmada geliştirilen modelin sonuçları RF, SVM ve LR ile karşılaştırılmıştır. Deneysel sonuçlar, geliştirilen derin sinir ağı modelinin Şili, Hindukuş ve Güney Kaliforniya veri setleri için sırasıyla %98,28, %95,13 ve %99,29 doğruluk değerleriyle karşılaştırılan modellerden daha başarılı olduğunu göstermiştir.

Sadhukhan vd. depremler ile küresel sıcaklıklar arasındaki ilişkiyi belirlemek için derin öğrenme tabanlı karşılaştırmalı bir analiz sunmuştur (Sadhukhan vd., 2022). Çalışmada, Gated Recurrent Unit (GRU), Bi-LSTM, Recurrent Neural Network (RNN) ve LSTM ve modellerinin sonuçları karşılaştırılmıştır. Deneysel sonuçlar, LSTM'in 0,31 MAE değeriyle karşılaştırılan modellerden daha başarılı olduğunu göstermiştir.


Abri ve Artuner, depremler ile iyonosfer arasındaki ilişkilere göre deprem tahmini yapabilmek amacıyla LSTM tabanlı bir model geliştirmiştir (Abri ve Artuner, 2022). Çalışmada, GPS istasyonlarından elde edilen 2012-2019 yılları arasındaki depremlerin toplam elektron içeriği (Total Electron Content-TEC) değerleri kullanılmıştır. Geliştirilen LSTM tabanlı tahmin modeli RF, SVM ve Linear Discriminant Analysis (LDA) ile karşılaştırılmıştır. Deneysel sonuçlar, LSTM'in deprem tespitinde 0,82 doğruluk oranıyla makine öğrenmesi modellerinden daha başarılı olduğunu göstermiştir.

## MATERYAL VE METOT

Bu çalışmada, CNN ve LSTM modelleri kullanılarak hibrit ConvLSTM modeli geliştirilmiştir. Geliştirilen model, USGS tarafından sağlanan gerçek zamanlı bir deprem veriseti üzerinde, geleneksel makine öğrenmesi ve derin öğrenme modelleriyle kapsamlı olarak karşılaştırılmıştır. Ayrıca verisetinin genel yapısını anlamak, görselleştirmek ve öznitelikler arasındaki ilişkileri sunabilmek amacıyla veriseti üzerinde çeşitli analizler yapılmıştır.

### Veriseti

Kullanılan veriseti, zaman, konum, büyüklük ve derinlik gibi 22 öznitelikten oluşmaktadır. Verisetinde 27 Aralık 2023 - 26 Ocak 2024 tarihleri arasında dünya genelinde meydana gelen 9451 depreme ait veriler bulunmaktadır (USGS Earthquakes, 2024). Verisetinde, tarih, enlem, boylam, depremin derinliği, büyüklüğü, deprem büyüklüğünü belirlemek için kullanılan ölçek, depremin yerini belirlemek için kullanılan sismik istasyonların sayısı, bitişik istasyonlar arasındaki mesafe, sismik olayın merkez üstünden en yakın istasyona olan mesafe, sismik olayın coğrafi konumu ve bir kimlik numarası bulunmaktadır. Ayrıca istasyonlar arası seyahat süresi, sismik olayın türü, sismik olayın konumunu ve büyüklüğünü ilk raporlayan ağ, kilometre cinsinden konumun belirsizliği, derinlik ve büyüklük hatası, büyüklüğü hesaplamak için kullanılan sismik istasyon sayısı ve sismik olayın uzmanlar tarafından incelenip incelenmediğini belirten durum öznitelikleri bulunmaktadır. Şekil 1'de belirtilen tarihler arasındaki depremlerin enlem ve boylamlarına göre konumları görülmektedir.



Şekil 1. Enlem ve Boylamlarına Göre Depremlerin Konumları

Şekil 2'de verisetinde bulunan konumlara göre meydana gelen depremler ve büyüklükleri görülmektedir.


Şekil 3'te en büyük 10 deprem ve konumları görülmektedir.

### Veri Ön-İşleme


Veri ön-işleme aşamasında, verisetindeki tarih, enlem, boylam, derinlik, büyüklük ve konum öznitelikleri seçilerek öznitelik boyutu azaltılmıştır. Örnek olarak verisetinin ilk 5 satırı Tablo 1'de görülmektedir.

Tablo 1. Veriseti

Tarih	Enlem	Boylam	Derinlik	Büyükük	Konum
2023-12-27	54.761900	-164.065400	7,443	3,00	Alaska
2023-12-27	43.462200	16.286000	10,000	2,70	Croatia
2023-12-27	54.748000	-164.104667	4,200	0,67	Alaska
2023-12-27	54.771700	-164.123600	9,669	3,60	Alaska
2023-12-27	18.097333	-66.835500	18,310	2,14	Puerto Rico



Şekil 2. Verisetinde Bulunan Konumlara Göre Meydana Gelen Depremler ve Büyüklükleri



Şekil 3. En Büyük 10 Deprem ve Konumları

Depremler, büyüklüğü 2,5'den büyük olanlar tehlikeli (1), 2,5'den küçük olanlar ise tehlikesiz (0) olarak etiketlenmiştir. Verisetinin %80'i modellerin eğitimi için %20'si ise modellerin testi için kullanılmıştır. Eğitim verilerinin %10'u ise model hiper-parametrelerinin optimize edilmesi amacıyla doğrulama için ayrılmıştır. Doğrulama verileri, her bir modelin en iyi sonuçları elde edeceği hiper-parametrelerin belirlenmesi amacıyla kullanılmıştır. Grid arama ile modellerin hiper-parametreleri belirlenmiştir. Modellerin hiper-parametreleri Tablo 2'de görülmektedir.

**Tablo 2. Modellerin Hiper-Parametreleri**

Model	Hiper-parametreler
LR	C: 100, penalty: l2
RF	n_estimators: 200, max_depth: 7, criterion: gini, max_features: auto
SVM	C: 1000, gamma: 0.001, kernel: rbf
XGBoost	max_depth: 7, subsample: 0.5, n_estimators: 60, learning_rate: 0.1
MLP	hidden_layer_sizes: (5,2), activation: relu, max_iter: 200, solver: adam
CNN	Conv1D filters: 64, activation: ReLU, kernel_size:3, pool_size:2
LSTM	number_of_neurons: 64, activation: sigmoid, optimizer: adam, epoch:50, batch_size: 16
ConvLSTM	kernel_size:3, Conv1D filters: 64, activation: ReLU, pool_size:2, number_of_neurons: 64, activation: sigmoid, optimizer: adam, epoch:80, batch_size: 4

### Sınıflandırma Yöntemleri

LR, bağımlı değişkenlerle bağımsız değişkenler arasındaki ilişkiyi belirlemek için kullanılan bir yöntemdir (Gomilla, 2021). Lojistik bir modelde kategorik bir sonuç değişkeninin olasılığı bir veya daha fazla öngörücü sürekli değişken temelinde modellenir. Değişkenler arasında doğrusal olmayan bir ilişki söz konusudur. Bağımlı değişken, sonuç olasılıklarının logaritmasının hesaplanmasını içeren bir dönüşüme tabi tutulur (Backhaus vd., 2023).

RF, daha doğru tahminlere ulaşmak için birden fazla karar ağacından oluşan bir topluluk oluşturan bir makine öğrenmesi algoritmasıdır (Utku, 2023). Oluşturduğu orman, torbalama yöntemiyle eğitilmiş karar ağaçları topluluğudur. Bu yöntem, model kombinasyonlarının genel sonucun doğruluğunu arttırmasını ifade etmektedir. RF, ağaçları oluştururken modele rastgelelik eklemektedir. Dğümleri bölerken rastgele bir özellik alt kümesi arasındaki en iyi özelliği arar (Zhou ve Mentch, 2023).

SVM, N boyutlu bir özellik uzayındaki farklı sınıflardaki veri noktalarını ayırabilen en uygun hiperdüzlemi bulmayı amaçlamaktadır (Cervantes vd., 2020). Hiperdüzlem, sınıfların birbirlerine en yakın noktaları arasındaki marjın, en büyük olmasını sağlamayı amaçlanmaktadır. Hiperdüzlemin boyutu, özelliklerin sayısına bağlıdır. SVM, giriş verilerini daha yüksek boyutlu bir özellik alanına dönüştürmek için çekirdek işlevini kullanır (Chandra ve Bedi, 2021). Çekirdek işlevi, verileri orijinal özellik alanından çekirdek alanına eşlemeyi mümkün kılar. SVM eğitildikten sonra karar sınırının hangi tarafına düştüklerini belirleyerek görülmemiş veri noktalarını sınıflandırabilir.

XGBoost, karar ağaçlarından oluşan zayıf öğrencilerin tahminlerini bir araya getirerek güçlü bir tahmin modeli oluşturur. Her zayıf öğrencinin, öncekilerin hatalarını düzeltmesini sağlayarak doğru bir topluluk modeli oluşturmak için bir güçlendirme tekniği kullanır (Ali vd., 2023). Hataların gradyanlarına göre modelin parametrelerini değiştirerek maliyet fonksiyonunu en aza indirir. XGBoost, yeni bir düğüm eklemenin her düzeyde bir bütün olarak amaç fonksiyonunu geliştirip geliştirmediğini değerlendirerek ağaçları seviye bazında veya genişlik öncelikli olarak oluşturur (Amjad vd., 2022). XGBoost, her seviyedeki her özellik için yapılabilecek her bölmeyle değerlendirir ve amaç fonksiyonunu mümkün olduğu kadar en aza indiren seçer. XGBoost, tüm özellikleri aynı anda dikkate alarak ağaç oluşturma esnasında aynı özelliğin birden fazla kez ziyaret edilmesi ve değerlendirilmesi ihtiyacını ortadan kaldırır (Liv vd., 2023).


MLP, bir giriş ve çıkış katmanı ile bir veya daha fazla gizli katmana sahip bir yapay sinir ağıdır. MLP'de her katman diğerine tam bağlıdır (Cinar, 2020). Modeli eğitmek için geriye yayılım algoritmasını kullanır. Her düğüm, değerini gelen düğüme yalnızca ileri yönde iletir. Giriş katmanı eğitim verisetini girdi olarak alır ve gizli katmana iletir. Gizli katmanlar MLP'nin hesaplama yaptığı katmanlardır. Gizli katmanlar, düğüm değerleriyle çarpılan ağırlıklara sahiptir. Aktivasyon fonksiyonu gizli katmanda aktif düğümleri tanımlamak için kullanılır (Kim vd., 2022). Çıkış katmanı ise üretilen tahmin çıktısını verir.

CNN havuzlama katmanı, konvolüsyon katmanı ve tam bağlantılı katmanlardan oluşan bir derin öğrenme modelidir. Konvolüsyon katmanı, filtreleri ve çekirdekleri kullanarak girdi verilerinden lokal örüntüleri ve özellikleri çıkarır. Filtre, veriden özellikleri çıkarmak için kullanılan küçük boyutlu bir matristir (Cao vd., 2024). Havuzlama katmanı, girdinin uzamsal boyutlarını alt örnekleyerek ağırlık hesaplamasının karmaşıklığını azaltır. Havuzlama katmanları, temel özellikleri korurken daha az önemli bilgileri atarak boyutsallığın azaltılmasına yardımcı olur (Singh vd., 2020). Tam bağlı katman, verideki ilişkileri öğrenme ve probleme özgü çıktılar üretmek amacıyla çıkarılan özellikleri bir sinir ağına entegre eder.

LSTM, kaybolan gradyan sorununu çözmek ve sıralı verilerdeki uzun vadeli bağımlılıkları yakalamak için tasarlanmış bir tekrarlı sinir ağı modelidir (Al-Selwi vd., 2023). LSTM giriş ve çıkış kapıları ile unutmaya kapısı gibi bellek hücrelerini kontrol eden kapılara sahiptir. Bu kapılar, bellek hücresine hangi bilgilerin ekleneceğine ve hangi bilgilerin bellek hücresinden çıkarılacağına karar verir (Ahire vd., 2021). Bu yapı bilgilerin seçici olarak tutulmasına veya unutulmasına olanak tanıyarak uzun vadeli bağımlılıkların öğrenilmesini sağlar. LSTM'in hafızasını temsil eden hücre durumları bilgileri uzun diziler halinde saklayabilir. Gizli durum, hücre durumundaki bilgileri seçici olarak hatırlayabilir, unutulabilir ve çıktı üretebilir (Landi vd., 2021). Unutmaya kapısı, hücre durumundaki hangi bilgilerin saklanacağını ve unutulacağını belirler. Çıkış kapısı, her zaman adımında çıkışı üretmek için kullanılan bilgiyi kontrol eder.

### Geliştirilen Hibrit Model

Şekil 4'te görüldüğü gibi geliştirilen sistemde öncelikle veriseti üzerinde öznelik boyutlarının azaltılması ve depremlerin büyüklüklerine göre etiketlenmesi süreçlerini içeren veri ön-işleme yapılmıştır.

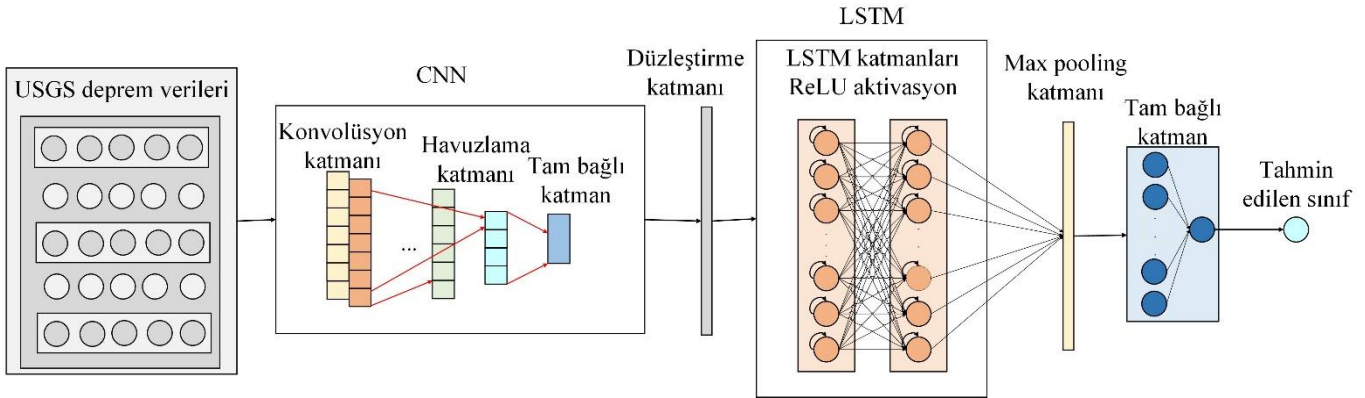


Şekil 4. Geliştirilen Sistemin Akış Diyagramı

Veriseti eğitim, test ve doğrulama için ayrılmıştır. Doğrulama verileri kullanılarak Grid arama yöntemiyle en yüksek doğruluğa sahip hiper-parametreler belirlenmiştir. CNN konvolüsyon, havuzlama ve tam bağlı katmanlardan oluşmaktadır. CNN özellik çıkarımı yaptıktan sonra özellik haritalarını LSTM'e iletir. LSTM sınıflandırma çıktısını üretmektedir. Elde edilen çıktıya göre doğruluk, kesinlik, duyarlılık, F-ölçütü ve AUC değerleri hesaplanmaktadır.

ConvLSTM ile CNN ve LSTM modellerinin öne çıkan özelliklerinden faydalanmak amaçlanmıştır. CNN, özellikle veriden özellik çıkarmak için etkinliği kanıtlanmış bir modeldir. Konvolüsyon ve havuzlama katmanları sayesinde verideki gürültüyü ortadan kaldırır. Tekrarlı bir sinir ağı modeli olan LSTM, sıralı girdi verileri üzerinde etkili olan bir modeldir. LSTM, tekrarlı sinir ağlarında kaybolan gradyan problemini çözmek için geliştirilmiş ve uzun vadeli

ilişkilerin öğrenilmesini kolaylaştıran bir modeldir. LSTM bilgi filtrelemek amacıyla sigmoid fonksiyonunu kullanır. Güncelleme kapıları, bilgi akışlarını kontrol ederek geçmiş verilerden hangilerinin hatırlanacağına karar verir. Şekil 5'te ConvLSTM'in mimarisi görülmektedir.



Şekil 5. ConvLSTM'in Mimarisi

ConvLSTM giriş katmanı, konvolüsyon katmanı, havuzlama katmanı, düzleştirme katmanı, LSTM katmanları, max pooling katmanı, tam bağlı katman ve çıkış katmanından oluşmaktadır. ConvLSTM'in hiper-parametreleri ise CNN bileşeni için kernel\_size:3, Conv1D filters: 64, activation: ReLU ile 1D MaxPooling katmanında pool\_size:2'dir. LSTM bileşeni için her biri 64 nörondan oluşan çift katmanlı LSTM kullanılmıştır. Dense katmanda aktivasyon fonksiyonu olarak sigmoid kullanılmıştır. Optimizasyon algoritması Adam'dır. ConvLSTM modelinde CNN, girdi verilerindeki özellikleri çıkararak konvolüsyon işlemi yardımıyla girdi özelliklerini çok boyutlu gruplara dönüştürür. Düzleştirme katmanı, havuzlama ve konvolüsyon katmanlarından gelen 3 boyutlu özellik haritalarının boyutlarının indirgenmesi için kullanılır. İndirgenen özellikler daha sonra tahmin için LSTM'e iletilir.

### Performans Değerlendirme Metrikleri

Sınıflandırma modellerinin değerlendirilmesinde karışıklık matrisi ve bu matris kullanılarak türetilen doğruluk, kesinlik, duyarlılık ve F-ölçütü metrikleri kullanılmaktadır. Ayrıca, sınıflandırıcının sınıfları ayırt etme yeteneğinin ölçüsü olan AUC metriği kullanılmaktadır. Şekil 6'da karışıklık matrisi görülmektedir.

		Gerçek değerler	
		Tehlikeli (1)	Tehlikesiz (0)
Tahmin değerleri	Tehlikeli (1)	TP	FP
	Tehlikesiz (0)	FN	TN

Şekil 6. Karışıklık Matrisi

Karışıklık matrisi, Şekil 6'da görüldüğü gibi ikili sınıflandırma problemlerinde 2x2 boyutunda bir matristir. TP, tehlikeli olarak etiketlenmiş ve tehlikeli olarak tahmin edilen depremlerin sayısını ifade etmektedir. FN, tehlikeli olarak etiketlenmiş ancak tehlikesiz olarak tahmin edilen depremlerin sayısını ifade eder. FP, tehlikesiz olarak etiketlenmiş ancak tehlikeli olarak tahmin edilen depremlerin sayısını ifade eder. TN ise tehlikesiz olarak etiketlenmiş ve tehlikesiz olarak tahmin edilen depremlerin sayısını ifade eder.

Karışıklık matrisi kullanılarak F-ölçütü, kesinlik, doğruluk, duyarlılık metrikleri elde edilmektedir. Doğruluk Eş. 1'de görüldüğü gibi doğruluk doğru tahmin edilen örneklerin sayısını ifade etmektedir.

$$\text{Doğruluk} = \frac{\text{TN} + \text{TP}}{\text{TN} + \text{FP} + \text{TP} + \text{FN}} \quad (1)$$

Kesinlik, Eş. 2'de görüldüğü gibi tehlikeli olarak tahmin edilen depremlerin gerçekte kaçının tehlikeli olduğunu ifade etmektedir.



$$\text{Kesinlik} = \frac{TP}{TP+FP} \quad (2)$$

Duyarlılık ise Eş. 3'te görüldüğü gibi modelin tehlikeli depremlerin kaçını doğru tahmin ettiğini ifade eder.

$$\text{Duyarlılık} = \frac{TP}{TP+FP} \quad (3)$$

F-ölçütü ise kesinlik ve duyarlılık değerleri kullanılarak Eş. 4'te görüldüğü gibi hesaplanır. F-ölçütü, eşit dağılmayan verisetlerinde hatalı model seçimleri yapılmasına engel olmaktadır.

$$\text{F-ölçütü} = \frac{2 * \text{Hassasiyet} * \text{Duyarlılık}}{\text{Hassasiyet} + \text{Duyarlılık}} \quad (4)$$

AUC değeri hesaplanırken sınıflandırıcının değişen karar eşiklerindeki performansını gösteren ROC eğrisinin altındaki alan ölçülmektedir. ROC eğrisi, farklı karar eşiklerine sahip bir sınıflandırıcının performansını Gerçek pozitif oranı (True Positive Rate - TPR) ve yanlış pozitif oranına (False Positive Rate - FPR) göre çizer. ROC eğrisinin altında kalan alan AUC puanı olarak hesaplanmaktadır. Modelin, tüm sınıflandırma eşiklerinde pozitif veya negatif örnekler arasında ayırım yapmak için göreceli puanları ne kadar iyi üretebildiğini özetler. AUC puanı 0 ile 1 arasında değişir ve AUC değerinin 1 olması mükemmel performansı belirtir.

## DENEYSEL SONUÇLAR

ConvLSTM'in deneysel sonuçları LR, RF, SVM, XGBoost, MLP, CNN ve LSTM ile kapsamlı bir şekilde karşılaştırılmıştır. Her bir model için karışıklık matrisi elde edilerek doğruluk, kesinlik, duyarlılık, F-ölçütü ve AUC değerleri hesaplanmıştır. LR için oluşturulan karışıklık matrisi Şekil 7'de ve karışıklık matrisine göre elde edilen performans metriklerinin sonuçları Tablo 3'te görülmektedir.

		Gerçek değerler	
		Tehlikeli (1)	Tehlikesiz (0)
Tahmin değerleri	Tehlikeli (1)	53	8
	Tehlikesiz (0)	11	1571

Şekil 6. LR için Karışıklık Matrisi

Şekil 7'de görüldüğü gibi LR için TP değeri 53, FP değeri 8, FN değeri 11 ve TN değeri ise 1571'dir.

Tablo 3. LR için Deneysel Sonuçlar

Doğruluk	Kesinlik	Duyarlılık	F-ölçütü	AUC
0,9884	0,8688	0,8281	0,8479	0,9477

Tablo 3'te görüldüğü gibi LR, 1643 örnekten 1624'ünü doğru sınıflandırarak %98,84 doğruluğa ulaşmıştır. Şekil 8 ve Tablo 4'te RF için karışıklık matrisi ve deneysel sonuçlar görülmektedir.

		Gerçek değerler	
		Tehlikeli (1)	Tehlikesiz (0)
Tahmin değerleri	Tehlikeli (1)	54	6
	Tehlikesiz (0)	10	1573

Şekil 8. RF için Karışıklık Matrisi

Şekil 8'de görüldüğü gibi LR için TP değeri 54, FP değeri 6, FN değeri 10 ve TN değeri ise 1573'tür.

**Tablo 4.** RF için Deneysel Sonuçlar

Doğruluk	Kesinlik	Duyarlılık	F-ölçütü	AUC
0,9902	0,9000	0,8437	0,8709	0,9496

Tablo 4'te görüldüğü gibi RF, 1643 örnekten 1627'sini doğru sınıflandırarak %99,02 doğruluğa ulaşmıştır. Şekil 9 ve Tablo 5'te SVM için karışıklık matrisi ve deneysel sonuçlar görülmektedir.

		Gerçek değerler	
		Tehlikeli (1)	Tehlikesiz (0)
Tahmin değerleri	Tehlikeli (1)	55	6
	Tehlikesiz (0)	9	1573

**Şekil 8.** SVM için karışıklık matrisi

Şekil 9'da görüldüğü gibi SVM için TP değeri 55, FP değeri 6, FN değeri 9 ve TN değeri ise 1573'tür.

**Tablo 5.** SVM için Deneysel Sonuçlar

Doğruluk	Kesinlik	Duyarlılık	F-ölçütü	AUC
0,9908	0,9016	0,8593	0,8799	0,9501

Tablo 5'te görüldüğü gibi SVM, 1643 örnekten 1628'ini doğru sınıflandırarak %99,08 doğruluğa ulaşmıştır. Şekil 10 ve Tablo 6'da XGBoost için karışıklık matrisi ve deneysel sonuçlar görülmektedir.

		Gerçek değerler	
		Tehlikeli (1)	Tehlikesiz (0)
Tahmin değerleri	Tehlikeli (1)	57	5
	Tehlikesiz (0)	7	1574

**Şekil 10.** XGBoost için Karışıklık Matrisi

Şekil 10'da görüldüğü gibi XGBoost için TP değeri 57, FP değeri 5, FN değeri 7 ve TN değeri ise 1574'tür.

**Tablo 6.** XGBoost için Deneysel Sonuçlar

Doğruluk	Kesinlik	Duyarlılık	F-ölçütü	AUC
0,9926	0,9193	0,8906	0,9047	0,9732

Tablo 6'da görüldüğü gibi XGBoost, 1643 örnekten 1631'ini doğru sınıflandırarak %99,26 doğruluğa ulaşmıştır. Şekil 11 ve Tablo 7'de MLP için karışıklık matrisi ve deneysel sonuçlar görülmektedir.

		Gerçek değerler	
		Tehlikeli (1)	Tehlikesiz (0)
Tahmin değerleri	Tehlikeli (1)	58	6
	Tehlikesiz (0)	6	1573

**Şekil 11.** MLP için Karışıklık Matrisi

Şekil 101'de görüldüğü gibi MLP için TP değeri 58, FP değeri 6, FN değeri 6 ve TN değeri ise 1573'tür.

**Tablo 7.** MLP için Deneysel Sonuçlar

Doğruluk	Kesinlik	Duyarlılık	F-ölçütü	AUC
0,9926	0,9062	0,9062	0,9062	0,9625

Tablo 67’de görüldüğü gibi MLP, 1643 örnekten 1631’ini doğru sınıflandırarak %99,26 doğruluğa ulaşmıştır. Şekil 12 ve Tablo 8’de CNN için karışıklık matrisi ve deneysel sonuçlar görülmektedir.

		Gerçek değerler	
		Tehlikeli (1)	Tehlikesiz (0)
Tahmin değerleri	Tehlikeli (1)	57	6
	Tehlikesiz (0)	7	1573

Şekil 12. CNN için Karışıklık Matrisi

Şekil 12’de görüldüğü gibi CNN için TP değeri 57, FP değeri 6, FN değeri 7 ve TN değeri ise 1573’tür.

Tablo 8. CNN için Deneysel Sonuçlar

Doğruluk	Kesinlik	Duyarlılık	F-ölçütü	AUC
0,9920	0,9047	0,8906	0,8975	0,9618

Tablo 8’de görüldüğü gibi CNN, 1643 örnekten 1630’unu doğru sınıflandırarak %99,20 doğruluğa ulaşmıştır. Şekil 13 ve Tablo 9’da LSTM için karışıklık matrisi ve deneysel sonuçlar görülmektedir.

		Gerçek değerler	
		Tehlikeli (1)	Tehlikesiz (0)
Tahmin değerleri	Tehlikeli (1)	58	4
	Tehlikesiz (0)	6	1575

Şekil 13. LSTM için Karışıklık Matrisi

Şekil 13’te görüldüğü gibi LSTM için TP değeri 58, FP değeri 4, FN değeri 6 ve TN değeri ise 1573’tir.

Tablo 9. LSTM için Deneysel Sonuçlar

Doğruluk	Kesinlik	Duyarlılık	F-ölçütü	AUC
0,9939	0,9354	0,9062	0,9205	0,9732

Tablo 9’da görüldüğü gibi LSTM, 1643 örnekten 1633’ünü doğru sınıflandırarak %99,39 doğruluğa ulaşmıştır. Şekil 14 ve Tablo 10’da ConvLSTM için karışıklık matrisi ve deneysel sonuçlar görülmektedir.

		Gerçek değerler	
		Tehlikeli (1)	Tehlikesiz (0)
Tahmin değerleri	Tehlikeli (1)	60	4
	Tehlikesiz (0)	4	1575

Şekil 14. ConvLSTM için Karışıklık Matrisi

Şekil 14’te görüldüğü gibi ConvLSTM için TP değeri 60, FP değeri 4, FN değeri 4 ve TN değeri ise 1575’tir.


Tablo 10. ConvLSTM için Deneysel Sonuçlar

Doğruluk	Kesinlik	Duyarlılık	F-ölçütü	AUC
0,9951	0,9375	0,9375	0,9375	0,9993

Tablo 10’da görüldüğü gibi ConvLSTM, 1643 örnekten 1635’ini doğru sınıflandırarak %99,51 doğruluğa ulaşmıştır. Tablo 11 ve Şekil 15’te karşılaştırmalı deneysel sonuçlar görülmektedir.

**Tablo 11.** Karşılaştırmalı Deneysel Sonuçlar

Model	Doğruluk	Kesinlik	Duyarlılık	F-ölçütü	AUC
LR	0,9884	0,8688	0,8281	0,8479	0,9477
RF	0,9902	0,9000	0,8437	0,8709	0,9496
SVM	0,9908	0,9016	0,8593	0,8799	0,9501
XGBoost	0,9926	0,9193	0,8906	0,9047	0,9732
MLP	0,9926	0,9062	0,9062	0,9062	0,9625
CNN	0,9920	0,9047	0,8906	0,8975	0,9618
LSTM	0,9939	0,9354	0,9062	0,9205	0,9732
ConvLSTM	0,9951	0,9375	0,9375	0,9375	0,9993

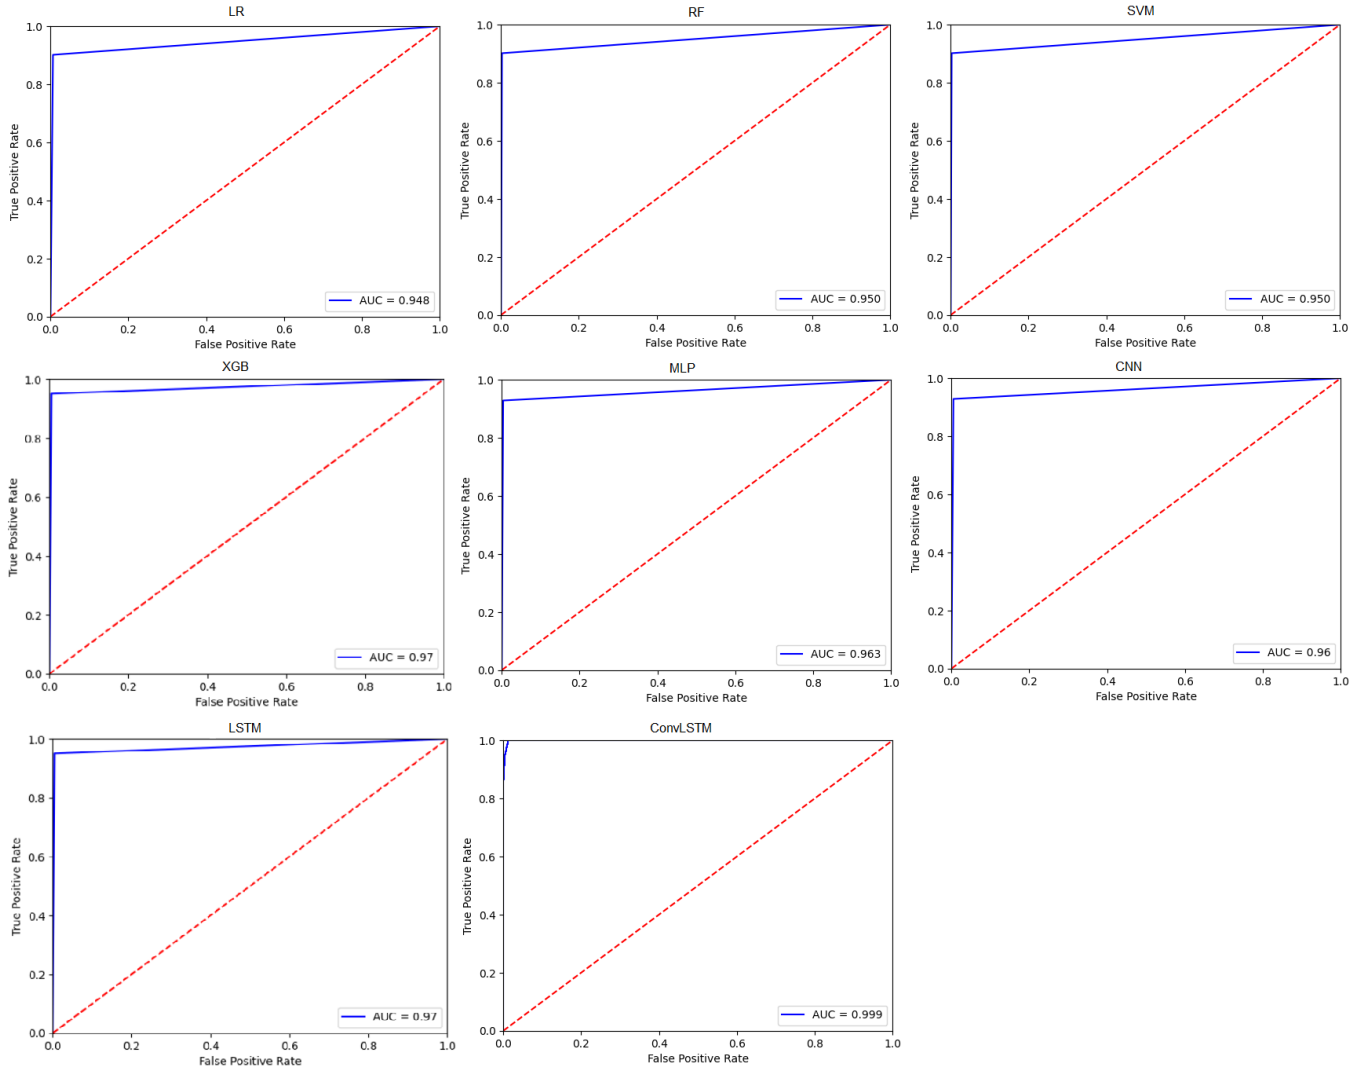
**Şekil 15.** Karşılaştırmalı Deneysel Sonuçlar

Tablo 11 ve Şekil 15'te görüldüğü gibi ConvLSTM 0,9951 doğruluk ve 0,9993 AUC değeriyle karşılaştırılan modellerden daha başarılı olmuştur. ConvLSTM'in ardından sırasıyla LSTM, XGBoost, MLP, CNN, RF ve LR başarılı olmuştur.

Şekil 16'da karşılaştırılan her bir modelin ROC/AUC grafikleri görülmektedir.

Şekil 16'da görüldüğü gibi ConvLSTM karşılaştırılan modellerden daha yüksek bir AUC değerine sahip olmuştur.

ConvLSTM, CNN ve LSTM'in güçlü özelliklerini bir araya getirerek daha etkin bir performansa sahip olmuştur. CNN konvolüsyon katmanları yardımıyla verideki örüntülerin ve özelliklerin çıkarılmasında, LSTM ise zaman serisi verilerindeki uzun-vadeli bağımlılıkların modellenmesinde ve öğrenilmesinde etkilidir. ConvLSTM'in, LR'den daha başarılı olması ConvLSTM'in zaman serileri gibi zamansal yapıları daha iyi anlayabilmesi, LR'nin ise zaman içindeki bu ilişkileri belirlemede yetersiz kalması ile yorumlanabilir. Benzer şekilde RF ve XGBoost verilerdeki zaman bağımlılıkları doğrudan işleyemez. SVM, zaman serilerindeki örüntüleri ve ilişkileri işlemeye ConvLSTM kadar esnek değildir. ConvLSTM'in CNN ve MLP'den daha başarılı olması, ConvLSTM'in zaman serilerindeki mevsimsellik ve trend gibi yapıları daha iyi belirlemesi, CNN ve MLP'nin ise bu tür yapıları belirgin bir şekilde modelleyememesi ile yorumlanabilir. ConvLSTM'in LSTM'den daha başarılı olması, ConvLSTM'in girişler üzerinde konvolüsyon yaparak zaman serilerindeki uzamsal yapıları da yakalayabilmesi yeteneği ile yorumlanabilir.



Şekil 16. ROC/AUC Grafikleri

## SONUÇLAR

Yerkabuğunu oluşturan tektonik plakalar sürekli hareket halindedir. Bu plakaların kenarları fay bölgelerinde birbirine doğru kayarken, sürtünme sebebiyle yavaşlar ve uzun süre boyunca basınç oluşmasına yol açabilir. Hareket kuvveti sürtünmeyi yendiğinde, kabuğun bazı bölümleri aniden kırılarak veya yer değiştirerek bastırılmış basıncın sismik dalgalar biçiminde serbest kalmasına neden olur. Depremlerin meydana getirdiği sismik dalgalar, yüzeye ulaştıklarında yeryüzünde hasar meydana getirebilirler. Dünya genelinde çok sayıda insanın hayatını kaybetmesine, yaralanmasına ve maddi kayıp yaşamasına neden olan depremlerin önceden tahmin edilmesine yönelik çalışmalar aktif bir araştırma alanıdır. Yapay zekâ yöntemleri kullanılarak deprem gibi doğal afetlere yönelik erken uyarı sistemlerinin geliştirilmesi amaçlanmaktadır.

Bu çalışmada, USGS tarafından sağlanan 27 Aralık 2023 - 26 Ocak 2024 tarihleri arasında dünya genelinde meydana gelen depremlerden oluşan bir veri seti kullanıldı. Geliştirilen ConvLSTM modelinin etkinliği LR, RF, SVM, XGBoost, MLP, CNN ve LSTM ile kapsamlı olarak karşılaştırılmıştır. Deneysel sonuçlar, ConvLSTM'in 0,9951 doğruluk ve 0,9993 AUC değeriyle karşılaştırılan modellerden daha başarılı olduğunu göstermiştir. ConvLSTM, deprem olasılıklarını tahmin etmek için jeolojik konumlar gibi uzamsal özellikler ile zamansal özellikleri birleştirmektedir. CNN, uzamsal özelliklerin çıkarılmasını, LSTM ise zamansal örüntülerin modellenmesini sağlamaktadır. Bu sayede, hem jeolojik hem de zaman serisi verilerinden elde edilen verilerin birleştirilmesiyle daha başarılı bir tahmin performansı elde edilmiştir. CNN, jeolojik verilerdeki detayları ve ilişkileri belirlemek için konvolüsyon katmanlarını kullanmaktadır. CNN, jeolojik konumların yakınlığı veya belirli jeolojik özelliklerin kombinasyonu gibi faktörleri çıkarmakta ve LSTM ile birleştirerek daha güçlü bir tahmin modeli oluşturmaktadır.

## TARTIŞMA

Bu çalışmada, depremlerin meydana gelme zamanlarını ve yerlerini tahmin etmek amacıyla ConvLSTM tabanlı hibrit bir model geliştirilmiş ve modelin etkinliği farklı makine öğrenmesi ve derin öğrenme modelleriyle kapsamlı bir şekilde karşılaştırılmıştır. Deneysel sonuçlar, ConvLSTM modelinin 0,99'un üzerinde doğruluk ve AUC değeriyle karşılaştırılan modellerden daha başarılı olduğunu göstermiştir. Deneysel sonuçlar, literatürdeki benzer çalışmalarla karşılaştırıldığında ön plana çıkmaktadır. Örneğin, Ommi ve Hashemi (Ommi & Hashemi, 2024) tarafından sunulan ANN, RF ve SVM'in karşılaştırmalı analizi, ANN'in %97 doğrulukla en iyi performansı gösterdiğini belirtmiştir. Ancak, bu çalışmada kullanılan ConvLSTM modeli daha yüksek bir doğruluk oranına ulaşmıştır. Benzer şekilde, Utku ve Akcayol (Utku & Akcayol, 2024) tarafından önerilen hibrit CNN-GRU modeli de düşük hata oranlarıyla öne çıkmıştır, ancak ConvLSTM'in doğruluk ve AUC değerleri, bu çalışmanın sonuçlarını da aşmaktadır. Deneysel sonuçlar göz önüne alındığında, ConvLSTM'in karmaşık veri yapılarını daha iyi işleyebildiği görülmektedir.

Çalışmanın güçlü yönleri yüksek performans, hibrit model ve verisetinin güncelliğidir. ConvLSTM modeli, diğer modellerle kıyaslandığında yüksek doğruluk ve AUC değerleri elde etmiştir. ConvLSTM, hem uzamsal hem de zamansal verileri başarılı bir şekilde birleştirerek daha kapsamlı ve doğru tahminler yapabilmektedir. CNN'in uzamsal özellikleri çıkarma yeteneğini ve LSTM'in zamansal desenleri modelleme yeteneğini birleştirerek başarılı bir performans sergilemiştir. Ayrıca çalışmada USGS tarafından sağlanan güncel bir veriseti kullanılmıştır. Literatürde bu veriseti ile yapılmış bir çalışma bulunmaması, çalışmanın özgünlüğünü artırmaktadır.

Çalışmanın zayıf yönleri ve sınırlılıkları verisetinin sınırlılığı, bölgesel özelliklerin verisetinde bulunmaması ve model karmaşıklığı olarak değerlendirilebilir. Çalışmada kullanılan veriseti 27 Aralık 2023 - 26 Ocak 2024 aralığını kapsamaktadır. Daha uzun zaman dilimlerini kapsayan verisetleri kullanılarak modelin genelleme yeteneği daha kapsamlı değerlendirilebilir. Veriseti, belirli bölgelerin jeolojik özelliklerine özelleştirilmemiştir. Bölgesel özelliklerin daha detaylı bir şekilde verisetine dâhil edilmesi, uygulanan modellerin performansını artırabilir. Ayrıca ConvLSTM, diğer modellere göre daha karmaşık bir yapıya sahiptir ve daha fazla hesaplama gücü gerektirmektedir.

Gelecek çalışmalarda, daha geniş zaman dilimlerini ve jeolojik özellikleri içeren ve farklı bölgelerdeki depremleri kapsayan verisetleri kullanılarak modelin genelleştirme yeteneğinin artırılması amaçlanmaktadır. Ayrıca transfer öğrenme ve daha gelişmiş optimizasyon tekniklerinin kullanılması amaçlanmaktadır.

## KAYNAKLAR

- Abebe, E., Kebede, H., Kevin, M., & Demissie, Z. (2023). Earthquakes magnitude prediction using deep learning for the Horn of Africa. *Soil Dynamics and Earthquake Engineering*, 170, 107913. <https://doi.org/10.1016/j.soildyn.2023.107913>
- Abri, R., & Artuner, H. (2022). LSTM-based deep learning methods for prediction of earthquakes using ionospheric data. *Gazi University Journal of Science*, 35(4), 1417-1431. <https://doi.org/10.35378/gujs.950387>
- Ahire, P., Lad, H., Parekh, S., & Kabrawala, S. (2021). LSTM based stock price prediction. *International Journal of Creative Research Thoughts*, 9(2), 5118-5122. <https://doi.org/10.6084/m9.doi.one.IJCRT2102617>
- Ali, Z. A., Abduljabbar, Z. H., Taher, H. A., Sallow, A. B., & Almufti, S. M. (2023). Exploring the power of eXtreme gradient boosting algorithm in machine learning: A review. *Academic Journal of Nawroz University*, 12(2), 320-334. <https://doi.org/10.25007/ajnu.v12n2a1612>
- Al-Selwi, S. M., Hassan, M. F., Abdulkadir, S. J., & Muneer, A. (2023). LSTM inefficiency in long-term dependencies regression problems. *Journal of Advanced Research in Applied Sciences and Engineering Technology*, 30(3), 16-31. <https://doi.org/10.37934/araset.30.3.1631>
- Amjad, M., Ahmad, I., Ahmad, M., Wróblewski, P., Kamiński, P., & Amjad, U. (2022). Prediction of pile bearing capacity using XGBoost algorithm: modeling and performance evaluation. *Applied Sciences*, 12(4), 2126. <https://doi.org/10.3390/app12042126>
- Backhaus, K., Erichson, B., Gensler, S., Weiber, R., & Weiber, T. (2023). Logistic regression. In *Multivariate Analysis: An Application-Oriented Introduction*. Wiesbaden: Springer Fachmedien Wiesbaden. <https://doi.org/10.1007/978-3-658-32589-3>

- Bytchkov, S. (2024). Seismology in the Light of Fundamental Sciences. *Open Journal of Earthquake Research*, 13(1), 84-112. <https://doi.org/10.4236/ojer.2024.131004>
- Cao, J., Li, G., Shen, J., & Dai, C. (2024). IFBCLNet: Spatio-temporal frequency feature extraction-based MI-EEG classification convolutional network. *Biomedical Signal Processing and Control*, 92, 106092. <https://doi.org/10.1016/j.bspc.2024.106092>
- Cervantes, J., Garcia-Lamont, F., Rodríguez-Mazahua, L., & Lopez, A. (2020). A comprehensive survey on support vector machine classification: Applications, challenges and trends. *Neurocomputing*, 408, 189-215. <https://doi.org/10.1016/j.neucom.2019.10.118>
- Chandra, M. A., & Bedi, S. S. (2021). Survey on SVM and their application in image classification. *International Journal of Information Technology*, 13(5), 1-11.
- Chaudhary, M. T., & Piracha, A. (2021). Natural disasters—origins, impacts, management. *Encyclopedia*, 1(4), 1101-1131. <https://doi.org/10.3390/encyclopedia1040084>
- Cinar, A. C. (2020). Training feed-forward multi-layer perceptron artificial neural networks with a tree-seed algorithm. *Arabian Journal for Science and Engineering*, 45(12), 10915-10938. <https://doi.org/10.1007/s13369-020-04872-1>
- Colombelli, S., Carotenuto, F., Elia, L., & Zollo, A. (2020). Design and implementation of a mobile device app for network-based earthquake early warning systems (EEWSs): Application to the PRESTo EEWS in southern Italy. *Natural Hazards and Earth System Sciences*, 20(4), 921-931. <https://doi.org/10.5194/nhess-20-921-2020>
- Giridhar, U. S., Prajapati, N., & Sonkusare, R. (2021). Analysis and determination of magnitude of earthquake using sta-lta algorithm. In 2021 12th International Conference on Computing Communication and Networking Technologies (ICCCNT), 1-5. <https://doi.org/10.1109/ICCCNT51525.2021.9579939>
- Gomila, R. (2021). Logistic or linear? Estimating causal effects of experimental treatments on binary outcomes using regression analysis. *Journal of Experimental Psychology: General*, 150(4), 700. <https://doi.org/10.1037/xge0000920>
- He, S., Chen, T., Vennes, I., He, X., Song, D., Chen, J., & Mitri, H. (2020). Dynamic modelling of seismic wave propagation due to a remote seismic source: a case study. *Rock Mechanics and Rock Engineering*, 1-25. <https://doi.org/10.1007/s00603-020-02217-w>
- Huang, C. J., Chen, H. Y., Chu, C. R., Lin, C. R., Yen, L. C., Yin, H. Y., & Kuo, B. Y. (2022). Low-Frequency Ground Vibrations Generated by Debris Flows Detected by a Lab-Fabricated Seismometer. *Sensors*, 22(23), 9310. <https://doi.org/10.3390/s22239310>
- Kaggle. USGS Earthquakes Dataset. (2024) <https://www.kaggle.com/datasets/rupindersinghrana/usgs-earthquakes-2024> Accessed 15.03.24
- Kavianpour, P., Kavianpour, M., Jahani, E., & Ramezani, A. (2023). A CNN-BiLSTM model with attention mechanism for earthquake prediction. *The Journal of Supercomputing*, 79(17), 19194-19226. <https://doi.org/10.1007/s11227-023-05369-y>
- Kim, H. S., Choi, D., Yoo, D. G., & Kim, K. P. (2022). Hyperparameter Sensitivity Analysis of Deep Learning-Based Pipe Burst Detection Model for Multiregional Water Supply Networks. *Sustainability*, 14(21), 13788. <https://doi.org/10.3390/su142113788>
- Landi, F., Baraldi, L., Cornia, M., & Cucchiara, R. (2021). Working memory connections for LSTM. *Neural Networks*, 144, 334-341. <https://doi.org/10.1016/j.neunet.2021.08.030>
- Li, Y., Zeng, H., Zhang, M., Wu, B., Zhao, Y., Yao, X., & Wu, F. (2023). A county-level soybean yield prediction framework coupled with XGBoost and multidimensional feature engineering. *International Journal of Applied Earth Observation and Geoinformation*, 118, 103269. <https://doi.org/10.1016/j.jag.2023.103269>
- Muhammad, D., Ahmad, I., Khalil, M. I., Khalil, W., & Ahmad, M. O. (2023). A generalized deep learning approach to seismic activity prediction. *Applied Sciences*, 13(3), 1598. <https://doi.org/10.3390/app13031598>
- Nievas, C. I., Bommer, J. J., Crowley, H., van Elk, J., Ntinalexis, M., & Sangirardi, M. (2020). A database of damaging small-to-medium magnitude earthquakes. *Journal of Seismology*, 24(2), 263-292. <https://doi.org/10.1007/s10950-019-09897-0>

- Ommi, S., & Hashemi, M. (2024). Machine learning technique in the north zagros earthquake prediction. *Applied Computing and Geosciences*, 22, 100163. <https://doi.org/10.1016/j.acags.2024.100163>
- Pribadi, K. S., Abduh, M., Wirahadikusumah, R. D., Hanifa, N. R., Irsyam, M., Kusumaningrum, P., & Puri, E. (2021). Learning from past earthquake disasters: The need for knowledge management system to enhance infrastructure resilience in Indonesia. *International Journal of Disaster Risk Reduction*, 64, 102424. <https://doi.org/10.1016/j.ijdr.2021.102424>
- Sadhukhan, B., Chakraborty, S., & Mukherjee, S. (2022). Investigating the relationship between earthquake occurrences and climate change using RNN-based deep learning approach. *Arabian Journal of Geosciences*, 15(1), 31. <https://doi.org/10.1007/s12517-021-09229-y>
- Sadhukhan, B., Chakraborty, S., & Mukherjee, S. (2023). Predicting the magnitude of an impending earthquake using deep learning techniques. *Earth Science Informatics*, 16(1), 803-823. <https://doi.org/10.1007/s12145-022-00916-2>
- Shafapourtehrany, M., Batur, M., Shabani, F., Pradhan, B., Kalantar, B., & Özener, H. (2023). A comprehensive review of geospatial technology applications in earthquake preparedness, emergency management, and damage assessment. *Remote Sensing*, 15(7), 1939. <https://doi.org/10.3390/rs15071939>
- Singh, P., Raj, P., & Namboodiri, V. P. (2020). EDS pooling layer. *Image and Vision Computing*, 98, 103923. <https://doi.org/10.1016/j.imavis.2020.103923>
- Utku, A., & Akcayol, M. A. (2024). Hybrid Deep Learning Model for Earthquake Time Prediction. *Gazi University Journal of Science*, 27(3). <https://doi.org/10.35378/gujs.1364529>
- Utku, A. (2023). Deep learning based hybrid prediction model for predicting the spread of COVID-19 in the world's most populous countries. *Expert Systems with Applications*, 231, 120769. <https://doi.org/10.1016/j.eswa.2023.120769>
- Zakka, L., Wuyep, L. C., Monday, I. A., Kadiri, U. A., Thomas, H. Y., Ogugua, E. P., & Gambo, S. (2024). Earthquake Dynamics in Nigeria: Insights, Challenges, and Preparedness Measures. *Asian Journal of Geological Research*, 7(1), 58-73.
- Zhou, S., & Mentch, L. (2023). Trees, forests, chickens, and eggs: when and why to prune trees in a random forest. *Statistical Analysis and Data Mining: The ASA Data Science Journal*, 16(1), 45-64. <https://doi.org/10.1002/sam.11594>
- Zhou, H., Che, A., Shuai, X., & Cao, Y. (2024). Seismic vulnerability assessment model of civil structure using machine learning algorithms: a case study of the 2014 Ms6. 5 Ludian earthquake. *Natural Hazards*, 1-28. <https://doi.org/10.1007/s11069-024-06465-9>