



Derin Öğrenme Yöntemleri Kullanılarak Deprem Tahmini Gerçekleştirilmesi

Metin KARCI^{a,*}, İsmail ŞAHİN^b

^{a,*} Gazi Üniversitesi Bilişim Enstitüsü, Bilişim Sistemleri Ana Bilim Dalı, Ankara 06560, TÜRKİYE

^b Gazi Üniversitesi, Teknoloji Fakültesi, Endüstriyel Tasarım Mühendisliği Bölümü, Ankara 06560, TÜRKİYE

MAKALE BİLGİSİ

Alınma: 26.01.2022
Kabul: 21.03.2022

Anahtar Kelimeler:

Derin Öğrenme
Deprem Tahmini
Yapay Zekâ
Uzun – Kısa Süreli
Bellek-LSTM

*Sorumlu Yazar:

e-posta:
metin@gazi.edu.tr

ÖZET

Büyük depremlerin tahmini önemli ve zor bir konudur. Deprem tahmininin amacı, depremleri önceden belirleyerek ölüm oranını ve yıkımları azaltmak için gereken önlemleri almaktır. Deprem tahmininde bulunabilmek için depremlerin çok iyi incelenmesi ve analizi edilmesi gerekir. Depremleri kesin olarak tahmin edebilen geliştirilmiş bir çalışma henüz gerçekleştirilememiştir. Ancak araştırmacılar önceden meydana gelmiş deprem kayıtlarını inceleyerek bazı deprem kalıpları oluşturmak için çalışmalar yapmaktadır. Gerçekleşecek depremleri önceden tahmin edebilmek için çok farklı çalışmalar yapılmaktadır. Bu çalışmalar genel olarak istatistiksel yöntemler ve son zamanlarda ise yapay zekâ ve derin öğrenme üzerine yoğunlaşmıştır. Daha başarılı tahminlerde bulunmak için yapay zekâ çalışma alanlarından olan derin öğrenme yöntemleri kullanılmaktadır. Derin öğrenme mimarilerinden özyinelemeli sinir ağları (Recurrent Neural Network) tahmin ve sınıflandırma gibi problemlerin çözümünde başarı oranı yüksek olduğu için tercih edilmektedir. Bu çalışmada Türkiye’de gerçekleşen depremlerin katalog verilerinden tarih, enlem, boylam, depremin derinliği gibi bilgileri kullanılarak gerçekleşecek olası depremin büyüklüğünün tahmin edilmesine yönelik bir model önerilmiştir. Bununla birlikte, meydana gelecek depremin büyüklüğünü ve zaman tahminini yapabilmek için bir özyinelemeli sinir ağı türü olan Uzun – Kısa Süreli Bellek (Long – Short Term Memory) modeli kullanılmıştır. Model, deprem veri setindeki zaman serileri ile eğitilmiş ve tahmin işlemi yapılmıştır.

Önerilen modelin deprem tahmin sonuçları ile en sık kullanılan makine öğrenmesi algoritmaları olan Çoklu Doğrusal Regresyon (Multiple Linear Regression), Polinomal Regresyon (Polynomial Regression), Karar Ağaçları (Decision Trees), Rastgele Orman (Random Forest Regression) sonuçları karşılaştırılmıştır. Sonuç olarak önerilen modelin deprem tahmin sonuçlarının daha başarılı olduğu gözlemlenmiştir.

DOI: 10.30855/AIS.2022.05.01.03

Earthquake Prediction By Using Deep Learning Methods

ARTICLE INFO

Received: 26.01.2022
Accepted: 21.03.2022

Keywords:

Deep Learning
Earthquake
Prediction,
Artificial
Intelligence, LSTM

*Corresponding Authors

ABSTRACT

The exact prediction of major earthquakes is one of the important issues. The purpose of the forecast is to take the necessary measures to reduce deaths and destruction by knowing about earthquakes in advance. The study and analysis of earthquakes is very important for earthquake prediction. A study that can accurately predict earthquakes has not yet taken place. However, researchers are working to create some earthquake patterns by studying the records of previous earthquakes. Various studies are carried out to predict future earthquakes. These studies have focused on statistical methods in general, and more recently on artificial intelligence and deep learning. Deep learning methods, one of the fields of artificial intelligence, are used to make realistic predictions. Recurrent Neural Network (RNN), one of the deep learning architectures, is preferred because of its high success rate in solving problems such as prediction and classification. In this study, a model has been proposed for estimating the magnitude of a possible earthquake by using information such as date, latitude, longitude and depth of the earthquake from earthquake data in Turkey. In addition, the Long-Short Term Memory (LSTM) model, which is a type of

e-mail:
metin@gazi.edu.tr

RNN, is used to predict the time together with the magnitude of the earthquake that will occur. The proposed model has been trained with the time series in the prepared earthquake data set and estimation has been made.

The earthquake prediction results of the proposed model and the most commonly used machine learning algorithms, Multiple Linear Regression (MLR), Polynomial Regression (PR), Decision Trees (DT), Random Forest Regression (RF)) results were compared. As a result, it has been observed that the earthquake prediction results of the proposed model are more successful.

DOI: 10.30855/AIS.2022.05.01.03

1. GİRİŞ (INTRODUCTION)

Deprem, insanların hareketsiz olarak kabul ettiği ve güvenle ayağını bastığı yerkürenin hareket edebileceği ve taşıdığı tüm yapılara hasar vererek, can kayıplarına sebep olacak şekilde yıkılabileceklerini gösteren bir doğa olayıdır. Türkiye dünyanın en etkin deprem kuşaklarından birinin üzerinde bulunmaktadır. Tarihte Türkiye’de birçok yıkıcı depremler olduğu gibi, gelecekte de meydana gelecek depremlerle büyük can ve mal kayıplarını meydana getireceği düşünülmektedir [1].

Depremler günümüzde daha sık meydana gelmektedir. Depremlerin oluşturacağı hasarların ve can kayıplarının en aza indirilmesini sağlamak için meydana gelen depremlerin yerlerinin ve büyüklüklerinin doğru olarak tahmin edilme çalışmaları araştırmacılar tarafından yapılmaktadır. Ancak depremlerin zamanın, yerinin ve büyüklüğünün doğru bir şekilde tahmin edilmesi zordur [2]. Deprem tahmininde birçok araştırmacı tarafından çeşitli matematiksel hesaplamalar ve istatistiksel teknikler kullanılmıştır.

Depremlerinin incelenmesi ve analizi deprem tahmini için çok önemlidir [3]. Akıllı hesaplama yöntemleri kullanılarak tahmin çalışmalarının sayısı giderek artmaktadır [4]. Bu yöntemler, farklı zamanlarda ve yerlerde meydana gelen depremler arasındaki ilişkileri çıkarmak için kullanılır. Derin öğrenme zorlu problemleri çözmek için kullanılan en güçlü tekniklerden biridir. Derin öğrenme de dâhil olmak üzere genel olarak makine öğreniminin popüler hale gelmesi ve deprem tahmini için yeni bir umut vermesi şartıcı değildir [5].

Yapay Sinir Ağlarının (YSA) deprem tahmini çalışmalarında ilk olarak 1994 yılında Aminzadeh, Katz, & Aki [6] tarafından ve Lakkos, Hadjiprocopis, Comley, & Smith [7] tarafından uygulandığı bilinmektedir [8]. 2001 yılında ise Bodri [9] bu alanda çalışmalar yapmıştır.

İlk derin sinir ağı 2002’de Negarestani, Setayeshi, Ghannadi-Maragheh, & Akashe [10], ilk özyinelemeli sinir ağı 2007’de Panakkat & Adeli [11] tarafından önerilmiştir. Deprem tahminindeki YSA uygulamaları üzerine ilk kapsamlı çalışma Panakkat & Adeli tarafından yapılmıştır.

Deprem tahmini çalışmalarına bakıldığında YSA tabanlı modellerin yerini derin öğrenmeye mimarilerinin aldığı gözlemlenmektedir. YSA’ bakıldığına ise , 2020 de Wang, Guo, Yu, & Li [12] tarafından kullanılan LSTM ağları ve 2018 yılında Huang, Wang, Zhao, Xin, & Xiang [13] tarafından kullanılan evrişimsel sinir ağları ile daha karmaşık mimarilere doğru bir eğilim görülmektedir [8].

2. DERİN ÖĞRENME (DEEP LEARNING)

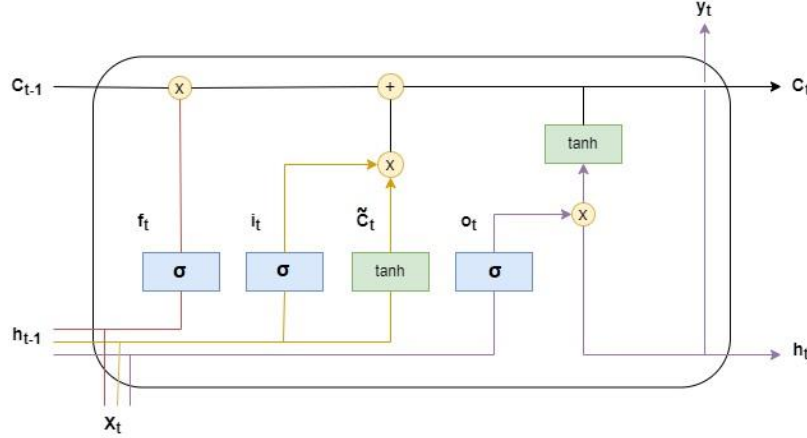
Derin öğrenme, dijital sistemlerin yapılandırılmamış, etiketlenmemiş verilere dayalı olarak öğrenmesini ve kararlar almasını sağlamak üzere yapay sinir ağlarını kullanan bir makine öğrenmesi türüdür. Genellikle makine öğrenmesi, yapay zekâ sistemlerini veri ile alınan deneyimleri inceleyerek öğrenecek, desenleri tanıyacak, öneriler sunacak ve uyum sağlayacak biçimde eğitir. Özellikle derin öğrenme söz konusu olduğunda dijital sistemler, yalnızca kural kümelerine yanıt vermek yerine, örneklerden faydalanarak bilgi edinir ve ardından bu bilgileri kullanarak insanlar gibi tepki verir, davranış gösterir ve performans sergiler [14].

Yapay sinir ağı, karmaşık desenleri modellemek, tahminler geliştirmek ve dış etmenlere uygun şekilde tepki vermek için insanın bilişsel sürecini taklit eden dijital bir mimaridir. Birçok makine öğrenmesi türü için yapılandırılmış veri gerekir, ancak sinir ağları çevrelerindeki dünyada gerçekleşen olayları işleyebilecekleri verilere dönüştürüp yorumlayabilir [15].

2.1. Uzun – Kısa Süreli Bellek Ağları (Long – Short Time Memory)

Uzun-Kısa Süreli Bellekler (UKSB) derin öğrenme alanında kullanılan uzun vadeli bağımlılık problemini çözmek için tasarlanan özel bir özyinelemeli sinir ağı mimarisidir [16]. UKSB ağları, zaman serisi verilerine dayanarak sınıflandırmak, işlemek ve tahminler yapmak için çok uygundur.

Sıradan bir UKSB ünitesi, bir giriş kapısı, bir çıkış kapısı ve bir unut kapısından oluşur. Hücre, değişken uzunlukta zaman aralıklarındaki değerleri hatırlar ve bu üç kapı, hücreye giren ve çıkan bilgi akışını düzenler.



Şekil 1. UKSB'nin temel birim yapısı (The basic unit structure of LSTM.)

Şekil 1'deki turuncu çizgiler giriş kapısını temsil etmektedir. Giriş kapısının ana işlevi, t anında tüm bilgilerin giriş sürecini kontrol etmektir. Uygulama süreci aşağıdaki gibi ifade edilebilir [17]:

$$i_t = (W_i h_{t-1} + U_i x_t + b_i), \quad (1)$$

$$\tilde{C}_t = \tan h(W_c h_{t-1} + U_i x_t + b_c), \quad (2)$$

Burada W_i , W_c , U_i ve U_c , giriş kapılarının ağırlıklarıdır b_i ve b_c , giriş kapılarının sapmalarıdır. $\tan h$ aktivasyon fonksiyonudur ve formülleri aşağıdaki gibidir:

$$\tan h(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}, \quad (3)$$

$$\sigma(x) = \frac{1}{1 + e^{-x}}, \quad (4)$$

Şekil 1'deki kırmızı çizgiler unut kapısını temsil eder. Unut kapısının girişi, birimin x_t girişini ve h_{t-1} çıkışını içerir. Çıktı süreci formül 5'te gösterilmiştir.

$$f_t = \sigma(W_f h_{t-1} + U_f x_t + b_f), \quad (5)$$

Burada W_f ve U_f , unut kapısının ağırlığıdır ve b_f , unut kapısının sapmasını temsil eder.

Unut kapısının ve giriş kapısının çıkış bilgisi sırasıyla çarpılır ve mevcut birim çıkış durumunu elde etmek için toplanır. Hesaplama süreci aşağıdaki gibidir:

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t, \quad (6)$$

Bu formülden, C_t 'nin o andaki tüm bilgilerin uzun süreli belleğini temsil ettiği görülebilir.

Şekil 1'deki mor çizgiler çıkış kapısını temsil etmektedir. Şekil 1'deki mor çizgiler çıkış kapısını temsil etmektedir. Çıkış kapısı, mevcut anda hücre çıkış durumu C_t ile ilgili olan tüm temel hücrenin çıkış sonucunu belirler. İlk olarak, çıkış kapısının O_t çıkışını elde etmek için giriş birimi bilgisinin bir kısmını işlemek için sigmoid fonksiyonu kullanılır ve ardından C_t 'deki bilgileri işlemek için tan h fonksiyonu kullanılır. İşlenmiş iki bilgi kümesi çarpıldıktan sonra, nihai çıktı h_t elde edilir. Hesaplama formülü aşağıdaki gibidir:

$$O_t = \sigma(W_0 h_{t-1} + U_0 x_t + b_0), \quad (7)$$

$$h_t = O_t^* \tan h(C_t) \quad (8)$$

3. VERİ KÜMESİNİN HAZIRLANMASI (DATA SET CONSTRUCTION)

Çalışmada kullanılan deprem verileri Boğaziçi Üniversitesi Kandilli Rasathanesi ve Deprem Araştırma Enstitüsü Bölgesel Deprem-Tsunami İzleme ve Değerlendirme Merkezi BDTİM Deprem Sorgulama Sisteminden alınmıştır [18]. Sistemden 1 Ocak 1970 – 26 Aralık 2021 tarihleri arasında meydana gelen 3.5 ve üzeri büyüklükteki depremler sorgulanmış ve 15879 deprem verisi listelenmiştir. Arama sonrası listelenen depremler txt uzantılı dosyalara kaydedilmektedir.

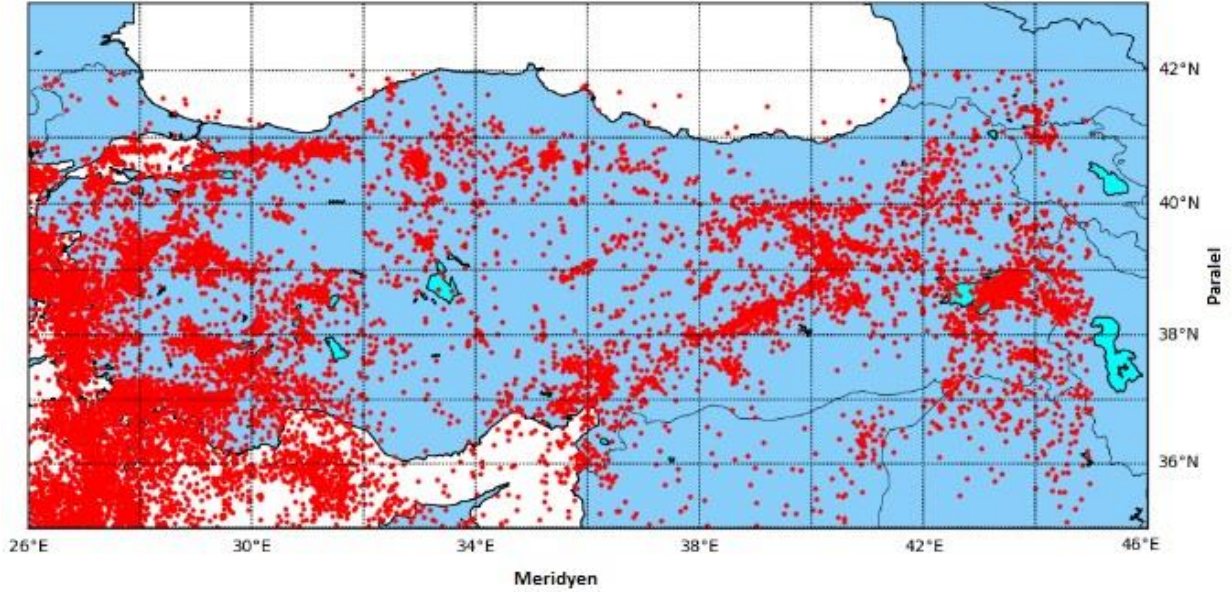
Alınan deprem kataloğu verileri ilk olarak xlsx formatına dönüştürüldü. Deprem kataloğu verileri arasından deprem tahmin modelinde kullanılacak olan depremin Oluş tarihi, Oluş zamanı, Enlem, Boylam, Der(km), xM bilgileri haricindeki bilgiler temizlendi. Depremin oluş tarihi verilerinde tarih formatında değişiklik yapıldı. Son olarak veriler csv formatına dönüştürüldü.

Bu çalışmada kullanılan deprem veri seti tarih, saat, enlem, boylam, derinlik ve büyüklük verilerinden oluşmaktadır. Verilen tarih ve zaman bilgileri, zaman damgasına çevrilerek bir girdi olarak kullanılabilir.

Tablo 1. Düzenlenmiş deprem verileri (Edited earthquake data)

Tarih	Zaman	Enlem	Boylam	Derinlik	xM	Zaman Damgası
07.06.2021	16:00:18.62	36.3925	27.0435	008.9	4.3	1625576418.0
05.06.2021	13:49:49.72	38.0907	27.0413	007.9	3.6	1620298189.0
04.06.2021	20:23:08.39	36.4368	27.0998	007.8	4.2	1617729788.0
03.06.2021	04:26:44.18	37.3318	35.0288	005.6	3.9	1614994004.0
02.06.2021	06:14:27.97	37.5585	36.1435	005.8	4.3	1612581267.0

Veriler deprem tahmin modelini oluşturmadan önce, meydana gelen depremlerin daha çok nerelerde olduğunu gösteren bir Türkiye haritası üzerinde görselleştirilmiştir.



Şekil 2. 1970 -2021 yılları Türkiye'deki deprem dağılımı (*Earthquake distribution in Turkey between 1970 -2021*)

4. ÖNERİLEN DERİN ÖĞRENME MODELLERİ (*SUGGESTED DEEP LEARNING MODEL*)

Bu çalışmada deprem tahmini konusunda iki farklı model önerilmiştir. Deprem büyüklüğü tahmin modeli Python için bir derin öğrenme kütüphanesi olan keras kullanılarak hazırlanmıştır. Belirlenen bir zaman dilimi içinde meydana gelecek depremleri tahmin edebilmek için ise uzun kısa süreli bellek kullanılarak bir model oluşturulmuştur.

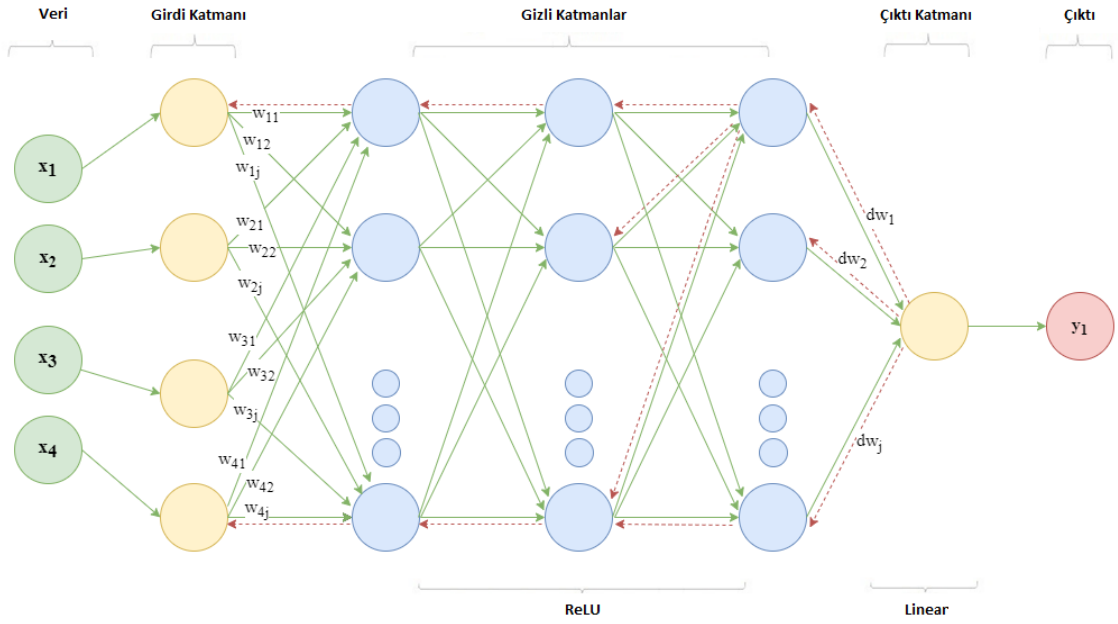
4.1. Deprem büyüklüğü tahmin modeli (DBTM) (*Earthquake magnitude prediction model*)

Deprem büyüklüğü tahmin modelinin geliştirilmesi için Python programlama dili kullanılmıştır. Tensorflow, derin öğrenme modelleri geliştirmek ve değerlendirmek için en güvenilir ve kullanımı kolay açık kaynaklı Python kitaplıklarından biridir. Keras, Python için farklı türden derin öğrenme modellerinin tanımlanmasına ve eğitilmesine olanak sağlayan derin öğrenme kütüphanelerinden biridir. Birçok derin öğrenme uygulamalarında, özellikle tahmin sistemleri için Keras kütüphanesi kullanılmaktadır.

Keras kütüphanesi kullanılarak tasarlanan bu model;

- 4 girişli bir girdi katman
- 3 gizli katman
- 1 çıkışlı bir çıktı katman

kullanılarak oluşturulmuştur..



Şekil 3. Deprem büyüklüğü tahmini için önerilen model (*The proposed model for earthquake prediction*)

Deprem tahmin modelini oluşturmak ve modelden çıktı almak için modele girdi olarak girilecek olan verilerin sırasıyla Girdi (Xs) ve Çıktı(Ys) olarak bölünmesi gerekmektedir. Burada girdiler Zaman Damgası, Enlem, Boylam ve Derinlik verileridir. Çıktı olarak Büyüklük bilgisi alınmaktadır.

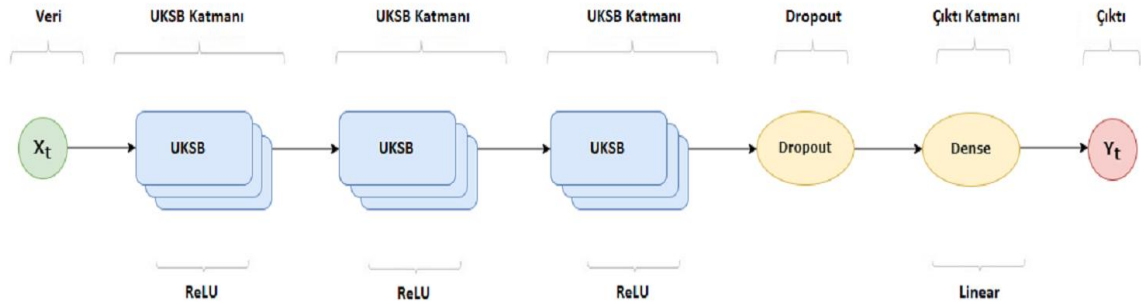
Keras kütüphanesinin bize sunduğu Sequential fonksiyonu ile model oluşturulur. Ardından oluşturulan modele yeni katmanlar eklenip bu katmanların düğüm sayıları ve aktivasyon fonksiyonlarını belirlenmektedir. Aktivasyon fonksiyonları olarak Relu ve Linear kullanılmaktadır. Adam optimizasyon fonksiyonu ve Kayıp fonksiyonu olarak mean squared error kullanılmaktadır. En uygun olanı bulmak için hiperparametreler iki veya daha fazla seçenekle tanımlanmıştır.

Oluşturulan model burada 10 örneklilik batchler halinde Adam optimizasyon fonksiyonunu çalıştırmaktadır. Tüm veri seti 100 kez yenilenir. X_train'de 15879 tane örnek bulunmaktadır. Algoritma X'in %80'ini kullanarak modeli eğitecek, kalan yüzde 20 ile test edecek ve hatalarını düzeltmektedir. Tüm çalışmalar Intel(R) Xeon(R) W-2145 CPU @ 3.70GHz 3.70 GHz işlemci 4 GB GPU RAM ve 32 GB RAM bulunan bir bilgisayarda gerçekleştirilmiştir.

4.2. UKSB ile Zaman ve Deprem Büyüklüğü Tahmin Modeli (*Time and Earthquake Magnitude Prediction Model with LSTM*)

Oluşturulan LSTM modeli;

- İlk katmanda 64 UKSB hücresi
- İkinci katmanda 32 UKSB hücresi
- Üçüncü katmanda 32 UKSB hücresi
- Dropout katmanı
- Çıktı katmanı



Şekil 4. UKSB ile zaman ve deprem büyüklüğü tahmin modeli (*Time and earthquake number prediction model with LSTM*)

kullanılarak tasarlanmıştır. UKSB ile zaman ve deprem büyüklüğü tahmin modelinde, aktivasyon fonksiyonu olarak ReLU kullanılmaktadır. Optimizasyon fonksiyonu olarak Adam, kayıp fonksiyonu olarak mean squared error belirlenmiştir. Modelde dropout oranı 0.2 olarak alınmıştır. Giriş veri kümesinin normalleştirilme işlemi scikit-learn kitaplığındaki StandardScaler ön işleme sınıfını kullanarak yapılmıştır. UKSB ağları için gerekli olan girdi verileri yeniden şekillendirilir. Zaman serisi verileriyle, değerlerin sırası önemlidir. Bu nedenle veri kümesi sıralandıktan sonra eğitim ve test veri kümelerine bölünmektedir.

Bu modelde eğitim için kullanılan veri kümesi 14 günlük periyodlar halinde alınmaktadır. İlk 14 günlük deprem verileri alınarak 15. günün daha sonra ikinci 14 güne bakılarak 16. günün deprem tahmini yapılarak, 14 günlük periyodlar halinde, eğitim kümesiyle model eğitilmektedir. Modelde gelecek günlerdeki depremleri tahmin etmek için gerekli değişkenler tanımlanır. Gelecekteki depremleri tahmin etmek için kullanılmak istenilen geçmiş günlerin sayısı ve geçmiş günlere bağlı olarak geleceğe bakmak istenilen gün sayısı belirlenmektedir. Performansın orijinal verilerle aynı birimlerde rapor edilmesini sağlamak için hata puanlarını hesaplamadan önce tahminlere ters dönüşüm uygulanmaktadır. Son olarak, modelin performansını elde etmek için hem eğitim hem de test veri kümesi kullanılarak tahminler yapılmaktadır.

3. SONUÇ ve TARTIŞMA (*RESULTS and DISCUSSIONS*)

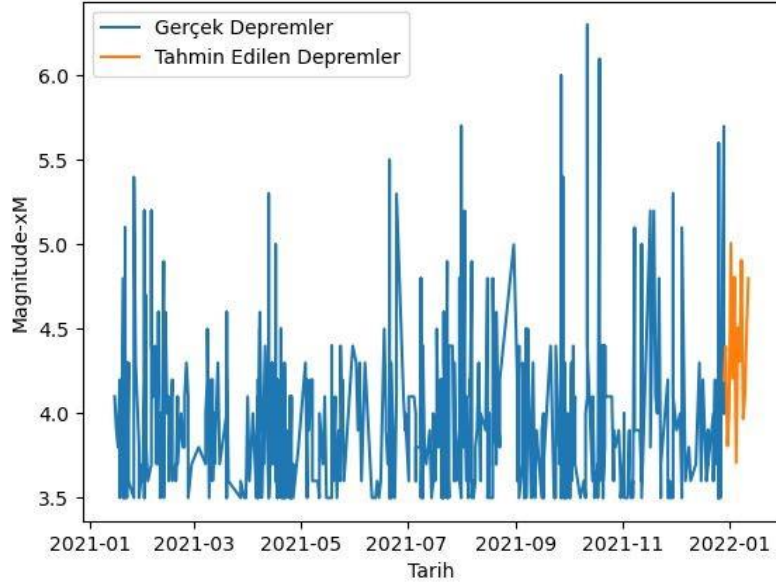
Bu Çalışma, Türkiye’de 1970 – 2021 yılları arasında meydana gelen depremlerin tarihsel verileri esas alınarak bir deprem tahmini yapmak üzerine gerçekleştirilmiştir. Ayrıca deprem verileri (tarih, zaman, enlem, boylam, büyüklük, derinlik) ile deprem zamanı arasındaki ilişkiyi UKSB sinir ağları yaklaşımı kullanarak incelemek ve zaman ve büyüklük tahmini yapmak konusu ele alınmıştır.

Meydana gelen bazı depremlerin tarih, enlem, boylam, derinlik bilgileri ile model test edildiğinde, önerilen derin öğrenme modelinin gerçekleşen büyüklüklere oldukça yakın sonuçlar verdiği görülmüştür.


Tablo 2. Meydana gelen bazı depremlerin gerçek büyüklükleri ve önerilen modelin tahmin sonuçlarının karşılaştırılması (*Comparison of the actual magnitudes of some earthquakes and the prediction results of the proposed model*)

Tarih	Enlem	Boylam	Der(km)	Yer	xM	DBTM
27.12.2020	38.5050	39.2180	002.9	Kavaktepe-(Elazığ)	5.6	4.49
30.10.2020	37.8877	26.7057	011.2	Ege Denizi-(İzmir)	6.9	5.63
04.08.2020	38.1945	38.7270	005.5	Alihan-Pütürge (Malatya)	5.7	4.51
24.10.2020	38.3922	39.0847	005.0	Kalaba-Sivrice (Elazığ)	6.7	5.27

Deprem zamanı ve büyüklüğüne yönelik olarak kullanılan UKSB ile zaman ve deprem büyüklüğü tahmin modelinin veri kümesi ile yaptığı 15 günlük ve 30 günlük depremin tahminleri Şekil 5. ve Şekil 6.'da gösterilmektedir.



Şekil 5. UKSB ile zaman ve deprem büyüklüğü tahmin modelinin 15 günlük deprem tahmini (15-day earthquake prediction of time and earthquake prediction model with UKSB)



Şekil 6. UKSB ile zaman ve deprem büyüklüğü tahmin modelinin 30 günlük deprem tahmini (30-day earthquake prediction of time and earthquake prediction model with UKSB)

UKSB ile zaman ve deprem büyüklüğü tahmin modelinin tahmin sonuçlarına baktığımız zaman 15 günlük tahminde en yüksek 5.0 büyüklüğünde en düşük 3.7 büyüklüğünde deprem tahmininde bulunmuştur. Bu da UKSB ile zaman ve deprem büyüklüğü tahmin modelinin 15 günlük periyotta 5.0 büyüklüğünün üstünde bir deprem meydana gelmeyeceğini tahmin ettiği anlamına gelmektedir.

30 günlük tahmine bakıldığında en yüksek 4.8 büyüklüğünde en düşük 3.5 büyüklüğünde deprem tahmini yapıldığı görülmektedir. Buda UKSB ile zaman ve deprem büyüklüğü tahmin modelinin 30 günlük periyotta 4.8 büyüklüğünün üstünde bir deprem meydana gelmeyeceğini tahmin ettiği anlamına gelmektedir.

Tablo 3. Deprem tahmini için kullanılan yapılandırılmış deprem kataloglarına dayalı YSA modelleri (*ANN models based on structured earthquake catalogs for earthquake prediction*)

Deprem Tahmini Alanında Yapılan Çalışmalar	Kullanılan YSA Mimarisi
Deep learning of aftershock patterns following large earthquakes [5]	Derin Sinir Ağları (DNN)
Neural network models for earthquake magnitude prediction using multiple seismicity indicators [11]	Özyinelemeli Sinir Ağları (RNN)
Large Earthquake Magnitude Prediction In Taiwan Based On Deep Learning Neural Network [13]	Evrişimli Sinir Ağları (CNN)
Earthquake Prediction Based on Spatio-Temporal Data Mining: An LSTM Network Approach [12]	Uzun –Kısa Süreli Bellek (LSTM)
Neural networks to predict earthquakes in Chile [19]	Gutenberg-Richter (GR)
DBTM	Uzun – Kısa Süreli Bellek (LSTM)

Deprem tahmini için yapılan yapay sinir ağı literatürü gözden geçirildiğinde bu alana olan ilginin arttığı ve zaman içinde YSA modellerinin derin öğrenmeye doğru kaydığı ortaya çıkmaktadır.

Deprem katalog verileri en sık kullanılan makine öğrenmesi algoritmaları olan Çoklu Doğrusal Regresyon (MLR), Polinomal Regresyon (PR), Karar Ağaçları (DT), Rassal Ağaçlar (RF) ile eğitilmiş çıkan sonuçlar ile önerilen modelin tahmin sonuçları Tablo 4'te karşılaştırılmıştır.

Tablo 4. Deprem tahmin sonuçlarının karşılaştırılması (*Comparison of earthquake prediction results*)

Tarih	Enlem	Boylam	Der(km)	Yer	xM	DBTM	MLR	PR	DT	RF
27.12.2020	38.5050	39.2180	002.9	Kavaktepe-(Elazığ)	5.6	4.49	4.38	4.28	4.34	4.43
30.10.2020	37.8877	26.7057	011.2	Ege Denizi-(İzmir)	6.9	5.63	4.35	4.38	4.32	4.25
04.08.2020	38.1945	38.7270	005.5	Alihan-Pütürge (Malatya)	5.7	4.51	4.38	4.33	4.33	4.53
24.10.2020	38.3922	39.0847	005.0	Kalaba-Sivrice (Elazığ)	6.7	5.27	4.38	4.32	4.35	4.51

Bu çalışmada, birden fazla algoritma denenmiş, elde edilen sonuçlar değerlendirilmiş, modeller hem test verileri üzerinden hem de gerçek veriler üzerinden test edilmiştir. Modellerin performansının değerlendirilmesinde R-kare, Ortalama Mutlak Hata, Ortalama Kare Hata, Kök Ortalama Kare Hata esas alınmıştır.

Tablo 5. Modellerin performans sonuçlarının karşılaştırılması (*Comparison of the performance results of the models*)

MODEL	R - Kare	Ortalama Mutlak Hata	Ortalama Kare Hata	Kök Ortalama Kare Hata
MLR	0.075	0.317	0.173	0.416
PR	0.060	0.319	0.176	0.420
DT	0.100	0.307	0.168	0.411
RF	0.185	0.286	0.152	0.397
DBTM	0.228	0.267	0.148	0.360
UKSB	0.506	0.283	0.151	0.367

Tablo 5'te gösterilen sonuçlar deprem katalog veri kümeleri ile deprem tahmini konusunda, önerilen derin öğrenme modellerinin, çoklu doğrusal regresyon, polinomal regresyon, rastgele orman ve karar ağaçları gibi makine öğrenmesi algoritmalarından daha iyi bir performansa sahip olduğunu göstermektedir. Bu durum önerilen derin öğrenme modellerinin deprem tahminini iyileştirme potansiyelinin olduğunu göstermiştir.

KAYNAKLAR (REFERENCES)

- [1] «Boğaziçi Üniversitesi Kandilli Rasathanesi Ve Deprem Araştırma Enstitüsü,» 05 03 2020. [Çevrimiçi]. Available: <http://www.koeri.boun.edu.tr/sismo/bilgi/depremnedir/index.htm>.
- [2] A. Pandit ve K. C. Biswal, «Prediction of earthquake magnitude using adaptive neuro fuzzy inference system,» *Earth Science Informatics*, pp. 513-524, 2019.
- [3] D. Kumar ve Mrs.K.Sangeetha, «A Study on Earthquake Prediction Using Neural Network Algorithms,» *International Journal of Computer Sciences and Engineering*, Cilt %1 / %2Volume-6, no. Issue-10, pp. 200-204, 2018.
- [4] N. S. S. Zakeri ve S. Pashazadeh, «Classification of databases and methods for seismic data analysis and earthquake prediction,» *International Journal of technical and physical problem of engineering*, pp. 18-26, 2014.
- [5] P. M. r. DeVries, F. Viégas, M. Wattenberg ve B. J. Meade, «Deep learning of aftershock patterns following large earthquakes,» *Nature*, pp. 560, pages 632–634, 2018.
- [6] F. Aminzadeh, S. Katz ve K. Aki, «Adaptive Neural Nets for Generation of Artificial Earthquake Precursors,» *IEEE Transactions on Geoscience and Remote Sensing*, pp. 32:1139-1143, 1994.
- [7] S. Lakkos, A. Hadjiprocopis, R. Comley ve P. Smith, «A neural network scheme for Earthquake prediction based on the seismic electric signals,» %1 içinde *Proceedings of IEEE Workshop on Neural Networks for Signal Processing*, Ermioni, Greece, 1994.
- [8] A. Mignan ve M. Broccardo, «Neural Network Applications in Earthquake Prediction (1994–2019): Meta-Analytic and Statistical Insights on Their Limitations,» *Seismological Research Letters*, p. 2330–2342, 2020.
- [9] B. Brodi, «A neural-network model for earthquake occurrence,» *J. Geodyn*, pp. 32:289-310, 2001.

- [10] A. Negarestani, S. Setayeshi, M. Ghannadi-Maragheh ve B. Akashe, «Layered neural networks based analysis of radon concentration and environmental parameters in earthquake prediction.,» *J. Environmental Radioactivity*, pp. 62:225-233, 2002.
- [11] A. Panakkat ve H. Adeli, «Neural network models for earthquake magnitude prediction using multiple seismicity indicators,» *J. Neural Systems*, pp. 17:13-33, 2007.
- [12] Q. Wang, Y. Guo, L. Yu ve P. Li, «Earthquake Prediction Based on Spatio-Temporal Data Mining: An LSTM Network Approach,» *IEEE Transactions on Emerging Topics in Computing*, pp. 148 - 158, 2020.
- [13] J. Huang, X. Wang, Y. Zhao, C. Xin ve H. Xiang, «Large Earthquake Magnitude Prediction In Taiwan Based On Deep Learning Neural Network,» *Neural Network World*, pp. 149-160, 2018.
- [14] «<https://azure.microsoft.com/tr-tr/overview/what-is-deep-learning/>,» 02 01 2022. [Çevrimiçi]. Available: <https://azure.microsoft.com/tr-tr/overview/what-is-deep-learning/>.
- [15] «<https://azure.microsoft.com/en-gb/overview/what-is-artificial-intelligence/>,» 20 01 2022. [Çevrimiçi]. Available: <https://azure.microsoft.com/en-gb/overview/what-is-artificial-intelligence/>.
- [16] S. Hochreiter ve J. Schmidhuber, «Long Short-Term Memory,» *Neural Computation*, pp. 9(8), 1735-1780., 1997.
- [17] C. Ren, C. Chunxu Chai, C. Yin, H. Ji, X. Cheng, G. Gao ve H. Zhang, «Short-Term Traffic Flow Prediction: A Method of Combined Deep Learnings,» *Journal of Advanced Transportation*, 2021.
- [18] «Boğaziçi Üniversitesi Kandilli Rasathanesi Ve Deprem Araştırma Enstitüsü BDTİM Deprem Sorgulama Sistemi,» 15 10 2021. [Çevrimiçi]. Available: <http://www.koeri.boun.edu.tr/sismo/zeqdb/>.
- [19] J. Reyes, A. Morales-Esteban ve F. Martínez-Álvarez, «Neural networks to predict earthquakes in Chile,» *Applied Soft Computing*, pp. 13:1314-1328, 2013.
- [20] G. A. Cortés, F. Martínez-Álvarez, A. Troncoso ve A. Morales-Esteban, «Medium-large earthquake magnitude prediction in Tokyo with artificial neural networks,» *Neural Computing and Applications*, pp. 1043-1055, 2017.
- [21] D. Rumelhart, G. Hinton ve R. Williams, «Learning representations by backpropagating errors,» *Nature*, pp. 323:533-536, 1986.

ÖZGECMİS

Metin KARCI*

Metin KARCI 3 Eylül 1986 Kahtamanmaraş'ta doğdu. Ankara Üniversitesi Mühendislik Fakültesi Bilgisayar Mühendisliği Bölümünden 2015 yılında mezun oldu. 2019 yılında Gazi Üniversitesi Bilişim Enstitüsü Bilişim Sistemleri Anabilim Dalında Yüksek Lisans Programına başladı. Gazi Üniversitesi Bilgi İşlem Dairesi Başkanlığında Bilgisayar Mühendisi olarak çalışmaktadır. Yapay zekâ, derin öğrenme, makine öğrenmesi ve yazılım sistemleri alanlarında araştırmalar yapmaktadır.

İsmail ŞAHİN^b

Prof. Dr. İsmail ŞAHİN 1997 yılında Gazi Üniversitesi Teknik Eğitim Fakültesi Makine Eğitimi Bölümünden mezun oldu. Gazi Üniversitesi Fen Bilimleri Enstitüsü Makine Eğitimi alanında 2001 yılında Yüksek Lisans, 2008 yılında Doktora eğitimini tamamladı. 2009 yılında Gazi Üniversitesi Teknik Eğitim Fakültesi'ne Yardımcı Doçent

olarak atandı. 2010 yılında Teknoloji Fakültesi İmalat Mühendisliği ve akabinde 2012 yılında Endüstriyel Tasarım Mühendisliği Bölümüne Yardımcı Doçent olarak atandı. 2015 yılında Makine Mühendisliği alanında Doçent unvanını aldı. 2020 yılından itibaren Gazi Üniversitesi Teknoloji Fakültesi Endüstriyel Tasarım Mühendisliği Bölümü'nde Profesör olarak görev yapmaktadır. Güncel araştırma alanlarında konstrüksiyon ve imalat, makina elemanları, makina tasarımı, bilgisayar destekli tasarım ve imalat, mühendislik ve teknoloji, bilgisayar bilimi ve yapay zeka bulunmaktadır.