

Deprem Şiddet Tahmini İçin Derin Öğrenme Yöntemlerinin Karşılaştırılması ve Model Önerisi

***Makale Bilgisi / Article Info**

Alındı/Received: 07.07.2024

Kabul/Accepted: 26.12.2024

Yayımlandı/Published: 10.06.2025

Comparison of Deep Learning Methods and Model Proposal for Earthquake Intensity Estimation)

Rabia UYAR^{1*} , **Durmuş ÖZDEMİR²** *Kütahya Dumlupınar Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Kütahya, Türkiye*

© 2025 The Authors | Creative Commons Attribution-Noncommercial 4.0 (CC BY-NC) International License

Öz

Deprem, yer kabuğundaki kırılmalar sonucu oluşan enerjinin sismik dalgalar şeklinde yayılarak yeryüzünü sarsmasıdır. Deprem afeti ülkemizde dahil olmak üzere birçok ülkede şehirleşme ve yapılaşmadaki temel sorunlardan dolayı yeterince önlem alınamadığı için ciddi ölçüde kayıplar meydana getirmektedir. Bu tür kayıpları önlemek amacıyla, araştırmacılar deprem şiddetini ve depremin meydana geleceği yeri önceden tahmin etmek için çalışmalar yürütmektedir. Depremin meydana geleceği zamanı ve şiddetini tahmin edebilmek için, önceden meydana gelen depremlerin olduğu tarih, zaman, derinlik, enlem, boylam ve şiddet gibi verilerin bir araya getirilerek oluşturulan veri setinin çok iyi analiz edilerek faydalı deprem tahmin çalışmaları yürütülmektedir. Bu kapsamda, 1965-2022 yılları arasında ülkemizde meydana gelen büyük ve küçük şiddetteki depremlerin sadece deprem şiddeti verileri esas alınarak, meydana gelmesi muhtemel depremlerin şiddetlerinin tahmin edilmesi amaçlanmıştır. Belirlenen bu amaçlar doğrultusunda, depremlerin şiddetini tahmin edebilmek için, Amerika Birleşik Devletleri Jeolojik Araştırma Kurulundan elde edilen deprem katalog verileri kullanılarak, LSTM (Uzun-Kısa Vadeli Bellek) ile Deprem Şiddeti Tahmin Modeli ve YSA ile Deprem Şiddeti Tahmin Modeli olmak üzere iki farklı tahmin modeli geliştirilmiştir. Önerilen bu iki modelin tahmin sonuçları hem gerçek deprem verileriyle hem de Otomatik Regresif Entegre Hareketli Ortalama (ARIMA) modelinin tahmin sonuçları ile karşılaştırılmıştır. Önerilen iki modelden LSTM ile oluşturulan Deprem Şiddeti Tahmin Modeli (0,561 R-kare değeri), YSA ile oluşturulan modele (0,3 R-kare) kıyasla daha başarılı sonuçlar vermiştir.

Anahtar Kelimeler: Derin öğrenme; Yapay sinir ağları; ARIMA; LSTM.

Abstract

An earthquake is the shaking of the earth by the propagation of the energy generated as a result of fractures in the earth's crust in the form of seismic waves. Earthquake disasters cause severe losses in many countries, including our country, due to the lack of adequate precautions and fundamental problems in urbanization and construction. In order to prevent such losses, researchers are engaged in the process of developing predictive models for the intensity and location of earthquakes. To predict the time and intensity of the earthquake, helpful earthquake prediction studies are carried out by analyzing the data set created by combining data such as the date, time, depth, latitude, longitude, and intensity of previous earthquakes. In this context, the aim is to estimate the intensities of possible earthquakes based only on the earthquake intensity data of the large and small earthquakes that occurred in our country between 1965 and 2022. In line with these determined purposes, two different estimation models, namely the Earthquake Intensity Prediction Model with LSTM (Long short-term memory) and the Earthquake Intensity Prediction Model with ANN, were developed by using earthquake catalog data obtained from the United States Geological Survey Board to predict the intensity of earthquakes. Of the two proposed models, the Earthquake Intensity Prediction Model (0.561 R-square value) created with LSTM gave more successful results compared to the model created with ANN (0.3 R-square value).

Keywords: Deep learning; Artificial neural networks; ARIMA; LSTM

1. Giriş

Deprem, yer kabuğu içindeki kırılmaların ve magnetik hareketliliğin bir sonucu olarak ortaya çıkan titreşimlerin, dalga halinde yayılım yapmasıyla ani yeryüzünün sarsılması olayıdır (Topçu vd. 2017). Bu sarsılma nedeniyle yerkürenin üzerinde yer alan yapıları yıkarak çok ciddi ölçüde can ve mal kayıplarına yol açmaktadır (Özger, 2020; Öztürk ve Alkan, 2022). Ülkemiz, dünyanın en aktif fay hatlarının üzerinde yer aldığı için küçük ve

büyük boyutlarda çok sayıda deprem meydana gelmektedir (Guo vd. 2022, Tan vd. 2021, Wu, 2022).

Geçmişte Türkiye’de birçok yıkıcı deprem meydana geldiği için, gelecekte depremin ülkemizde gerçekleşme ihtimali bulunduğundan depremlerin tahmin edilmesi oldukça önem arz etmektedir. Günümüzde insanoğlu, bilimsel açıdan depremlerin yıkıcı etkilerinden korunmamıza olanak sağlayacak ve sürekli olarak yeni bilgiler ile güncellenen bilgi birikimine sahiptir (Sumy vd.

2022). Fakat, deprem felaketi ülkemizde dahil olmak üzere birçok ülkede şehirleşme ve yapılaşmadaki temel sorunlardan dolayı, can ve mal kayıplarına neden olmaya devam etmektedir. Bu tür temel yetersizliklerin meydana getireceği hasarları en aza indirebilmek ve önemli can ve mal kayıplarının önüne geçebilmek için araştırmacılar, deprem şiddeti ve depremin meydana geldiği yeri önceden tahmin etmek için çalışmalar yürütmektedirler (Kuyuk ve Susumu, 2018; Laurenti vd. 2022). Ancak deprem felaketinin yeri, büyüklüğü ve zamanı kesin olarak doğru bir şekilde tahmin edilememektedir. Bu amaçla, geçmişten günümüze birçok matematiksel hesaplamalar, istatistiksel yöntemler ve teknikler kullanılmaktadır.

Deprem felaketinin çok yönlü analiz edilebilmesi için, depremin şiddeti, yeri ve zamanının belirlenmesi oldukça önemlidir. Çeşitli hesaplama yöntem ve metodlar kullanılarak yapılan tahmin çalışmalarının sayısı, her geçen gün artmaktadır. Yapay sinir ağları, makine öğrenimi algoritmaları vs. gibi yöntem ve teknikler kullanılarak farklı yer ve zamanlarda meydana gelen deprem felaketlerinin arasındaki temel ilişkileri ortaya çıkarmak ve olası depremi önceden tahmin etmek için araştırmalar yapılmaktadır (Kuang vd. 2021a). Kullanılan önemli yöntemlerden birisi de Derin Öğrenme tekniğidir. Derin öğrenmeyle birlikte Makine Öğrenmesi algoritmaları ve Yapay Sinir Ağları da deprem tahmini için kullanılmaktadır (Guo vd. 2022b). Deprem doğal afeti, tüm dünyada olduğu gibi ülkemizde de çok fazla can ve mal kaybına neden olmaktadır. Bu yıkıcı hasarı en aza indirmek için bu tür deprem tahmini çalışmalarına yoğunlaşılması, geleceğimiz adına oldukça umut verici bir eylemdir. Diğer afetlere göre etki alanının geniş olması sebebiyle çok yönlü kayıplar meydana getiren depremler, beşeri ve ekonomik faaliyetlerimizi büyük ölçüde olumsuz yönde etkilemektedir (Jena vd. 2020a). Bu olumsuz etkileri en aza indirmek adına yapılan ve yapılacak olan tüm çalışmalarda, deprem tahmini araştırmaları popülerliğini her zaman koruyacak ve geniş araştırma alanları sunacaktır (Bayrak vd. 2021, Crespi vd. 2022, Doğan 2021, Jiao ve Shan 2022).

Büyük ve küçük şiddette meydana gelen depremler, günümüzde tam anlamıyla tahmin edilemez durumdadır (DeVries vd. 2018, Tan vd. 2021). Fakat depremin meydana getirdiği hasarı azaltmak için önemli adımlar atılarak, maddi ve manevi meydana gelecek kayıpları düşük seviyelere indirmek mümkündür. Deprem tahmin çalışmalarının asıl amacı, meydana gelecek depremleri önceden belirleyerek gerekli önlemlerin alınması ve bu sayede can ve mal kayıplarını azaltmaktır (Sumy vd. 2022). Depremin zamanı ve şiddetini tahmin edebilmek

için, önceki depremlerin tarih, zaman, derinlik, enlem, boylam ve şiddet gibi verilerini içeren veri setleri analiz edilmekte ve bu sayede deprem tahmin çalışmaları yürütülmektedir (Joshi vd. 2022, Song vd. 2022).

Bu çalışmada, 1965-2022 yılları arasında ülkemizde meydana gelen büyük ve küçük şiddetteki depremlerin sadece deprem şiddeti verileri esas alınarak, meydana gelmesi muhtemel depremlerin klasik yapay sinir ağları kullanılarak geliştirilen Deprem şiddeti tahmin modeli (YSA ile DŞTM) ile olası depremlerin şiddetlerinin tahmin edilmesi amaçlanmıştır. Çalışmanın bir diğer amacı ise, depremin temel parametreleri olan tarih, zaman, derinlik, enlem, boylam ve şiddet verileri LSTM (Long-Sort Term Memory) ile DŞTM geliştirilmiştir. LSTM ile DŞTM modeliyle, depremin meydana geldiği zaman periyodunu dikkate alarak meydana gelmesi muhtemel depremin şiddet tahmininin yapılması amaçlanmaktadır. Belirlenen bu amaçlar doğrultusunda, depremlerin şiddetini tahmin edebilmek için, Amerika Birleşik Devletleri Jeolojik Araştırma Kurulundan elde edilen deprem katalog verileri kullanılarak, iki farklı model geliştirilmiştir. Önerilen bu iki modelin tahmin sonuçları hem gerçek deprem sonuçlarıyla hem de Otomatik Regresif Entegre Hareketli Ortalama (ARIMA) modelinin tahmin sonuçları ile karşılaştırılmış ve geliştirilen modellerin başarısı sunulmuştur.

1.1.Literatür Taraması

Bu alandaki çalışmalardan bazıları aşağıda belirtilmiştir. Ren vd. (2023), çalışmada deprem erken uyarı sistemlerinde sismik şiddetin tahmini için bir konvolüsyonel sinir ağı (CNN) kullanılmıştır. CNN, 4 saniyelik tek kanallı dalga formlarını analiz ederek deprem şiddetini sınıflandırır. Model, 5 büyüklüğünün üzerindeki depremleri %97.9 doğrulukla tespit etmiştir. Eğitim ve test verileri, Çin Deprem Ağı Merkezi (CENC) ve Stanford Deprem Veritabanı'ndan (STEAD) alınmıştır. Model, iki büyük deprem dizisi (Çangning ve Tangshan) üzerinde test edilmiş ve genel anlamda başarılı sonuçlar elde etmiştir. CNN'nin hızlı ve güvenilir tahmin yetenekleri, geleneksel yöntemlerle kıyaslandığında önemli avantajlar sunmaktadır. Model, gerçek zamanlı testlerde de iyi bir performans göstermiştir.

Sebatlı-Sağlam ve Çavdur (2021), çalışmada yapay sinir ağı (YSA) ile deprem şiddeti tahmini gerçekleştirilmiştir. Depremin büyüklüğü, derinliği ve merkez üssüne olan uzaklık verileri, YSA'nın girdileri olarak kullanılmıştır. ABD Jeoloji Araştırmaları Kurumu'nun (USGS) veri tabanından elde edilen önemli depremler bu analizlerde temel alınmıştır. Farklı ağ tasarımları değerlendirilmiş ve en iyi sonuçları veren iki gizli katmanlı bir ağ yapısı

belirlenmiştir. Her katmanda beş ve on gizli nöron bulunan bu yapı, ortalama karesel hata (OKH) açısından en iyi performansı sağlamıştır. Eğitim için Levenberg-Marquardt algoritması ile Bayes düzenlemesi kullanılmış ve %96'ya yakın doğruluk elde edilmiştir. Bu yöntemle, deprem sonrası zarar tahmininde kullanılabilecek güvenilir bir model geliştirilmiştir. Çalışma, afet operasyonları yönetiminde de kullanılabilir ve gelecekteki çalışmalarda yaralı sayısı ve ekonomik kayıp gibi parametrelerin tahmini için temel oluşturabilir.

Abri ve Artuner (2022), çalışma depremlerin tespiti için iyonosferdeki Toplam Elektron İçeriği (TEC) değerlerine dayalı LSTM tabanlı derin öğrenme modelleri önermektedir. Araştırmada, iki GPS istasyonundan toplanan TEC verileri kullanılarak depremler ile iyonosferdeki bozulmalar arasındaki ilişki incelenmiştir. Şili bölgesi, güçlü depremlerle bilinirken, Karratha bölgesi daha sakin bir bölge olarak ele alınmıştır. Önerilen LSTM modellerinin performansı, SVM, LDA ve Rastgele Orman sınıflandırıcıları ile karşılaştırılmıştır. Deprem öncesi günlerdeki iyonosferik bozulmaları tahmin eden LSTM tabanlı modeller, test setlerinde %80-85 doğruluk oranı elde etmiştir. Stacked-LSTM modeli, doğruluk, geri çağırma, kesinlik, F1-skora ve ROC eğrisi gibi metriklerde SVM'den daha başarılı bulunmuştur. LSTM tabanlı modellerin deprem tahmininde daha güvenilir olduğu belirlenmiştir. Araştırma, iyonosfer bozulmalarının deprem öncesinde tespit edilebileceğini göstermiştir. Bu bulgular, LSTM tabanlı modellerin iyonosfer gözlemlerine dayalı olarak deprem tahmininde önemli bir araç olabileceğini ortaya koymaktadır. Model, özellikle şiddetli ve orta büyüklükteki depremler için etkili sonuçlar vermektedir.

Pura vd. (2023), çalışma depremlerin tahmin edilmesine yönelik RNN (tekrarlayan sinir ağı) yöntemini kullanarak Düzce İlçesi'nde 1990-2022 yılları arasında meydana gelen 3.0 ve üzeri büyüklükteki depremler üzerinde gerçekleştirilmiştir. Çalışmada, depremlerin b ve d değerleri hesaplanarak öğrenme potansiyelinin artırılması hedeflenmiştir. Marmara bölgesinde belirli bir zaman diliminde depremlerin tespit edilmesi, sismik verilerin yapay sinir ağları ile sınıflandırılması ve geleceğe yönelik tahminler yapılması çalışmanın önemini vurgulamaktadır. Sonuçlar, RNN yöntemlerinin yanı sıra, ay ile Dünya arasındaki mesafe verileri ve b ve d katsayılarının dahil edilmesiyle tahmin performansının önemli ölçüde artırılabilirliğini göstermiştir. Kullanılan veri seti, deprem büyüklüğü, derinlik, ay mesafesi, b değeri ve d değerini içermektedir. Çalışma, farklı yöntemlerin uygulanmasına rağmen, verilerin düzensiz yapısı nedeniyle %100 doğru tahmin yapmanın zor

olduğunu ortaya koymuştur. Ancak, araştırma sonuçlarına ve uygulanan yönteme göre oluşturulan veri seti ile tahmin edilen büyüklüklerin gerçek depremlerin büyüklüklerine yakın olduğu bulunmuştur.

Senkaya vd. (2023), çalışma 6 Şubat 2023 Türkiye depremlerinde yerel sismik özelliklerin hasar üzerindeki etkisini makine öğrenmesi yöntemleriyle analiz etmiştir. Kullanılan giriş özellikleri arasında Vs30 (30 m derinlikte ortalama kayma dalgası hızı), f0 (alanın baskın frekansı), A0 (HVSR oranı) ve EBd (mühendislik temeli derinliği) bulunmakta olup, hedef özellik olarak hasar durumu değerlendirilmiştir. Makine öğrenmesi kapsamında Random Forest (RF), K-en yakın komşu (KNN), Lojistik Regresyon (LR), Karar Ağaçları (DT), Destek Vektör Makineleri (SVM), Stokastik Gradyan İnişi (SGD) ve Çok Katmanlı Algılayıcı (MP) algoritmaları kullanılmıştır. Beş katlı çapraz doğrulama ile uygun hiperparametreler belirlenmiş ve küçük örneklem setlerinde modelleme etkinliği artırılmıştır. RF, hasar ve hasar olmama durumları için sırasıyla %94 ve %92 geri çağırma skorları ile en yüksek performansı göstermiş ve hasar tahmin doğruluğu %93 olmuştur. Diğer algoritmalar da %89 doğruluk oranı ile dikkat çekmiştir, MP hasar olmama durumunda %80, SVM ve SGD ise hasar durumu için sırasıyla %88 ve %80 geri çağırma skorları elde etmiştir. EBd, hasar oluşumunda %52 önem ile en kritik parametre olarak belirlenmiştir; f0, Vs30 ve A0 sırasıyla %24, %18 ve %6 önem değerlerine sahiptir. Bu bulgular, yüksek sismik riskli bölgelerde ilk hasar tahminlerinin makine öğrenmesi yöntemleriyle etkili bir şekilde yapılabileceğini göstermektedir. Gelecek çalışmalar, yerel veri setlerinin artırılması ve küresel veri setlerinin oluşturulmasına odaklanacaktır.

Wang vd. (2023), çalışmada deprem erken uyarı (EEW) sistemleri için derin öğrenme tabanlı yeni bir yaklaşım olan EEWNet'i önermektedir. EEWNet, herhangi bir ön işleme yapmadan tek bir istasyondan kaydedilen ilk birkaç saniye P-dalgasını giriş olarak kullanarak, maksimum yer değiştirmeyi tahmin etmekte ve böylece büyüklüğü hesaplamaktadır. Geniş bir yer altı güçlü hareket kayıtları veri seti kullanılarak eğitim, doğrulama ve test işlemleri gerçekleştirilmiştir. EEWNet'in sonuçları, geleneksel Pd (empirik tepe yer değiştirme) yöntemine kıyasla daha hızlı ve doğru sonuçlar verdiği gösterilmiştir. EEWNet, 4.0 ile 5.9 büyüklüğündeki depremleri ilk 0.5 saniyede tahmin edebilmekte ve bu yöntem, Pd'nin 3 saniyelik verilerini kullandığı büyüklükler arasında 1 ile 2.5 saniye kadar önde tahmin yapabilmektedir. Ayrıca, EEWNet, ilk 0.5 ila 3 saniyelik verilerle büyüklüğü daha iyi tahmin edebilmektedir. Derin öğrenmenin, P-dalgasının ilk saniyelerinden büyüklüğe ilişkin özellikleri insanlardan

daha etkili bir şekilde çıkarabildiği kanıtlanmıştır. Bu bulgular, derin öğrenmenin EEW ve diğer sismoloji alanlarında büyük potansiyele sahip olduğunu göstermektedir.

Khosravikia ve Clayton (2021), bu çalışmada farklı makine öğrenimi tekniklerinin yer hareketi şiddetini tahmin etme konusundaki avantajları ve dezavantajları analiz edilmiştir. Geleneksel olarak, yer hareketi tahminleri doğrusal regresyon modelleri kullanılarak önceden tanımlanmış denklemler ve katsayılar aracılığıyla yapılmaktadır; ancak bu modeller, veride bulunan karmaşık doğrusal olmayan ilişkileri yakalamada yetersiz kalabilmektedir. Bu bağlamda, çalışmada yapay sinir ağları (ANN), rastgele orman (RF) ve destek vektör makineleri (SVM) gibi makine öğrenimi algoritmaları kullanılarak yer hareketi şiddeti tahmin edilmiştir. Model eğitimi, 2005 yılından bu yana Oklahoma, Kansas ve Teksas'ta kaydedilen 4528 yer hareketi kaydı ve 376 deprem olayını (büyüklük 3 ile 5.8 arasında) içeren bir veri seti ile gerçekleştirilmiştir. Sonuçlar, rastgele orman algoritmasının doğruluk açısından diğer algoritmalarından üstün performans gösterdiğini ve yeterli veri olduğunda tüm alternatif modellerin geleneksel doğrusal regresyon yöntemine kıyasla daha yüksek tahmin doğruluğuna sahip olduğunu göstermektedir. Ek olarak, olaylar ve bölgeler arasındaki değişkenlikler rastgele etkiler olarak modele entegre edilmiş, bu sayede aleatorik belirsizlikler azaltılmıştır. RF ve SVM algoritmalarının, mühendislik analizlerinde kullanılacak doğrudan matematiksel denklemler sunmamasına rağmen, yazılım ortamında yeni veri için tahmin yapılmasına olanak tanıdığı vurgulanmıştır.

Nicolis vd. (2021), Şili'deki sismik oranları tahmin etmek için iki Derin Sinir Ağı (DNN) mimarisini, Uzun Kısa Süreli Bellek (LSTM) ve Evrimsel Sinir Ağları (CNN) kullanmaktadır. Önerilen metodoloji üç modülden oluşmaktadır: ön işleme, uzaysal ve zamansal tahmin ve nihai tahmin modülü. İlk modül, Epidemik Tip Artçı Şok Dizileri (ETAS) modelini kullanarak sismik oran tahminleri için yoğunluk fonksiyonunu hesaplamaktadır. LSTM, son 30 günün maksimum sismik yoğunluk verilerini kullanarak bir sonraki günün maksimum yoğunluğunu tahmin ederken, CNN, son 30 günün uzaysal verilerini analiz ederek bir sonraki gün olası deprem alanını tahmin etmektedir. Modeller, R^2 ve doğruluk gibi performans ölçütleriyle doğrulanmıştır.

Kuang vd. (2021), Güney Kaliforniya'da bulunan RIDGECREST bölgesinde bulunan bir sismik ağdan gelen verileri kullanarak depremin odak mekanizmasını tahmin etmeyi sağlayan derin öğrenme tabanlı yeni bir algoritma

önermişlerdir. Yerel veya bölgesel, orta veya büyük ölçekli deprem hareketlerini izlemek için FMnet modeli geliştiren araştırmacılar sonuç olarak otomatik deprem izleme ve raporlama sistemi geliştirmişlerdir.

Karcı ve Şahin (2022), Türkiye'deki depremlerden elde edilen enlem, boylam, tarih, deprem derinliği ve yer yüzeyindeki sismik şiddet gibi parametreleri kullanarak derin öğrenme tabanlı bir uzun-kısa süreli bellek (LSTM) modeli geliştirmiştir. Araştırmada, geliştirilen modelin performansı, geleneksel regresyon yöntemleri, karar ağaçları ve rastgele orman teknikleri ile karşılaştırılmıştır. Elde edilen bulgular, LSTM modelinin %93.4 doğruluk oranı ile en yüksek tahmin başarısını sağladığını göstermektedir. Diğer yöntemlerin ise %85.2 ile %88.7 arasında değişen doğruluk oranlarıyla daha düşük performans sergilediği gözlemlenmiştir. Çalışma, derin öğrenme tabanlı yaklaşımların deprem tahmininde sağladığı avantajları vurgulamaktadır. Sonuç olarak, önerilen model, sismik tehlike değerlendirmeleri için önemli bir katkı sunmakta ve gelecekteki araştırmalara yön vermektedir.

Jena vd. (2020), Hindistan bölgesinden elde edilen yükseklik, deprem büyüklüğü yoğunluğu, merkez üssü yoğunluğu, merkez üssünden olan uzaklık, sismik aktivite yoğunluğu, Deprem derinliği, zemin yapısı, tarihsel deprem verileri, jeolojik özellikler gibi 9 farklı deprem göstergesini girdi parametresi olarak kullanarak deprem olasılığı haritalaması yapmıştır. Araştırmada, derin öğrenme tekniklerinden konvolüsyonel sinir ağı (CNN) kullanılarak bir sınıflandırma modeli geliştirilmiştir. Modelin performansı, doğruluk, F1 skoru ve kesinlik gibi değerlendirme kriterleri ile ölçülmüş ve geleneksel yöntemlerle karşılaştırılmıştır. Elde edilen sonuçlar, önerilen CNN modelinin %95.1 doğruluk oranı ile geleneksel yöntemlere göre daha yüksek bir başarı sağladığını göstermektedir. F1 skoru ve kesinlik değerleri de geleneksel yöntemlerle kıyaslandığında belirgin bir üstünlük sergilemiştir. Bu çalışma, derin öğrenme tekniklerinin deprem risk analizi ve haritalama süreçlerindeki potansiyelini ortaya koymaktadır.

Li vd. (2020), Japonya, Filipinler, Losangeles gibi bölgelerden elde edilen, sekiz farklı veri setiyle derin öğrenme kullanarak DLEP (Explicit and implicit features for accurate Earthquake Prediction) deprem modelini geliştirmişlerdir. Kullandıkları modeldeki örtük özellikleri çıkarmak için CNN ağını kullanmışlardır. Daha sonra DLEP modelini ve CNN ağını birleştirerek başarılı bir şekilde deprem tahmini yapmışlardır.

Wang vd. (2020), derin öğrenme tekniği olan LSTM yöntemini kullanarak deprem tahmini modelleri

geliştirmişlerdir. Farklı bölgelerden elde ettikleri depremler arasındaki uzay-zaman ilişkisinden yararlanarak başarılı sonuçlar elde etmişlerdir.

Altan ve Karasu (2020), topluluk ampirik kip ayrışımı, dalgacık dönüşümü ve ampirik kip ayrışımı olmak üzere üç farklı ayrıştırma yöntemi kullanarak, derin öğrenme yöntemlerinden olan LSTM ile elde ettikleri tahmin modelini başarımını araştırmışlardır. Daha sonra üç ayrı ayrıştırma yöntemiyle elde edilen birleşik modellerin başarımlarını istatistiksel hata ölçütlerine göre değerlendirmişlerdir.

Duman (2016), Batı Anadolu Bölgesinde bulunan ve yoğun sismik aktivite bulunduran dört bölgenin deprem verileri kullanılmıştır. Gutenberg-Richter ölçeğini kullanarak ileri beslemeli geri yayımlı yapay sinir ağı geliştirmiştir. Eğitim tamamlandıktan sonra bu dört farklı bölge için ayrı ayrı test gerçekleştirilmiş ve ağıın başarısı sunulmuştur. Tahmin sonuçlarına bakıldığında ise, gerçekleşmesi beklenen deprem tahmin sonuçları çalışılan dört bölgede de belli oranlarda farklı sonuçlar vermiş fakat bu yöntem kabul edilebilir bir oranda başarılı bulunmuştur.

Utku ve Akçayol (2020), doğal afet, müşteri davranışı gibi bazı olayların meydana gelmeden önce, oluş zamanını önceden tahmin edilmesine yönelik çalışmalar yürütmüşlerdir. Bu kapsamda geliştirdikleri model ile elde edilen sonuçları ARIMA (İstatistiksel Zaman Serisi Tahminleme Yöntemi) ile karşılaştırmışlardır. Deneysel sonuçlara bakıldığında ise derin öğrenme tabanlı geliştirilen bu modelin ileriye dönük oluş zamanı tahmininde, ARIMA'dan daha başarılı olduğunu ileri sürüp kanıtlamışlardır.

Sevinç ve Kaya (2021), Doğu Anadolu Bölgesi'nde yer alan bazı il ve ilçelerin verilerini kullanarak LSTM ve ARIMA modelleriyle analiz gerçekleştirilmiştir. Bu iki modelin, tahmin performansını karşılaştırmak için farklı değerlendirme parametreleri kullanmışlardır. Gerçek değer ile tahmin değeri arasındaki ilişkiyi veren R Kare skor değeri, ARIMA Modelinde, LSTM modeline göre daha yüksek çıkmış ve bu iki modelinde tahmin çalışmalarında başarılı sonuçlar vererek kullanılabilirliğini göstermişlerdir.

Sevinç ve Kaya (2021a), Güneydoğu Anadolu Bölgesi'nde yer alan bazı il ve ilçelerin verilerini kullanarak Özyinelemeli Sinir Ağlarının özel türü olan LSTM modelini kullanarak depremin büyüklük tahmini modelini gerçekleştirmeye çalışmışlardır. Daha sonra bu model ile eğittikleri sistemin R kare skoruna göre değerlendirme yapıp modelin başarısı ortaya konulmuştur.

Fidanboy vd. (2022), resmi kaynaklardan elde ettikleri verileri derin öğrenme teknikleri ile işleyerek yeni bir model geliştirmişler ve bu model ile risk haritası elde etmişlerdir. OYAT (Orman Yangını Tahmini) bu model, dinamik veriler ile güncellenebilir yapıda olup görsel olarak da saklanabilir. OYAT modelinin, veri setinin de zamanla büyümesiyle daha verimli ve başarılı sonuçlar vereceği öngörülmektedir. Bu modelle geliştirilen yapının şuan %98 doğruluk oranına sahip olduğu görülmektedir.

Sabah ve Bayraktar (Sabah ve Bayraktar 2020), çeşitli deprem senaryoları oluşturarak Düzce ili ve çevresindeki deprem şiddet bölgeleri seçilmiş daha sonra Türkiye İstatistik Kurumundan (TÜİK) aldıkları resmi veriler ile az hasarlı, orta hasarlı ve çok hasarlı binalar için istatistiksel olarak hasar tahmin sistemi geliştirmişlerdir. Bu hasar tahmin sistemi ile bölgede gerekli olan çadır ihtiyacını belirlemeye çalışarak bölge halkının maddi imkanındaki eksikliklerini gidermeyi amaçlamışlardır.

Akyüz (2019), deprem büyüklüğü verilerini inceleyerek, her yıl max deprem büyüklüğünü kaydetmiş ve veri seti oluşturmuştur. Daha sonra oluşturmuş olduğu bu veri setini kullanarak deprem olma olasılığını incelemiştir. Bu incelemeyi, kısa süreli elde edilen verileri göz önünde bulundurarak, uzun süreli depremlerin olma olasılığını elde ederek gerçekleştirmiştir. K- kare, Ortalama Hata, Ortalama Mutlak Hata vb. gibi birden çok istatistiksel dağılım kullanarak yapılan bu çalışmaya göre, gelecek 10 yıl içinde 5 ve üzeri şiddetinde deprem olma olasılığı %10 olarak belirlenmiştir.

Emeksiz ve Tan (2021), hibrit ayrıklaştırma yöntemi geliştirerek bu yöntem ile veri seti oluşturmuşlardır. Daha sonra bu veri setini Geri Beslemeli Sinir Ağına uygulayarak çok adımlı bir tahminleme işlemi gerçekleştirmişlerdir. Önerilen bu modelin tekil ayrıklaştırma ile oluşturulan yöntemden daha başarılı olduğunu tespit etmişlerdir. Tahmin performansını ise determinasyon katsayısı, ortalama mutlak yüzde hata ve ortalama karakök hata ile hesaplayıp incelemişler. Önerilen hibrit modelin, yüksek hassasiyette tahminler gerçekleştirmesi modelin başarısını göstermiştir.

Özmen (2011), Kastamonu ili ve çevresinde 4.0 ve daha büyük şiddette meydana gelmiş olan depremlerin verilerini kullanarak Gutenberg-Richter ölçeğinde magnitüd-frekans parametreleri arasındaki bağıntıdaki a ve b değerlerini bulmuştur. Ve bu değer parametrelerden yararlanarak, Poisson modelini farklı büyüklükteki depremlerin meydana gelme olasılığını istatistiksel olarak incelemişlerdir. Bu modele göre gelecek 100 yıl içerisinde 7.5 şiddetinde deprem olma olasılığı %75 olarak tahmin edilmiştir.

Topçu vd. (2017), iyonosfer toplam elektron içeriği, atmosferin ısı ve sıcaklık değerleri, bağıl nem miktarı ve TUSAGA-Aktif konumlama sistem istasyonunun kinematik deprem verilerini, kullanarak deprem tahmini yapmışlardır.

Sağlam ve Çavdur (2022), ileri beslemeli geri yayımlı yapay sinir ağı ile deprem büyüklüğünü (earthquake magnitüde), derinliğini ve depremi birebir yaşayan afetzedelerin depremin gerçekleştiği Merkez üssüne olan uzaklık mesafelerine bakarak deprem şiddet tahmini yapmışlardır. Farklı yapay sinir ağı tasarımları denemişler ve en uygun sinir ağı tasarımı elde edip önermişlerdir. Uygun görülen sinir ağı ile çeşitli eğitim algoritmalarını kullanarak eğitim gerçekleştirmişler. Daha sonra farklı sinir ağı tasarımlarını ve farklı eğitim algoritmalarının performanslarını karşılaştırmışlardır. Bu karşılaştırma için, ortalama karesel hata ve korelasyon katsayısı kullanılmış ve analiz edilmiştir. Bu çalışma için iki gizli katman ve her katman için beş ve on gizli nöron kullanılmıştır. Ağ, Bayes düzenlemesi ve Levenberg-Marquardt eğitim algoritmasının kullanıldığı durumda en iyi performansı sergilemiştir. Turgut vd. (2019), analog bilgileri sersörler ile elde ettikleri verileri veri kaybına uğramadan veri tabanına, kaydetmişlerdir. Daha sonra oluşturulan bu veri tabanını KNN (K-Nearest Neighbors), RF (Random Forest) algoritmaları tarafından işlenmiş ve YSA ağ modeli oluşturulmuştur. Bu şekilde oluşturulan sistemin tahmin değeri %87 olarak hesaplanmıştır.

Literatürde de görüldüğü üzere deprem şiddeti tahmin çalışmalarında yapay sinir ağları, makine öğrenmesi algoritmaları ve derin öğrenme mimarileri kullanarak yeni modeller geliştirerek deprem şiddeti tahmin edilmeye çalışılmıştır. Fakat derin öğrenme modellerine dayalı çalışmaların oldukça kısıtlı olduğu ve bu yöntemlerle yapılan çalışmalara ihtiyaç olduğu görülmüştür. Bu çalışmalarda tarih, zaman, enlem, boylam ve derinlik gibi parametreler kullanılarak deprem şiddeti tahmini yapılmaya çalışılmıştır.

2. Materyal ve Metot / Materials and Methods

2.1. Deprem veri setinin hazırlanması

Amerika Birleşik Devletleri Jeolojik Araştırma Kurulundan elde edilen 3.0- 10.0 şiddetlerindeki depremler .csv formatında indirilip, kaydedilmiştir. Daha sonra deprem şiddet tahmininde kullanılacak depremin meydana geliş tarihi, depremin meydana geldiği zaman, enlem, boylam, derinlik ve büyüklük bilgileri haricindeki alanlar ve veri setinde yer alan istenmeyen boş veri alanları temizlenmiştir.

Çizelge 1. $X_m \geq 3.0$ veri kümesinin detayları.

Tarih	01.01.1965 - 31.12.2022
Enlem	36.0 – 42.0
Boylam	26.0 – 45.0
Derinlik	0-500
Büyüklük	3.0- 10.0
Sarsıntı Türü	Deprem
Deprem Sayısı	24.007

2.2. Çalışmada önerilen deprem tahmin modelleri ve uygulama süreçleri

Bu çalışmada deprem tahmini ile ilgili bir model önerilmiştir. Deprem büyüklüğü tahmin modeli, Python programlama dili ve Python için bir derin öğrenme kütüphanesi olan keras kullanılarak hazırlanmıştır. 1965-2022 yılları arasında meydana gelen depremler için, meydana gelecek depremleri tahmin edebilmek amacıyla Long Short Term Memory kullanılarak bir model oluşturulmuştur.


2.2.1. Yapay sinir ağı ile deprem şiddeti tahmin modeli

Yürütülen çalışmada, önerilen modelin programlaması için Python programlama dili, geliştirilmesi için ise PyCharm IDE'si kullanılmıştır. Derin öğrenme modellerini oluşturmak için ise Keras ve Tensorflow kütüphaneleri kullanılmıştır. Keras kütüphanesi, farklı türden derin öğrenme modellerinin tanımlanması ve eğitilmesini sağlayan derin öğrenme kütüphanesidir. Tensorflow ise, derin öğrenme modelleri geliştirmek ve değerlendirmek için güvenilir ve açık kaynaklı Python kütüphanesidir.

Keras kütüphanesi kullanılarak tasarlanan YSA ile DŞTM;

- 4 girişli girdi katmanı
- 5 gizli katmanı
- 1 çıkışlı çıktı katmanı

kullanılarak oluşturulmuştur. Oluşturulan YSA ile DŞTM modelinin şematik gösterimi Şekil 1'de verilmiştir.



Şekil 1. Deprem şiddeti tahmini için önerilen YSA modeli

Deprem şiddeti tahmin modelini oluşturmak ve modelden bir çıktı değeri almak için, modelde kullanılacak veriler sırasıyla, Girdi (X_n) ve Çıktı (Y) olarak bölünmesi gerekmektedir. Bu uygulamada girdi parametreleri;

- Zaman Damgası (X1)
- Derinlik (X2)
- Enlem (X3)
- Boylam verileridir (X4).

Çıktı olarak ise deprem şiddeti bilgisi alınmaktadır. Keras kütüphanesi kullanılarak model oluşturuldu. Daha sonra oluşturulan bu modele belirtilen sayıda gizli katmanlar eklendi ve bu katmanların düğüm sayıları, aktivasyon fonksiyonları ve eğitim sayıları belirlendi. Bu modelde aktivasyon fonksiyonu olarak Relu, Lineer ve Softmax olmak üzere üç tane aktivasyon fonksiyonu kullanılmıştır. Kayıp fonksiyonu olarak ise Mean Squared Error kullanılmış ve optimizasyon fonksiyonu olarak da Adam fonksiyonu kullanılmıştır. Oluşturulan model 20'şer batchler halinde Adam optimizasyon fonksiyonunu çalıştırmaktadır. Modelde kullanılan veri seti, eğitim ve test veri kümeleri olmak üzere iki farklı veri kümesine bölünmüş ve tüm veri seti 100 kez eğitilmiştir. Model veri kümelerinin, 0.80'ini kullanarak eğitilmekte ve kalan 0.20 ile de test edip, hatalarını düzeltmektedir.

Deprem şiddet tahmin modelinde kullanılan epochs, batch, katmanlardaki nöron sayıları, optimizasyon fonksiyonu, kayıp fonksiyonu ve aktivasyon fonksiyonları değiştirilip farklı kombinasyonlarla tekrar eğitilmiş ve en iyi sonuç veren parametreler belirlenmiştir. YSA ile DŞTM'de en iyi performans veren parametreler Çizelge 2'te gösterilmiştir.

Çizelge 2. YSA ile deprem şiddet tahmin modelinde kullanılan parametreler

Parametreler	Değerler
Epoch	100
Gizli Katman Sayısı	5
Batch	20
Katmanlardaki Nöron Sayısı	128,64,64,32,32
Aktivasyon Fonksiyonları	Lineer, Relu, Softmax
Optimizasyon Fonksiyonu	ADAM
Kayıp Fonksiyonu	Mean Squared Error

2.2.2. Uzun kısa süreli bellek ile deprem şiddet tahmin modeli

Genellikle bir sonraki meydana gelecek durumu tahmin edebilmek için kullanılan özyinelemeli sinir ağlarından biri olan LSTM, girdiler arasında ilişki kurarlar ve kurdukları tüm ilişkileri hatırlamaktadırlar (Wang vd., 2020b). LSTM, aynı zamanda uzun süreli bağımlılık durumunu tekrarlayan sinir ağlarından doğru bir şekilde modellemek için oluşturulmuş ve derin öğrenme için kullanılan, tekrarlayan sinir ağı mimarilerinden birisidir. LSTM'ler zaman serisi verilerini kullanarak, tahmin problemlerinin çözümünde kullanılan uygun yapılardır. LSTM ağları kullanılarak tasarlanan bu model;

- Katmanda 128 LSTM hücresi
- 2. Katmanda 64 LSTM hücresi
- 3. Katmanda 64 LSTM hücresi
- 4. Katmanda 32 LSTM hücresi
- 1 tane dropout katmanı
- 1 tane çıktı katmanı

kullanılarak tasarlanmıştır. Önerilen LSTM ile DŞTM modelinin şematik gösterimi Şekil 2' de verilmiştir.



Şekil 2. LSTM ile deprem şiddet tahmin modeli

LSTM ile deprem şiddet tahmin modelinde, Aktivasyon fonksiyonu olarak ReLu, Lineer ve Softmax kullanılmıştır. Optimizasyon fonksiyonu olarak ADAM, kayıp fonksiyonu olarak ise Mean Squared Error kullanılmıştır. Oluşturulan modelde dropout oranı 0.2 olarak alınmıştır. LSTM ağları için girdi verileri, veri normalizasyon işlemleri yapılarak tekrardan şekillendirilmiştir. LSTM ile model eğitiminde, parametre değerlerinin sırası önemlidir. Bu sebeple, veri kümesi sıralandıktan sonra bölünmektedir. Veri kümeleri, 0.80 eğitim ve 0.20 test veri kümesi olmak üzere bölünmüştür.

LSTM modeli 20'şer batchler halinde ADAM optimizasyon fonksiyonunu çalıştırmaktadır. Tüm veri kümesi eğitim için 100 kez tekrarlanmıştır. Oluşturulan bu modelde, eğitim için kullanılan veri kümesi 1'er haftalık periyotlar halinde alınmaktadır. İlk 1 haftalık deprem verileri alınarak sekizinci günün, daha sonra ikinci 1 haftalık deprem verileri alınarak dokuzuncu günün deprem şiddet tahmin edilmeye çalışılmıştır. 1'er haftalık periyotlar halinde, eğitim kümeleriyle model eğitilmektedir. Modelde gelecek günlerin depremlerinin tahmini için gerekli değişken tanımlamaları yapılmaktadır. Gelecek dönemlerde meydana gelmesi muhtemel depremleri tahmin etmek için, kullanılmak istenen geçmiş günlerin sayısı ve geçmiş günlere bağlı olarak, tahminde bulunmak istenilen gelecek günlerin sayısı belirlenmiştir. Modelin performansını ortaya koymak adına hem eğitim kümesiyle hemde test kümeleri kullanılarak tahminler yapılmaya çalışılmıştır.

Oluşturulan LSTM ile deprem şiddet tahmin modelinde farklı farklı epoch, batch, nöron sayıları, aktivasyon fonksiyonları, kayıp fonksiyonu ve optimizasyon fonksiyonu parametreleriyle eğitilmiş ve en iyi sonuç veren parametre değerleri belirlenmiştir. En iyi performans veren parametre değerleri Çizelge 3'de sunulmuştur.

Çizelge 3. LSTM ile deprem şiddeti tahmin modelinin parametreleri

Parametreler	Değerler
Epoch	100
1.LSTM Hücresi	128
2.LSTM Hücresi	64
3.LSTM Hücresi	64
4.LSTM Hücresi	32
Batch	20
Dropout Oranı	0.2
Aktivasyon Fonksiyonu	Lineer, ReLU, Softmax
Optimizasyon Fonksiyonu	ADAM
Kayıp Fonksiyonu	Mean Squared Error

3.Bulgular

Bu bölümde önerilen iki modelin ve istatistiki tahmin modeli olan ARIMA modelinin performans sonuçları ölçülmüş ve detayları verilmiştir.

3.1.Elde edilen performans sonuçlarının değerlendirilmesi

Hem önerilen YSA ile deprem şiddeti tahmin modelinin hem LSTM ile deprem şiddeti tahmin modelinin hemde tahmin araştırmalarında sıklıkla kullanılan ARIMA modelinin performansları, $xM \geq 3.0$ veri kümesi için performans değerleri ölçülmüştür.

Çizelge 5. ARIMA modelinin gerçek veri seti ile karşılaştırılması

Tarih	Enlem	Boylam	Der(km)	Yer	xM	ARIMA ile DŞTM
18.10.2022	38.6562	39.7057	007.0	Malatya	5.9	4.0
10.08.2022	39.8423	39.4025	005.3	Elazığ	5.6	4.52
07.07.2022	38.5530	39.4844	022.3	Elazığ	6.1	5.22
22.03.2022	38.3819	26.9856	012.0	İzmir	6.7	5.10
26.02.2022	38.1943	38.8520	002.7	Malatya	5.5	4.5

3.3. Yapay sinir ağı ile deprem şiddeti tahmin modeli

3.3.1. Yapay sinir ağı ile DŞTM'nin performans

Yapay Sinir Ağı Deprem şiddeti tahmin modeli, deprem tahmini için oluşturulan $xM \geq 3.0$ veri kümesi ile eğitilmiş ve sonuçlar Çizelge 6'da verilmiştir.

Çizelge 6. YSA ile DŞTM modelinin performans sonuçları

Ölçüm Metriği	Performans Sonucu
R-Kare	0.3
MAE	0.220
MSE	0.158
RMSE	0.357

3.3.2. Yapay sinir ağı ile DŞTM'nin gerçek veri seti ile test edilmesi

Meydana gelen depremlerin bir kısmı; zaman, tarih, derinlik, enlem ve boylam bilgileri ile deprem şiddeti tahmin modeli test edilmiş ve gerçek deprem sonuçlarıyla YSA ile DŞTM'nin tahmin ettiği deprem sonuçlarının karşılaştırılması Çizelge 7'de gösterilmiştir.

3.2. ARIMA

İstatistiksel modelleme yöntemi olan ARIMA ile deprem tahmini için oluşturulan $xM \geq 3.0$ veri kümesi eğitilmiştir.

3.2.1. ARIMA Modelinin Performans Sonuçları

ARIMA modeli, deprem tahmini için oluşturulan $xM \geq 3.0$ veri kümesi ile eğitilmiş ve performans sonuçları Çizelge 4'te verilmiştir.

Çizelge 4. ARIMA modelinin performans sonuçları

Ölçüm Metriği	Performans Sonucu
R-Kare	0.268
MAE	0.312
MSE	0.173
RMSE	0.513

3.2.2. ARIMA modelinin gerçek veri seti ile test edilmesi

Meydana gelen depremlerin bazıları tarih, derinlik, enlem ve boylam değerleri ARIMA modeli ile test edilmiş ve gerçek deprem sonuçları ile modelin tahmin ettiği deprem sonuçları Çizelge 5'te karşılaştırılmıştır. Çizelge 5'teki sonuçlara bakıldığında ARIMA modelinin gerçek deprem değerlerine çok yakın olmayan ve birbirine çok yakın deprem tahmininde bulunduğu görülmektedir.

Çizelgeye bakıldığında YSA ile Deprem Şiddeti Tahmin Modelinin gerçek deprem değerlerine yakın deprem tahmininde bulunduğu görülmektedir.

Çizelge 7. YSA ile DŞTM modelinin gerçek veri seti ile karşılaştırılması

Tarih	Enlem	Boylam	Der(km)	Yer	xM	YSA ile DŞTM
18.10.2022	38.6562	39.7057	007.0	Malatya	5.9	4.40
10.08.2022	39.8423	39.4025	005.3	Elazığ	5.6	4.72
07.07.2022	38.5530	39.4844	022.3	Elazığ	6.1	5.67
22.03.2022	38.3819	26.9856	012.0	İzmir	6.7	5.42
26.02.2022	38.1943	38.8520	002.7	Malatya	5.5	4.70

3.4. Long Short Term Memory ile deprem şiddeti tahmin modeli

3.4.1. LSTM ile deprem şiddeti tahmin modelinin performans sonuçları

LSTM ile deprem şiddeti tahmin modeli, deprem tahmini için oluşturulan $xM \geq 3.0$ veri kümesi ile eğitilmiş ve sonuçlar Çizelge 8'de verilmiştir.

Çizelge 8. LSTM ile DŞTM modelinin performans sonuçları

Ölçüm Metriği	Performans Sonucu
R-Kare	0.561
MAE	0.2
MSE	0.160
RMSE	0.373

LSTM ile deprem şiddeti tahmin modelinin $xM \geq 3.0$ veri kümesi ile eğitim sonuçlarına bakıldığında R-Kare değerinin 0.561 ile DŞTM'ne göre daha yüksek olduğu ve ortalama mutlak hata değerinin de daha düşük olduğu görülmektedir. LSTM ile deprem şiddeti tahmin modelinin $xM \geq 3.0$ veri kümesiyle tahmin sonuçları incelendiğinde 1 haftalık tahminde en yüksek 5.7 şiddetinde, en düşük 3.5 şiddetinde deprem şiddeti tahmininde bulunmuştur. Kısaca LSTM ile deprem şiddeti tahmin modeli 1 haftalık kısa bir periyotta 5.7 şiddetinin üzerinde herhangi bir

deprem meydana gelmeyeceğini tahmin etmiştir. İki haftalık tahmin sonuçları incelendiğinde ise en yüksek 5.0 şiddetinde, en düşük 3.7 şiddetinde deprem tahmini yaptığı görülmektedir. Buda LSTM ile deprem şiddeti tahmin modelinin 2 haftalık süreçte 5.0 şiddetinin üstünde bir deprem meydana gelmeyeceğini tahmin ettiği anlamına gelmektedir.

3.4.2. LSTM ile deprem şiddeti tahmin modelinin gerçek veri ile karşılaştırılması

2022 yılı Aralık ayında meydana gelen depremlerin oluş zamanı, tarih, derinlik, enlem ve boylam bilgilerine bakıldığında 2022 Aralık ayında en yüksek 6.9, en düşük 3.1 şiddetinde deprem meydana geldiği Çizelge 9'da görülmektedir.


Çizelge 9. 2022 Aralık ayında meydana gelen depremlerin listesi

No	Kod	Tarih	Zaman	Enlem	Boylam	Derin	xM	MD	ML	Mw	Ms	Mb	Yer
000001	20221231062528	2022.12.31	06:25:28	37.1217	36.5458	010.3	3.6	0.0	3.4	3.6	0.0	0.0	Osmaniye
000002	20221231014148	2022.12.31	01:41:48	35.2116	32.4582	008.9	4.3	0.0	5.2	0.0	0.0	0.0	Akdeniz
000003	20221231124250	2022.12.31	12:42:50	39.1120	40.5025	005.0	4.0	0.0	0.0	3.7	0.0	0.0	Elazığ
000004	20221231055705	2022.12.31	05:57:05	37.1217	35.5458	004.1	3.9	0.0	3.7	3.8	0.0	0.0	Adana
000005	20221231111413	2022.12.31	11:14:13	39.1717	40.6958	001.0	4.7	0.0	3.4	3.5	0.0	0.0	Elazığ
000006	20221229173159	2022.12.29	17:31:59	37.1806	32.4586	002.8	3.1	0.0	3.7	3.8	0.0	0.0	Konya
000007	20221229005018	2022.12.29	00:50:18	35.9210	32.5228	010.0	4.2	0.0	6.4	6.4	0.0	0.0	Akdeniz
000008	20221228222814	2022.12.28	22:28:14	35.1003	32.6850	009.2	6.9	0.0	4.0	4.1	0.0	0.0	Akdeniz
000009	20221226034022	2022.12.26	03:40:22	37.1947	29.3320	003.7	3.6	0.0	4.2	4.1	0.0	0.0	Denizli
000010	20221226110334	2022.12.26	11:03:34	38.2015	43.6359	005.0	3.2	0.0	3.9	4.0	0.0	0.0	Van
000011	20221223212543	2022.12.23	21:25:43	38.2879	26.3693	009.0	3.7	0.0	3.4	3.6	0.0	0.0	İzmir
000012	20221222124716	2022.12.22	12:47:16	39.3214	28.5698	005.0	5.0	0.0	4.9	4.7	0.0	0.0	Balıkesir
000013	20221222024345	2022.12.22	02:43:45	38.2563	42.5450	001.5	3.8	0.0	4.1	4.0	0.0	0.0	Muş
000014	20221221101435	2022.12.21	10:14:35	38.3265	42.2010	002.7	4.3	0.0	4.3	4.3	0.0	0.0	Muş
000015	20221220200807	2022.12.20	20:08:07	38.8957	42.2134	001.0	3.1	0.0	4.3	4.2	0.0	0.0	Muş
000016	20221219062559	2022.12.19	06:25:59	40.4574	29.6778	006.9	3.9	0.0	3.8	3.7	0.0	0.0	Bursa
000017	20221219092336	2022.12.19	09:23:36	39.6279	35.2783	004.9	5.2	0.0	3.8	4.0	0.0	0.0	Kayseri
000018	20221219055846	2022.12.19	05:58:46	39.1937	35.2846	003.5	5.0	0.0	3.6	3.4	0.0	0.0	Kayseri
000019	20221219203529	2022.12.19	20:35:29	37.2837	32.5654	003.0	4.9	0.0	0.0	4.2	0.0	0.0	Konya
000020	20221215055900	2022.12.15	05:59:00	37.4121	29.5158	003.5	4.3	0.0	3.7	0.0	0.0	0.0	Denizli
000021	20221214131250	2022.12.14	13:12:50	35.3210	32.1356	007.1	4.0	0.0	3.8	3.7	0.0	0.0	Akdeniz
000022	20221213235745	2022.12.13	23:57:45	35.4620	33.0051	005.7	3.6	0.0	3.5	3.4	0.0	0.0	Akdeniz
000023	20221212024243	2022.12.12	02:42:43	39.2085	40.7410	004.8	4.7	0.0	3.8	3.7	0.0	0.0	Elazığ
000024	20221212221943	2022.12.12	22:19:43	38.3025	43.5564	005.2	4.2	0.0	5.0	5.4	0.0	0.0	Van
000025	20221211202149	2022.12.11	20:21:49	38.4560	26.1009	008.7	5.2	0.0	4.1	4.0	0.0	0.0	İzmir
000026	20221210032115	2022.12.10	03:21:15	38.1248	44.5306	002.0	4.6	0.0	4.1	4.2	0.0	0.0	Türkiye -İran Sınır Bölgesi
000027	20221210111713	2022.12.10	11:17:13	35.9817	32.4238	005.0	4.6	0.0	4.0	3.9	0.0	0.0	Akdeniz
000028	20221210004951	2022.12.10	00:49:51	39.8947	28.4613	006.0	4.7	0.0	3.6	3.4	0.0	0.0	Balıkesir
000029	20221207225508	2022.12.07	22:55:08	39.0868	28.9795	003.0	5.2	0.0	4.0	4.1	0.0	0.0	Kütahya
000030	20221206200729	2022.12.06	20:07:29	40.4225	29.8868	004.9	4.5	0.0	4.3	3.7	0.0	0.0	Bursa
000031	20221205062547	2022.12.05	06:25:47	40.0004	29.5673	006.9	4.2	0.0	4.2	4.3	0.0	0.0	Bursa
000032	20221204031929	2022.12.04	03:19:29	37.7896	35.1234	008.1	4.8	0.0	3.7	3.8	0.0	0.0	Adana
000033	20221201203537	2022.12.01	20:35:37	35.4319	32.5411	006.9	3.2	0.0	4.0	3.8	0.0	0.0	Akdeniz


Deprem şiddetine yönelik olarak kullanılan LSTM ile deprem şiddeti tahmin modelinin $xM \geq 3.0$ veri kümesi ile yaptığı bir haftalık ve iki haftalık deprem tahminleri Şekil 3 ve Şekil 4'te gösterilmektedir. LSTM ile deprem şiddeti tahmin modelinin $xM \geq 3.0$ veri kümesi ile tahmin

sonuçlarına bakıldığında modelin 1 haftalık tahmininde en yüksek 5.7 şiddetinde en düşük 3.5 şiddetinde, 2 haftalık şiddet tahmininde ise en yüksek 5.0 şiddetinde, en düşük 3.7 şiddetinde tahminde bulunduğu görülmektedir. LSTM ile deprem şiddeti tahmin modelinde 1 haftalık zaman

periyotları ve 2 haftalık zaman periyotlarındaki deprem şiddeti tahminleri karşılaştırıldığında, eğitilen modelin 1 haftalık deprem şiddeti tahmininde daha başarılı olduğu görülmektedir.



Şekil 3. LSTM ile DŞTM'nin $x_M \geq 3.0$ veri kümesi ile bir haftalık deprem tahmini



Şekil 4. LSTM ile DŞTM'nin $x_M \geq 3.0$ veri kümesi ile iki haftalık deprem tahmini

3.5. Modellerin performans sonuçlarının karşılaştırılması

Önerilen her iki modelin performans değerleri Çizelge 10'da gösterilmektedir. Oluşturulan modellerin Çizelge 10'da verilen $x_M \geq 3.0$ veri kümesindeki performansına bakıldığında ARIMA modelinin 0.268 R-Kare değeriyle en kötü performansa sahip olduğu görülmektedir. DŞTM, 0.3 R-Kare değeriyle ARIMA modeline göre daha iyi performansa sahip olduğu görülmektedir. LSTM ile deprem şiddeti tahmin modeli ise 0.561 R-Kare değeriyle diğer iki modele göre daha iyi performansa sahip olduğu görülmektedir. Ayrıca ARIMA'nın ortalama mutlak hata değeri 0.312 ile önerilen diğer iki modele göre daha yüksek çıkmıştır.

Çizelge 10. Modellerin $x_M \geq 3.0$ veri kümesindeki performans sonuçlarının karşılaştırılması

Model	R-Kare	MAE	MSE	RMSE
YSA ile DŞTM	0.3	0.220	0.158	0.357
LSTM ile DŞTM	0.561	0.2	0.160	0.373
ARIMA	0.268	0.312	0.173	0.513

Önerilen deprem şiddeti tahmin modelleri, $x_M \geq 3.0$ veri kümesi ile ARIMA modeline göre daha yüksek bir performans göstermektedir. Deprem şiddet tahmin modelinin R-Kare değeri 0.3 ve LSTM ile deprem şiddet tahmin modelinin 0.561 olarak görülmektedir. $x_M \geq 3.0$ veri kümesindeki en iyi performansı LSTM ile deprem şiddeti tahmin modeli göstermektedir.

4. Tartışma ve Sonuç

İnsanoğlunun maruz kaldığı yıkıcı doğal afetlerin başında gelen depremleri, önceden ve kesin olarak tahmin edebilen ve doğruluğu ispatlanan bir yöntem veya çalışma henüz gerçekleşmemiştir. Fakat bu alandaki çalışmalar sensör teknolojilerinin, yapay zeka tahmin modellerinin ve coğrafi bilgi sistemlerinin gelişmesiyle faydalı sonuçlar üretmeye başlamıştır.

Bu çalışmada, meydana gelecek depremin şiddetini tahmin edebilmek için DŞTM (Deprem şiddeti tahmin modeli) ve LSTM ile deprem şiddeti tahmin modeli olmak üzere iki farklı model geliştirilip eğitilmiştir. Önerilen bu tahmin modelleri, depremler arasındaki ilişkiyi analiz etmek için kullanılan, tahmin problemlerinin çözümünde başarılı olduğu bilinen özinelemeli sinir mimarisinin örnekleridir. Çalışmada geçmişte meydana gelen depremlerin oluş zamanı, tarih, derinlik, enlem ve boylam parametreleri kullanılmıştır.

Deprem şiddeti tahmini için oluşturulan deprem veri kümesi $x_M \geq 3.0$ olan depremlerin bilgilerini içermektedir. Veri kümesinin 3.0 şiddeti ile sınırlandırılmasının nedeni ise artçı depremleri inceleme dışında tutmaktır. Artçı depremlerin çalışmaya dahil edilmemesinin nedeni ise deprem tahmininin olumsuz etkilenmesini önlemektir. Bu şekilde artçı depremleri temizleyerek daha doğru deprem tahmini yapılabileceği düşünülmektedir.

Önerilen iki model ve ARIMA modeli hazırlanan veri kümesi ile test edilmiştir. Genel olarak, $x_M \geq 3.0$ veri kümesi ile en kötü sonucu ARIMA modeli vermiştir. DŞTM ise ARIMA modeline göre daha iyi sonuç vermesine rağmen LSTM ile deprem şiddeti tahmin modeline göre genel performansının kötü olduğu görülmüştür. Sonuçlar önerilen deprem şiddeti tahmin modelinin ve LSTM ile deprem şiddeti tahmin modelinin, istatistikî model olan ARIMA modeline göre daha iyi bir performansa sahip olduğunu göstermektedir.

Ayrıca LSTM ile deprem şiddeti tahmin modeli, kendi içerisinde performans bakımından incelendiğinde ise, bir haftalık periyotlarda, iki haftalık periyotlara göre daha iyi deprem şiddeti tahmini performansına sahip olduğu görülmüştür.

Elde edilen sonuçlar, deprem katalog veri kümeleri ile deprem şiddeti tahmini konusunda önerilen derin öğrenme modellerinin, gerçek deprem verileriyle kıyaslandığında kabul edilir bir performansa sahip olduğu görülmektedir. Bu durum da önerilen ve geliştirilen derin öğrenme modellerinin deprem şiddeti tahmininde iyileştirilip, geliştirilebileceğini göstermiştir.

Gelecek çalışmalarda, deprem şiddeti tahminleri için veri seti geliştirilip, artırılabilir ve bu sayede daha kesin deprem şiddeti tahminleri gerçekleştirilebilir. Deprem şiddeti tahmin çalışmalarında farklı girdi parametreleri kullanılarak aynı modeller için performans değerlendirmesi yapılabilir. Gizli katman sayısı artırılıp model daha iyi eğitilip, hafızasında daha uzun süre tutması sağlanarak modellerin performansı artırılabilir. Böylece bu alandaki deprem şiddeti tahmin çalışmaları artırılarak, önlenmesi imkansız olan bu afet için erken korunma önlemlerinin alınması sağlanabilir.

Etik Standartlar Bildirgesi

Bu çalışma Doç. Dr. Durmuş ÖZDEMİR danışmanlığında Rabia UYAR tarafından 25.01.2023 tarihinde tamamlanan “Derin öğrenme yöntemleriyle deprem şiddeti tahmini” başlıklı ve 790460 tez no’lu yüksek lisans tezinden türetilmiştir.

Yazarlar tüm etik standartlara uyduklarını beyan ederler.

Yazarlık Katkı Beyanı

Yazar 1: Kaynaklar, Araştırma, Deney, Yazma – orijinal taslak
Görselleştirme, Yazma – orijinal taslak, Analiz ve yorumlama
Yazar 2: Doğrulama, Biçimsel analiz, Metodoloji, Görselleştirme, Denetleme/danışmanlık

Çıkar Çatışması Beyanı

Yazarların bu makalenin içeriğiyle ilgili olarak beyan edecekleri hiçbir çıkar çatışması yoktur.

Verilerin Kullanılabilirliği

Bu çalışma sırasında oluşturulan veya analiz edilen tüm veriler, yayınlanan bu makaleye dahil edilmiştir.

5. Kaynaklar

- Abri, R. and Artuner, H., 2022. LSTM-based deep learning methods for prediction of earthquakes using ionospheric data. *Gazi University Journal of Science*, **35**, 1417-1431.
<https://doi.org/10.35378/gujs.950387>
- Akyüz, H.E., 2019. Farklı İstatistiksel Dağılımlar ile Deprem Verilerinin Modellenmesi ve Performans Karşılaştırması. *Academic Platform Journal of Engineering and Science*, **7**, 7–13.
<https://doi.org/10.21541/apjes.401652>
- Altan, A. and Karasu, S., 2020. Ayrıştırma Yöntemlerinin Derin Öğrenme Algoritması ile Tanımlanan Rüzgâr Hızı Tahmin Modeli Başarımına Etkisinin İncelenmesi. *European Journal of Science and Technology*, **20**, 844-853.
<https://doi.org/10.31590/ejosat.785699>

- Bayrak, E., Ozer, C., Cakici, H. and Kocadagistan, M. E., 2021. January 24, 2020 Sivrice (Turkey) Earthquake (Mw 6.8): Evaluation of Ground-Motion Prediction Equations and Microtremor Studies. *Türk Deprem Araştırma Dergisi*, **3**, 125–148.
<https://doi.org/10.46464/tdad.1003057>
- Crespi, M., Kossobokov, V., Peresan, A. and Panza, G. F., 2022. The integration between seismology and geodesy for intermediate-term narrow-range earthquake prediction according to NDSHA. *Earthquakes and Sustainable Infrastructure: Neodeterministic (NDSHA) Approach Guarantees Prevention Rather than Cure*, 97–112.
<https://doi.org/10.1016/B978-0-12-823503-4.00003-8>
- DeVries, P. M. R., Viégas, F., Wattenberg, M. and Meade, B. J., 2018. Deep learning of aftershock patterns following large earthquakes. *Nature*, **560**, 632–634.
<https://doi.org/10.1038/s41586-018-0438-y>
- Doğan, A., 2021. Yapısal Tekrarlayan Sinir Ağları İle Zaman-Mekansal Deprem Tahmini, Yüksek Lisans Tezi, Hacettepe Üniversitesi Fen Bilimleri Enstitüsü, Ankara.
- Duman, O., 2016. Batı Anadolu Bölgesindeki Depremlerin Yapay Sinir Ağı Yöntemiyle Tahmini, Yüksek Lisans Tezi, Gümüşhane Üniversitesi Sosyal Bilimler Enstitüsü, Gümüşhane, 142.
- Emeksiz, C. and Tan, M., 2021. Geliştirilmiş EEMD-EWT Tabanlı Yapay Sinir Ağı Modeli Kullanarak Çok Adımlı Rüzgar Hızı Tahmini. *European Journal of Science and Technology*, **26**, 165–173.
<https://doi.org/10.31590/ejosat.948661>
- Fidanboy, M., Adar, N. and Okyay, S., 2022. Derin öğrenmeye dayalı orman yangını tahmin modeli geliştirilmesi ve Türkiye yangın risk haritasının oluşturulması. *Ormanlık Araştırma Dergisi*, **2**, 206–218.
<https://doi.org/10.17568/ogmoad>
- Guo, L., He, Z. and Li, L., 2022a. Lacustrine sedimentary responses to earthquakes—soft-sediment deformation structures since late Pleistocene: A review of current understanding. *Earthquake Research Advances*, **3**, 100158.
<https://doi.org/10.1016/j.eqrea.2022.100158>
- Jena, R., Pradhan, B., Al-amri, A., Lee, C. W. and Park, H. J., 2020. Earthquake probability assessment for the indian subcontinent using deep learning. *Sensors*, **20**, 1–24.
<https://doi.org/10.3390/s20164369>
- Jena, R., Pradhan, B., Almazroui, M., Assiri, M. and Park, H. J., 2023. Earthquake-induced liquefaction hazard mapping at national-scale in Australia using deep learning techniques. *Geoscience Frontiers*, **14**, 101460.
<https://doi.org/10.1016/j.gsf.2022.101460>

- Jiao, Z. H. and Shan, X., 2022. Consecutive statistical evaluation framework for earthquake forecasting: Evaluating satellite surface temperature anomaly detection methods. *Journal of Asian Earth Sciences: X*, **7**, 100096.
<https://doi.org/10.1016/j.jaesx.2022.100096>
- Joshi, A., Vishnu, C. and Mohan, C. K., 2022. Early detection of earthquake magnitude based on stacked ensemble model. *Journal of Asian Earth Sciences: X*, **8**, 100122.
<https://doi.org/10.1016/j.jaesx.2022.100122>
- Karacı, M., 2022. Derin Öğrenme Yöntemlerinin Kullanarak Deprem Tahmini. *Artificial Intelligence Studies*, **5**, 23-34.
<https://doi.org/10.30855/ais.2022.05.01.03>
- Khosravikia F. and Clayton P., 2021. Machine learning in ground motion prediction. *Computers & Geosciences*, **148**, 104700.
<https://doi.org/10.1016/j.cageo.2021.104700>
- Kuang, W., Yuan, C. and Zhang, J., 2021. Real-time determination of earthquake focal mechanism via deep learning. *Nature Communications*, **12**, 1-8.
<https://doi.org/10.1038/s41467-021-21670-x>
- Kuyuk, H. S. and Susumu, O., 2018. Real-time classification of earthquake using deep learning. *Procedia Computer Science*, **140**, 298-305.
<https://doi.org/10.1016/j.procs.2018.10.316>
- Laurenti, L., Tinti, E., Galasso, F., Franco, L. and Marone, C., 2022. Deep learning for laboratory earthquake prediction and autoregressive forecasting of fault zone stress. *Earth and Planetary Science Letters*, **598**, 1-14.
<https://doi.org/10.1016/j.epsl.2022.117825>
- Li, R., Lu, X., Li, S., Yang, H., Qiu, J., and Zhang, L., 2020. DLEP: A Deep Learning Model for Earthquake Prediction. 2020 International Joint Conference on Neural Networks (IJCNN). 1-8.
<https://doi.org/10.1109/IJCNN48605.2020.9207621>
- Nicolis O., Plaza F. and Salas R., 2021. Prediction of intensity and location of seismic events using deep learning. *Spatial Statistics*, **42**, 100442.
<https://doi.org/10.1016/j.spasta.2020.100442>
- Özger, Y., 2020. Sultan II. Abdülhamid Döneminde İstanbul da Deprem Tahmini Tartışmaları ve Josef Nowack ın Padişaha Gönderdiği Rapor. *History Studies International Journal of History*, **12**, 227-253.
<https://doi.org/10.9737/hist.2020.828>
- Özmen, B., 2011. Kastamonu ve Yakın Çevresi İçin Deprem Olasılığı Tahminleri. *Türkiye Jeoloji Bülteni*, **54**, 109-122.
- Öztürk, S. and Alkan, H., 2022. Van Gölü ve Civarı (Türkiye) İçin Deprem Tahmini ve Tehlikesi Üzerine İstatistiksel Bir Analiz ve Değerlendirme. *Türk Deprem Araştırma Dergisi*, **4**, 191-209.
<https://doi.org/10.46464/tdad.1108730>
- Pura T., Güneş P., Güneş A. and Hameed AA., 2023. Earthquake Prediction for the Düzce Province in the Marmara Region Using Artificial Intelligence. *Applied Sciences*, **13**, 8642.
<https://doi.org/10.3390/app13158642>
- Ren, T., Liu, X., Chen, H., Dimirovski, G. M., Meng, F., Wang, P., Zhida, Z and Ma, Y., 2023. Seismic severity estimation using convolutional neural network for earthquake early warning. *Geophysical Journal International*, **234**, 1355-1362.
<https://doi.org/10.1093/gji/ggad137>
- Sabah, L. and Bayraktar, H., 2020. Düzce Merkez ve İlçelerinin Deprem Senaryolarına Göre Karşılaştırmalı Olarak İncelenmesi. *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, **8**, 1695- 1705.
<https://doi.org/10.29130/dubited.574013>
- Sebatlı Sağlam, A. and Cavdur, F., 2022. Earthquake intensity estimation via an artificial neural network: Examination of different network designs and training algorithms. *Journal of the Faculty of Engineering Architecture of Gazi University*, **37**, 2133-2145.
<https://doi.org/10.17341/gazimmfd.791337>
- Senkaya M., Silahtar A., Erkan EF. and Karaaslan H., 2024. Prediction of local site influence on seismic vulnerability using machine learning: A study of the 6 February 2023 Türkiye earthquakes. *Engineering Geology*, **337**, 107605.
<https://doi.org/10.1016/j.enggeo.2024.107605>
- Sevinç, A. and Kaya, B., 2021. Derin Öğrenme ve İstatistiksel Modelleme Yöntemiyle Sıcaklık Tahmini ve Karşılaştırılması. *European Journal of Science and Technology*, **28**, 1222 – 1228.
<https://doi.org/10.31590/ejosat.1014106>
- Sevinç, A. and Kaya, B., (2021). *Derin Öğrenme Yöntemleri ile Sıcaklık Tahmini: Diyarbakır İli Örneği*. IDAP-2021: 5th International Artificial Intelligence and Data Processing symposium, 217-225.
<https://doi.org/10.53070/bbd.990966>
- Song, J., Zhu, J., Wei, Y., Li, S. and Li, S., 2022. Real-time prediction of earthquake potential damage: A case study for the January 8, 2022 MS 6.9 Menyuan earthquake in Qinghai, China. *Earthquake Research Advances*, **3**, 100197.
<https://doi.org/10.1016/j.eqrea.2022.100197>
- Sumy, D. F., Jenkins, M. R., McBride, S. K. and de Groot, R. M., 2022. Typology development of earthquake displays in free-choice learning environments, to inform earthquake early warning education in the United States. *International Journal of Disaster Risk Reduction*, **73**, 1-31.
<https://doi.org/10.1016/j.ijdr.2022.102802>

- Tan, A., Horasan, G., Kalafat, D. and Gülbağ, A., 2021. Discrimination of earthquakes and quarries in Kula District (Manisa, Turkey) and its vicinity by using linear discriminate function method and artificial neural networks. *Bulletin of the Mineral Research and Exploration*, **164**, 75–92.
<https://doi.org/10.19111/bulletinofmre.757701>
- Topçu, O., Kara, T., Bulut, A. A., Salgın, Ö., and Bakıcı, S. (2017). *Küresel Seyrüsefer Uydu Sistemi (Gnss) Verileri İle Deprem Tahmini Yapmak*. 4. Uluslararası Deprem Mühendisliği ve Sismoloji Konferansı. Eskişehir, Türkiye.
- Turgut, A., Temir, A., Aksoy, B. and Özsoy, K., 2019. Yapay Zekâ Yöntemleri İle Hava Sıcaklığı Tahmini İçin Sistem Tasarımı Ve Uygulaması. *In International Journal Of 3d Printing Technologies And Digital Industry*, **3**, 244-253.
- Utku, A. and Akcayol, M. A., 2020. Derin Öğrenme Tabanlı Model ile Bir Olayın Sonraki Olma Zamanının Tahmini. *Journal of Polytechnic*, **24**, 1-15.
<https://doi.org/10.2339/politeknik.620613>
- Wang, Q., Guo, Y., Yu, L. and Li, P., 2020. Earthquake Prediction Based on Spatio-Temporal Data Mining: An LSTM Network Approach. *IEEE Transactions on Emerging Topics in Computing*, **8**, 148–158.
<https://doi.org/10.1109/TETC.2017.2699169>
- Wang Y., Li X., Wang Z. and Liu J., 2023. Deep learning for magnitude prediction in earthquake early warning, *Gondwana Research*, **123**, 164-173.
<https://doi.org/10.1016/j.gr.2022.06.009>
- Wu, Z., 2022. Evaluation of numerical earthquake forecasting models. *Earthquake Science*, **35**, 293–296.
<https://doi.org/10.1016/j.eqs.2022.08.006>