



İzmir'i etkileyebilecek büyük depremlerin makine öğrenimi yöntemleriyle tahmin edilmesi

Prediction of major earthquakes that may affect İzmir using machine learning methods

AYHAN DOĞAN ^{1*} 

¹ Hacettepe Üniversitesi, Başkent OSB Teknik Bilimler Meslek Yüksekokulu, Bilgisayar Teknolojileri Bölümü, Ankara, Türkiye

Geliş (*received*): 9 Aralık (*December*) 2023 Kabul (*accepted*): 16 Nisan (*April*) 2024

ÖZ

Deprem, üzerinde yaşadığımız dünya üzerindeki en büyük doğal afetlerdendir. İnsanlık tarihten günümüze depremlerden dolayı çok sayıda can ve mal kaybı yaşamıştır. Bu nedenle tarih boyunca insanlar depremleri önceden tahmin edebilmek ve önlemler alabilmek için çeşitli çalışmalar yapagelmıştır. Ancak dünyanın karmaşık jeolojik yapısı ve çeşitli dinamikleri nedeniyle depremleri tahmin etmek oldukça zordur. Yapay zeka çalışmalarında son yıllarda meydana gelen gelişmeler sayesinde birçok alanda yeni çözümler ortaya çıkmaya başlamıştır. Bu çalışmada diğer çalışmalardan farklı olarak gelecekte İzmir ilini etkileyebilecek 6 ve üzeri büyüklükteki depremlerin odak konumları ve odak derinlikleri Random Forest (RF), Decision Tree (DT), Light Gradient Boosting Machine (LGBM), Category Boosting (CB), Support Vector Machine (SVM) makine öğrenimi yöntemleri kullanılarak tahmin edilmiştir. Girdi verisi olarak 1900-2023 arasındaki deprem katalog verileri ile Gutenberg-Richter yasasına göre bu verilerden üretilen a ve b katsayıları birlikte kullanılmıştır. Sonuçlar RMSE, MAE ve R² metrikleriyle değerlendirilmiştir. Gelecekte İzmir'i etkileyebilecek depremlerin tahmin edilen odak konumları ve derinlikleri tablo halinde verilmiş ve harita üzerinde gösterilmiştir.

Anahtar Kelimeler: Deprem tahmini, İzmir, makine öğrenimi, odak konumu, odak derinliği

ABSTRACT

Earthquakes are among the most devastating natural disasters worldwide, causing significant loss of life and property throughout history. Therefore, numerous earthquake prediction studies have been conducted, and precautions have been taken. However, due to our planet's complex geological structure and various dynamics, predicting earthquakes remains challenging. New solutions have emerged in various fields thanks to recent advancements in artificial intelligence research. In this study, we predict the hypocenter locations and depths of earthquakes of magnitude 6 or greater, which could impact the İzmir province in the future. We utilize machine learning techniques, specifically Random Forest (RF), Decision Tree (DT), Light Gradient Boosting Machine (LGBM), Category Boosting (CB), and Support Vector Machine (SVM) methods to make

these predictions. The study utilized earthquake catalog data collected between 1900 and 2023, and a and b coefficients generated from this data based on the Gutenberg-Richter law. The evaluation of the results was carried out using RMSE, MAE, and R^2 metrics. The map showcases the predicted hypocenter locations and depths of future earthquakes that could impact Izmir.

Keywords: Earthquake prediction, Izmir, machine learning, hypocenter location, hypocenter depth

<https://doi.org/10.17824/yerbilimleri.1402618>

*Sorumlu Yazar/ Corresponding Author: aydogan@hacettepe.edu.tr

GİRİŞ

Deprem, genellikle yer altındaki plakaların birbirine çeşitli şekillerde temas etmesi ve fay hattı boyunca oluşan gerilme enerjisinin ortaya çıkması sonucu oluşan sismik olaylardır. Depremler sonucunda ortaya çıkan sismik enerji tüm doğayı etkiler. Ancak depremler sonucunda insanlık açısından en büyük kayıplar, yeterli mühendislik hizmeti almamış veya doğru inşa edilmemiş yapılar nedeniyle meydana gelir. Depremler çok büyük yer tabakalarının hareketleri sonucunda meydana geldiğinden bu hareketleri engellemek mümkün değildir. Depremin neden olduğu zararları en az indirmek için genellikle iki ana konu üzerinde durulmaktadır. Bunlar, depremleri önceden tahmin edip önlemler alabilmek ve depreme dayanıklı yapılar inşa edebilmektir. Depremlerin mekanizması karmaşık olduğundan depremleri önceden tahmin edebilmek çok zordur. Bu nedenle toplumlar depremin zararlarından korunabilmek için depreme dayanıklı yapılar inşa etmeye çalışmaktadır. Bu önemli bir çözümdür. Ancak yine de ekonomik kaygılar, denetim eksikliği, yeterli mühendislik hizmetinin alınmaması, mevzuat yetersizlikleri, üretim hataları ve yeterli bilincin oluşmaması gibi çeşitli nedenlerle uygulamada sıklıkla istenilen seviyede başarılı sonuçlar alınamamaktadır.

İnsanlık tarihi boyunca depremlerin tahmin edilebilmesi önemli olmuştur. Bu amaçla çok

çeşitli çalışmalar yapılmıştır. İlk zamanlarda yeraltı suları, yeraltından çıkan gazlar gibi birçok doğa olayı gözlenmiş, çeşitli hayvanların depremlerden kısa süre önce davranışlarındaki değişiklikler incelenerek depremler tahmin edilmeye çalışılmıştır (Rikitake, 1968; Barsukov vd., 1984; Kirschvink, 2000). Sonra tahmin amacıyla elektrik ve sismik yöntemler başta olmak üzere çeşitli bilimsel yöntemler de kullanılmıştır (Whitcomb vd., 1973; Moustra vd., 2011). Yapılan bu çalışmalar genellikle depremden çok kısa süre öncesinde ortaya çıkan belirtileri olasılıklı olarak kısmen tahmin edebilmektedir (Hayakawa ve Hobara, 2010). Depremler olmadan önce yeterli zamana sahip olabilmek ve öncelikle can kaybını en aza indirebilmek için önlem alabilmek amacıyla depremin zamanını, odak konumunu, derinliğini ve büyüklüğünü saatler ve günler öncesinden tahmin edebilmek çok önemlidir (Michael vd., 2020).

Günümüzde yapay zeka çalışmalarında meydana gelen gelişmeler, deprem tahmini yapabilmek için umut vericidir. Asencio-Cortés vd., (2017) Japonya'da yedi gün içerisinde olabilecek depremleri tahmin etmişlerdir. Çalışmalarında çeşitli yapay zeka yöntemleri kullanmışlar ve kullandıkları yöntemler arasında en başarılı yöntemin Artificial Neural Network (ANN) (Yapay Sinir Ağları (YSA)) olduğunu söylemişlerdir. Benzer bir çalışma Malezya'da deprem tahmini için yapılmış ve iki yöntem arasından ANN yönteminin daha başarılı olduğu sonucuna varılmıştır (Essam

vd., 2021). Diğer bir çalışmada deprem anındaki kırılmanın nasıl olduğunu ve dalga yayılımını anlamak için ANN ve RF yöntemleri kullanılarak tahminler yapılmıştır (Ahamed ve Daub, 2019). Bazı çalışmalarda çeşitli derin öğrenme yöntemleri kullanılarak depremin zamanı, büyüklüğü ve yeri tahmin edilmeye çalışılmıştır (Berhich vd., 2022; Berhich vd., 2023). Arazi verileri yerine laboratuvar deneylerinden elde edilen verileri kullanarak depremin zamanını ve depremlerle ilgili diğer parametreleri tahmin eden çalışmalar da vardır (Rouet-Leduc vd., 2017; Wang vd., 2022).

Sezer, (2004) yaptığı çalışmayla İzmir'in depremselliğini ve deprem riskini, büyük depremlere standart sapma analizi Gumbel-Gutenberg-Richter yöntemleriyle belirlemeye çalışmıştır. Saç ve Camgöz, (2005) İzmir ve çevresindeki depremlerle radon gazı konsantrasyonları arasındaki ilişkiyi araştırmışlardır. Sayıl, (2013) Batı Anadolu bölgesi için multiple linear regression (çoklu doğrusal regresyon) tekniğini kullanarak elli yıl içerisinde büyük bir deprem olasılığını değerlendirmiştir. Çalışmaya göre bölgede deprem olasılığı yüksek çıkmıştır. Öncel Çekim vd., (2023) Türkiye'nin batısını kapsayan ve deprem büyüklük tahminine yönelik bir çalışma yapmışlardır. Çalışmada 1970 ile 2020 yılları arasındaki deprem katalog bilgileri aylık ortalama deprem büyüklüklerine göre gruplandırılarak kullanılmıştır. Çalışmada çeşitli istatistik ve derin öğrenme yöntemleri kullanılmış, üç yıllık periyotta büyüklük değerlerine bakılarak en iyi deprem tahmin sonuçlarının LSTM yöntemiyle elde edildiği vurgulanmıştır. Çalışmada tahmin edilen büyüklüklerin 4.5'ten küçük olduğu dikkat çekmektedir. Bulbul, (2023) yaptığı çalışmada uzay hava koşullarını dikkate alarak iyonosferde meydana gelen değişiklikleri deprem öncesi ve sonrasında incelemiştir. Çalışmada 2020 yılında meydana gelen İzmir Seferihisar depremi de araştırılmıştır. Çalışma

sonuçlarında 6.5 Mw'den daha büyük depremlerin 1-3 hafta öncesinden günlük toplam elektron içeriği (TEC) anomalilerine neden olabildiği belirtilmektedir. Demirelli vd., (2023) yaptıkları çalışmada İzmir-Balıkesir bölgesine ait jeodezik gerinim hızları, artçı deprem bilgilerinin çıkarıldığı 1970-2021 arasındaki deprem katalog bilgileri, fay uzunlukları ve türlerini kullanarak gerçekleşmiş depremler üzerinde çeşitli makine öğrenimi yöntemlerinin tahmin başarılarını test etmişlerdir. Kullandıkları yöntemlerden RF ve XGBoost yöntemlerinin en iyi sonuçları verdiğini belirtmişlerdir.

Bu çalışmada İzmir ve yakın çevresi için gelecekte olabilecek 6 ve üzeri büyüklükteki depremlerin odak koordinatları ve odak derinlikleri makine öğrenimi yöntemleri kullanılarak tahmin edilmektedir. Bu tahminlerin başarıları performans metrikleriyle ölçülmüş ve karşılaştırılmıştır.

MATERYAL VE METOT

Çalışma alanı

Türkiye'nin nüfus olarak en büyük üçüncü şehri ve deprem riski yüksek olan İzmir ili çalışma alanı olarak seçilmiştir. İzmir ili ve çevresi çok sayıda aktif fay hattı üzerindedir. Şekil 1'de çalışma alanı ve bölgedeki aktif fay hatları gösterilmektedir.


Veri

İzmir'i etkileyebilecek depremlerle ilgili olarak deprem katalog verileri Boğaziçi Üniversitesi Kandilli Rasathanesi ve Deprem Araştırma Enstitüsü'nden (KOERI) alınmıştır. Veriler 01.01.1900 tarihi ile 30.11.2023 tarihleri arasında İzmir'in en yoğun yerleşim yerlerinden biri olan Konak ilçesi merkez kabul edilerek 100 km yarıçapındaki alanda meydana gelmiş 3 ve üzeri büyüklükteki depremleri kapsamaktadır (Şekil 1). Bu alan 2020 yılında depremin merkez üssü İzmir'in Seferihisar ilçesine bağlı Sığacık açıklarında Ege denizi içinde meydana gelen depremi de kapsamaktadır.



Şekil 1. Çalışma alanı ve bölgedeki aktif fay hatları (MTA, 2023)

Figure 1. Study area and active fault lines in the region (MTA, 2023)



Şekil 2. Çalışmada kullanılan depremlerin konumları ve büyüklükleri

Figure 2. The locations and magnitudes of the earthquakes used in the study

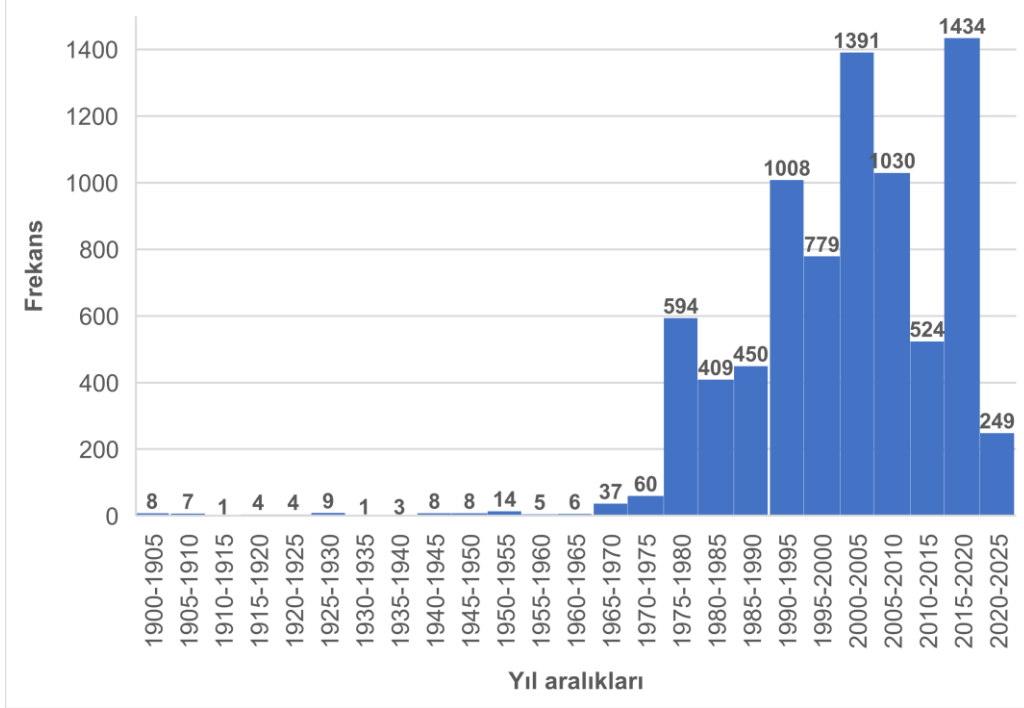
Belirtilen kriter aralıklarında farklı büyüklüklerde toplam 8043 deprem kaydı mevcuttur.

KOERI web sitesinden alınan verilerde magnitüde değerleri farklı büyüklük ölçülerine sahip olduğundan (Md, MI, Ms, Mb, Mw) hepsi Mw büyüklüğüne dönüştürülmüştür. Bu dönüşüm için Kadıroğlu ve Kartal, (2016)'ın Türkiye için önermiş olduğu dönüşüm bağıntıları kullanılmıştır. Veri içerisindeki deprem oluş tarihi, enlem, boylam, derinlik ve büyüklük verileri alınmıştır.

Bu verilerden Gutenberg-Richter yöntemindeki a ve b katsayıları elde edilmiştir. Tüm veriler standartlaştırma işlemiyle makine öğreniminde kullanılmaya hazır hale getirilmiştir. Çalışmada kullanılan depremlerin konumları ve büyüklüklerine göre harita üzerinde gösterimi Şekil 2'de verilmektedir.

Kullanılan verilere ait istatistiksel bilgiler Tablo 1'de verilmektedir. Bölgede 5 ve üzeri büyüklükte 86 deprem, 6 ve üzeri büyüklükte 10 deprem, 6.5 ve üzeri büyüklükte 2 deprem meydana gelmiştir. Kayıtlara göre 1900 yılından bu yana bölgede 7 ve üzeri büyüklükte deprem olmamıştır.

Kullanılan deprem verilerinin sıklığını gösteren histogram Şekil 3'de verilmektedir. 1965'li yıllardan itibaren deprem sayısında önemli bir artış görülmektedir. Bu durum bölgedeki sismik aktivitenin arttığını düşündürmektedir. Buna ek olarak deprem kayıt istasyonlarının sayısındaki artış da bu sonuçlar üzerinde etkili olabilir. Histogramdaki başka bir dikkat çekici durum ise 1975 yılından başlayarak yaklaşık ortalama her 10-15 yıllık periyotlarla daha fazla sayıda deprem olması ve bunların arasındaki yıllarda ise önceki döneme göre görece azalmasıdır.



Şekil 3. Yıllara göre Mw ≥ 3 depremlerin histogramı

Figure 3. Histogram of earthquakes with a magnitude of Mw ≥ 3 by year

Tablo 1. Büyüklüklerine göre deprem sayıları

Table 1. Number of earthquakes by magnitude

Büyüklük (Mw)	Deprem sayısı
Mw ≥ 4	1869
Mw ≥ 5	86
Mw ≥ 6	10
Mw ≥ 6.5	2

Metot

Bu çalışmada RF, DT, LGBM, CB, SVM makine öğrenimi yöntemleri kullanılarak gelecekte İzmir ve yakınlarında olması muhtemel büyük depremlerin (Mw=6 ve üzeri) deprem odak koordinatları ve odak derinlikleri

tahmin edilmiştir. Makine öğrenimi modellerinin eğitim ve test aşamalarında 5 katlı K-Fold çapraz doğrulama yöntemi kullanılmış ve performans metrikleriyle (RMSE, MAE ve R²) değerlendirilmiştir.

Yapılan çalışmalarda 1900-2023 yılları arasındaki deprem katalog verileri ile birlikte bu verilerden üretilen Gutenberg-Richter (GR) yasasındaki a ve b katsayıları birlikte kullanılmıştır. GR yasasında depremlerin görülme sıklığı ile büyüklükleri arasındaki ampirik ilişki Eşitlik 1 ile ifade edilmektedir.

$$\log N = a - bM \quad (1)$$

Bu eşitlikteki N değeri, M'ye eşit veya daha

büyük depremlerin toplam sayısı, a sabiti depremselliğin aktivite düzeyi, b sabiti ise frekans-büyüklik dağılımının eğilimi hakkında bilgi verir (Bayrak vd., 2017). Buradaki a değeri deprem sayısı ve gözlem aralığından da etkilenmektedir (Eyidoğan, 2020). GR yasasından elde edilen değerlerin kullanılma nedenlerinin başında, özellikle b değerinin zamansal değişimleri ile depremlerin oluşumu arasındaki ilişkinin birçok çalışmayla ortaya konulmuş olmasıdır (Nuannin vd., 2005; Wiemer ve Schorlemmer, 2007; Morales-Esteban vd., 2013).

Random Forest (Rastgele Orman)

RF, temelde ağaç tabanlı bir makine öğrenimi yöntemidir. Ağaç tabanlı modeller, önceden belirlenmiş bir durma koşulu karşılınca kadar belirli bir kritere dayalı olarak verilen veri kümesini yinelemeli olarak iki gruba ayırmayı içerir (Schonlau ve Zou, 2020). RF, hem sınıflandırma hem de regresyon problemlerinde kullanılan bir topluluk (ensemble) yöntemidir. İlk defa Leo Breiman tarafından 2001 yılında tanıtılmıştır (Breiman, 2001). RF yöntemi veri setinden rastgele alt örnekler (bootstrap) üretir ve yeni veri setleri oluşturur. Bu şekilde genel modele uyumu artırmaya çalışır. Oluşturduğu örneklemeler üzerinde derinliği sınırlı ağaçlar oluşturur. Bu sayede aşırı öğrenme önlenir. Ağacın her düğümünde özellik seçimi yapılır. Bu işlem her ağacın diğerinden farklı olmasını sağlar. Sonuçta sınıflandırma için oylama, regresyon için ortalama olarak hedefe ulaşır.

Decision Tree (Karar Ağacı)

DT yöntemi karar kurallarını ve sonuçlarını içeren ağaç benzeri bir yapıya sahiptir. Ağaç, kök düğümünden başlar, sonuçları temsil eden yaprak düğümlerinde sonlanır. Her düğüm bir özellik veya test koşuluyla ilişkilidir. Her kenar ise belirli bir test koşulunun doğru veya yanlış olmasına göre gidilecek yolu gösterir. Bu

yöntem eğitim verilerine aşırı uyum gösterebileceğinden aşırı öğrenmeye meyillidir. Bu sorunu çözmek için ağaçların derinliği sınırlanır veya ağacın gereksiz dalları budanır (Maimon ve Rokach, 2014; Correa Bahnsen vd., 2015).

Light Gradient Boosting Machine (Hafif Gradyan Artırma Makinesi)

LGBM, bir tür gradyan artırma algoritmasıdır. Özellikle büyük veri setleri ve yüksek boyutlu özellik uzayları ile başa çıkmak üzere optimize edilmiştir. XGBoost modelinden temel farkları, eğitim sürecini hızlandırmak, bellek tüketimini azaltmak ve derinlik kısıtlamalarıyla yaprak bazında büyüme stratejisi uygulamaktır. Bunun için histogram tabanlı algoritmalar kullanır (Fan vd., 2019). LGBM, geleneksel gradyan artırma algoritmalarına göre eğitim sürecini çok hızlandırır (Ke vd., 2017). Bu yöntemde "leaf-wise" büyüme stratejisi benimsendiğinden, bir ağacın en çok bilgi içeren dalına odaklanarak daha hızlı eğitim sağlanır. LGBM, adım adım zayıf öğreniciler ekleyerek, hataları düzelterek ve bilgi kazancını artırarak bir topluluk modeli oluşturur. Böylece, büyük veri setleri ve yüksek boyutlu özellik uzayları ile çalışırken yüksek performans sağlar (Guo vd., 2023).

Category Boosting (Kategori Artırma)

CB, kategorik değişkenlere özel olarak tasarlanmış bir gradyan artırma yöntemidir. Sınıflandırma ve regresyon problemlerinde kullanılır (Prokhorenkova vd., 2018). Simetrik ağaç büyümesi yöntemini benimser. Bu yöntem ağaçların daha hızlı büyümesine imkân tanır. Daha önce eklenmiş ağaçların hatalarını düzeltmek üzere yeni ağaçların eklenmesini kontrol eder. Bayes düzenleştirmesi yöntemini kullanarak aşırı öğrenmeyi kontrol altına alır. Sınıf dengesizliği durumuna karşı dirençlidir (Hussain vd., 2021). Eğitim süresini kısaltır ve düşük bellek tüketimi sağlar. Böylece özellikle büyük veri setleri üzerinde çalışırken avantaj

sağlar. Hiperparametreleri otomatik ayarlayabildiğinden el ile müdahaleyi azaltır (Prokhorenkova vd., 2018; Gupta vd., 2021; Baik vd., 2023)

Support Vector Machine (Destek Vektör Makinesi)

SVM, özellikle yüksek boyutlu özellik uzayları ve non-linear veri setlerinde etkili olan bir öğrenme modelidir. Sınıflar arası ayrımı maksimum yapmayı amaçlar. İki sınıf arasındaki en büyük marjı sağlayan bir hiperdüzlem oluşturur (Doğan vd., 2023). Çeşitli çekirdek fonksiyonları kullanarak doğrusal ayrımın mümkün olmadığı durumlarda veri noktalarını daha yüksek

boyutlu uzaya taşıyarak daha etkili çözümler bulmaya çalışır (Cortes ve Vapnik, 1995; Soman vd., 2009).

BULGULAR

Çalışma alanında gelecekte olması muhtemel 6 ve üzeri depremlerin odak konumları ve derinliklerini tahmin edebilmek için beş farklı makine öğrenimi yöntemiyle eğitimler gerçekleştirilmiştir. K-Fold çapraz doğrulama sonucunda performans metrikleriyle elde edilen test sonuçları Tablo 2'de verilmektedir. Test sonuçları incelendiğinde tüm yöntemlerin oldukça başarılı olduğu, bunlar içerisinde en başarılı yöntemin ise RF yöntemi olduğu görülmektedir.

Tablo 2. Makine öğrenimi tahminlerine ait metriklerin sonuçları

Table 2. Results of machine learning prediction metrics


		SVM	CB	LGBM	RF	DT
RMSE	Enlem	0.055	0.004	0.003	0.001	0.001
	Boylam	0.057	0.006	0.003	0.001	0.001
	Derinlik	3.950	0.419	0.767	0.197	0.254
MAE	Enlem	0.040	0.003	0.002	0.001	0.001
	Boylam	0.040	0.003	0.002	0.001	0.001
	Derinlik	0.584	0.064	0.054	0.011	0.015
R ²	Enlem	0.985	0.998	0.998	0.999	0.999
	Boylam	0.986	0.998	0.998	0.999	0.999
	Derinlik	0.764	0.997	0.991	0.998	0.998

Yapılan beş makine öğrenimine ait odak enlem, boylam ve derinlik tahmin sonuçları Tablo 3'te verilmektedir. Sonuçlar incelendiğinde SVM yöntemi dışında diğer dört yöntemle (CB, LGBM, RF, DT) elde edilen odak konumları birbirine çok yakındır ve

aralarındaki uzaklık ortalama 0.3 km'dir. Bu dört yöntemle tahmin edilen odak konumları İzmir körfezi denizi içerisinde göstermektedir (Şekil 4). SVM yöntemiyle tahmin edilen odak konumu ile RF yöntemiyle elde edilen odak konumu arasındaki uzaklık ise sadece 3.5

Tablo 3. Büyüklüğü 6 ve üzeri olan deprem tahmin sonuçları**Table 3.** Earthquake prediction results with magnitude 6 and above

Makine Öğrenimi Yöntemi	Odak		
	Enlem	Boylam	Derinlik (km)
SVM	38.46668236	27.00774065	12.04245709
CB	38.43396077	27.03192379	9.48316773
LGBM	38.43874799	27.02946647	10.14100136
RF	38.43980000	27.03191800	9.30000000
DT	38.43780000	27.03120000	9.30000000

**Şekil 4.** Büyüklüğü 6 ve üzeri olabilecek depremler için tahmin sonuçları (Sarı renkli yer işaretleri: SVM, LGBM, RF, DT, CB)**Figure 4.** Prediction results obtained for earthquakes of magnitude 6 and above (Yellow landmarks: SVM, LGBM, RF, DT, CB)

km'dir. Bilindiği gibi deprem odağına olan uzaklık depremin etkisini etkileyen önemli faktörlerdendir. Elde edilen bulgular gelecekte İzmir'de 6 ve üzerinde depremlerin şehir merkezinin çok yakınlarında olabileceğini göstermektedir. Bu durum depremde oluşabilecek zararı artırabilir.

TARTIŞMA

İzmir ve yakınlarında bugüne kadar yapılan deprem tahmini çalışmaları bu çalışmada kullanılan yöntemlerden farklıdır. Bu çalışmada kullanılan makine öğrenimi yöntemlerinin birlikte kullanıldığı bir çalışma bulunmamaktadır. Aynı zamanda İzmir için deprem katalog bilgileri ile birlikte GR yasasının a ve b sabitlerinin birlikte kullanıldığı herhangi bir makine öğrenimi çalışması da yoktur. Yapılan çalışmalardan bazıları tüm Batı Anadolu bölgesini kapsayacak şekilde farklı yöntemlerle yapılmış, İzmir özelinde yapılmamıştır (Sayıl, 2013; Öncel Çekim vd., 2023). Buna ek olarak bazı çalışmalarda kısıtlı veri seti kullanılmıştır. Çalışmaların birçoğu deprem katalog verilerini kullanmışlar bu verilerden deprem tahmini için anlamlı yeni özellikler türetmemişlerdir. Bir çalışmada yine bu çalışmadan farklı olarak, Batı Anadolu bölgesi için GR yasasının sadece b değeri, gerinim hızları ve fay bilgileri ek özellik olarak kullanılmıştır (Demirelli vd., 2023). Farklı verilerle (TEC, radon gazı vb.) ve başka yöntemlerle yapılmış çalışmalar bulunmaktadır (Saç ve Camgöz, 2005; Bulbul, 2023; Pırtı vd., 2023).

Makine öğrenimi eğitim ve test çalışmalarında mümkün olduğunca veri sayısının çok olması istenir. Depremlerin tekrarlama periyotları bazen onlarca bazen de yüzlerce yıl olabilmektedir. Bu nedenle gelecekteki depremleri tahmin edebilmek için mümkün olduğunca çok sayıda geçmiş yıllara ait deprem verisinin kullanılmasıyla tahmin

başarısının artması beklenmektedir. Ancak geçmişte yapılan bazı çalışmalarda hem yıl olarak hem de deprem büyüklüğü olarak kısıtlı veri kullanıldığı görülmektedir. Bu çalışmada 1900-2023 yılları arasında 123 yıllık deprem katalog verisi, büyüklüğü 3 ve üzeri tüm depremleri kapsayacak şekilde kullanılmıştır.

SONUÇ

Depremleri olmadan tahmin edebilmek tarih boyunca insanlar için önemli olmuştur. Bu amaçla çok sayıda bilimsel çalışma yapılmıştır. Makine öğrenimi ise son yıllarda kullanılan yeni tahmin araçları arasındadır. Makine öğrenimi oldukça karmaşık olan deprem mekanizmasını çok sayıda deprem verisini ve bu verilerden elde edilen anlamlı özellikleri de kullanarak oldukça isabetli tahminler yapabilmektedir.

Bu çalışmada İzmir için gelecekte olabilecek büyük depremlerle ilgili tahminler yapılmış ve deprem odak konumu ve derinlikleri tahmin edilmiştir. Bu amaçla deprem katalog bilgileri ve bu verilerden üretilen GR yasası a ve b sabitleri kullanılarak makine öğreniminin tahmin başarısı artırılmaya çalışılmıştır. Performans metrikleri incelendiğinde tahmin başarıları tüm yöntemlerde yüksek çıkmıştır. Bununla birlikte metriklere göre en başarılı yöntem RF yöntemidir. RF yönteminden sonra en başarılı yöntem ise DT yöntemidir. Diğer yöntemlerde sıralama enlem, boylam ve derinliğe göre değişmektedir. RF yöntemi enlem ve boylam tahmin başarısı RMSE ve MAE metriklerine göre 0.001, R^2 metriğine göre 0.999'dur. Derinlik tahmininde ise RMSE metriğine göre 0.197, MAE metriğine göre 0.011, R^2 metriğine göre 0.998 bulunmuştur. Tüm makine öğrenimi çalışmalarından elde edilen odak konumu tahmin sonuçları birbirine yakındır. Sonuçlar incelendiğinde gelecekte olabilecek >6 büyüklükteki bir depremin odak konumunun İzmir körfezinde olabileceği

tahmin edilmektedir. Odak derinliğine ait sonuçlar incelendiğinde gelecekte olabilecek 6 ve üzeri büyüklükteki bir depremin yaklaşık 9 ile 12 km aralığındaki bir derinlikte olması beklenmektedir. Tüm esnek hesaplama yöntemlerinde olduğu gibi bu çalışmada bulunan tahmin değerleri, belirli bir güven aralığında değişkenlik göstermektedir. Zaman içerisinde deprem katalog bilgilerinin artmasıyla tahmin başarı oranlarının yükselmesi de beklenen bir durumdur. Ayrıca gelecek ile ilgili yapılan deprem tahminlerinin depremlerin karmaşık mekanizması ve yeraltındaki tüm dinamiklerin bilinmemesi sebebiyle kesinlik ifade etmediğini de belirtmek gerekir. Bununla birlikte bu çalışmayla karar vericiler, planlamacılar ve uygulayıcılara yapacakları çalışmalar için önemli bilgiler sağlanırken aynı zamanda bilimsel literatüre de katkıda bulunulmuştur.

KAYNAKLAR

- Ahamed, S., Daub, E. G., 2019. Machine learning approach to earthquake rupture dynamics. arXiv preprint arXiv:1906.06250.
- Asencio-Cortés, G., Martínez-Álvarez, F., Troncoso, A., Morales-Esteban, A., 2017. Medium-large earthquake magnitude prediction in Tokyo with artificial neural networks. *Neural Computing and Applications*, 28(5), 1043-1055. <https://doi.org/10.1007/s00521-015-2121-7>
- Baik, S. M., Hong, K. S., Park, D. J., 2023. Application and utility of boosting machine learning model based on laboratory test in the differential diagnosis of non-COVID-19 pneumonia and COVID-19. *Clinical Biochemistry*, 118, 110584. <https://doi.org/10.1016/j.clinbiochem.2023.05.003>
- Barsukov, V. L., Varshal, G. M., Zamokina, N. S., 1984. Recent results of hydrogeochemical studies for earthquake prediction in the USSR. *Pure and Applied Geophysics* 122(2), 143-156. <https://doi.org/10.1007/BF00874588>
- Bayrak, E., Yılmaz, Ş., Bayrak, Y., 2017. Temporal and spatial variations of Gutenberg-Richter parameter and fractal dimension in Western Anatolia, Turkey. *Journal of Asian Earth Sciences*, 138, 1-11. <https://doi.org/10.1016/j.jseaes.2017.01.031>
- Berhich, A., Belouadha, F.-Z., Kabbaj, M. I., 2022. A location-dependent earthquake prediction using recurrent neural network algorithms. *Soil Dynamics and Earthquake Engineering*, 161, 107389. <https://doi.org/10.1016/j.soildyn.2022.107389>
- Berhich, A., Belouadha, F.-Z., Kabbaj, M. I., 2023. An attention-based LSTM network for large earthquake prediction. *Soil Dynamics and Earthquake Engineering*, 165, 107663. <https://doi.org/10.1016/j.soildyn.2022.107663>
- Breiman, L., 2001. Random forests. *Machine Learning*, 45, 5-32.
- Bulbul, S., 2023. Investigation of possible causes of ionospheric anomalies pre/post-earthquakes based on space weather conditions (SWC). *Indian Journal of Physics*. 10.1007/s12648-023-02866-x
- Correa Bahnsen, A., Aouada, D., Ottersten, B., 2015. Example-dependent cost-sensitive decision trees. *Expert Systems with Applications*, 42(19), 6609-6619. <https://doi.org/10.1016/j.eswa.2015.04.042>
- Cortes, C., Vapnik, V., 1995. Support-vector networks. *Machine Learning*, 20(3), 273-297. <https://doi.org/10.1007/BF00994018>
- Demirelli, E., Solak, H. İ., Tiryakioğlu, İ., 2023. Makine öğrenmesi algoritmaları ile deprem

- katalogları kullanılarak deprem tahmini. Gümüşhane Üniversitesi Fen Bilimleri Dergisi, 13(4), 979-989.
- Doğan, A., Korkmaz, M., Kirmaci, V., 2023. Estimation of Ranque-Hilsch vortex tube performance by machine learning techniques. International Journal of Refrigeration, 150, 77-88. <https://doi.org/10.1016/j.ijrefrig.2023.01.021>
- Essam, Y., Kumar, P., Ahmed, A. N., Murti, M. A., El-Shafie, A., 2021. Exploring the reliability of different artificial intelligence techniques in predicting earthquake for Malaysia. Soil Dynamics and Earthquake Engineering, 147, 106826. <https://doi.org/10.1016/j.soildyn.2021.106826>
- Eyidoğan, H., 2020. Manisa Akhisar Civarındaki Deprem Aktivitesi ile Gutenberg-Richter Parametrelerinin Zamansal ve Mekânsal Özelliklerinin İncelenmesi. Türk Deprem Araştırma Dergisi, 2(2), 138-159.
- Fan, J., Ma, X., Wu, L., Zhang, F., Yu, X., Zeng, W., 2019. Light Gradient Boosting Machine: An efficient soft computing model for estimating daily reference evapotranspiration with local and external meteorological data. Agricultural Water Management, 225, 105758. <https://doi.org/10.1016/j.agwat.2019.105758>
- Guo, J., Yun, S., Meng, Y., He, N., Ye, D., Zhao, Z., Jia, L., Yang, L., 2023. Prediction of heating and cooling loads based on light gradient boosting machine algorithms. Building and Environment, 236, 110252. <https://doi.org/10.1016/j.buildenv.2023.110252>
- Gupta, H., Kumar, P., Saurabh, S., Mishra, S. K., Appasani, B., Pati, A., Ravariu, C., Srinivasulu, A., 2021. Category boosting machine learning algorithm for breast cancer prediction. Revue roumaine des sciences techniques-série électrotechnique et énergétique, 66(3), 201-206.
- Hayakawa, M., Hobara, Y., 2010. Current status of seismo-electromagnetics for short-term earthquake prediction. Geomatics, Natural Hazards and Risk, 1(2), 115-155. <https://doi.org/10.1080/19475705.2010.486933>
- Hussain, S., Mustafa, M. W., Jumani, T. A., Baloch, S. K., Alotaibi, H., Khan, I., Khan, A., 2021. A novel feature engineered-CatBoost-based supervised machine learning framework for electricity theft detection. Energy Reports, 7, 4425-4436. <https://doi.org/10.1016/j.egyr.2021.07.008>
- Kadirioğlu, F. T., Kartal, R. F., 2016. The new empirical magnitude conversion relations using an improved earthquake catalogue for Turkey and its near vicinity (1900-2012). Turkish Journal of Earth Sciences, 25(4), 300-310. <https://www.doi.org/10.3906/yer-1511-7>
- Ke, G., Meng, Q., Finley, T., Wang, T., Chen, W., Ma, W., Ye, Q., Liu, T.-Y., 2017. Lightgbm: A highly efficient gradient boosting decision tree. Advances in neural information processing systems, 30.
- Kirschvink, J. L., 2000. Earthquake prediction by animals: Evolution and sensory perception. Bulletin of the Seismological Society of America, 90(2), 312-323.
- Maimon, O. Z., Rokach, L. 2014. Data mining with decision trees: theory and applications. World scientific,
- Michael, A. J., McBride, S. K., Hardebeck, J. L., Barall, M., Martinez, E., Page, M. T., van der Elst, N., Field, E. H., Milner, K. R., Wein,

- A. M., 2020. Statistical seismology and communication of the USGS operational aftershock forecasts for the 30 November 2018 Mw 7.1 Anchorage, Alaska, earthquake. *Seismological Research Letters*, 91(1), 153-173. <https://doi.org/10.1785/0220190196>
- Morales-Esteban, A., Martínez-Álvarez, F., Reyes, J., 2013. Earthquake prediction in seismogenic areas of the Iberian Peninsula based on computational intelligence. *Tectonophysics*, 593, 121-134. <https://doi.org/10.1016/j.tecto.2013.02.036>
- Moustra, M., Avraamides, M., Christodoulou, C., 2011. Artificial neural networks for earthquake prediction using time series magnitude data or Seismic Electric Signals. *Expert Systems with Applications*, 38(12), 15032-15039. <https://doi.org/10.1016/j.eswa.2011.05.043>
- MTA. 2023. Geosciences Map Viewer. <http://yerbilimleri.mta.gov.tr/anasayfa.aspx> (Erişim Tarihi: 20.11.2023).
- Nuannin, P., Kulhanek, O., Persson, L., 2005. Spatial and temporal b value anomalies preceding the devastating off coast of NW Sumatra earthquake of December 26, 2004. *Geophysical Research Letters*, 32(11).
- Öncel Çekim, H., Karakavak, H. N., Özel, G., Tekin, S., 2023. Earthquake magnitude prediction in Turkey: a comparative study of deep learning methods, ARIMA and singular spectrum analysis. *Environmental Earth Sciences*, 82(16), 387.
- Pırtı, A., Hoşbaş, R. G., Yücel, M. A., 2023. Examination of the Earthquake (Samos Island) in Izmir (30.10.2020) by Using Cors-Tr GNSS Observations and InSAR Data. *KSCE Journal of Civil Engineering*, 27(1), 135-144. 10.1007/s12205-022-0392-y
- Prokhorenkova, L., Gusev, G., Vorobev, A., Dorogush, A. V., Gulin, A., 2018. CatBoost: unbiased boosting with categorical features. *Advances in neural information processing systems*, 31.
- Rikitake, T., 1968. Earthquake prediction. *Earth-Science Reviews*, 4, 245-282. [https://doi.org/10.1016/0012-8252\(68\)90154-2](https://doi.org/10.1016/0012-8252(68)90154-2)
- Rouet-Leduc, B., Hulbert, C., Lubbers, N., Barros, K., Humphreys, C. J., Johnson, P. A., 2017. Machine Learning Predicts Laboratory Earthquakes. *Geophysical Research Letters*, 44(18), 9276-9282. <https://doi.org/10.1002/2017GL074677>
- Saç, M. M., Camgöz, B., 2005. İzmir'de sismik aktiviteler ile radon konsantrasyonları arasındaki korelasyonun incelenmesi. *Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen ve Mühendislik Dergisi*, 7(3), 47-54.
- Sayıl, N., 2013. Long-term earthquake prediction in western Anatolia with the time-and magnitude-predictable model. *Natural Hazards*, 66(2), 809-834. 10.1007/s11069-012-0532-7
- Schonlau, M., Zou, R. Y., 2020. The random forest algorithm for statistical learning. *The Stata Journal*, 20(1), 3-29.
- Sezer, L. İ., 2004. İzmir sismotektonik yöresinin depremselliği. *Ege Coğrafya Dergisi*, 13(1-2).
- Soman, K., Loganathan, R., Ajay, V. 2009. Machine learning with SVM and other kernel methods. PHI Learning Pvt. Ltd., New Delhi, 477s.
- Wang, K., Johnson, C. W., Bennett, K. C., Johnson, P. A., 2022. Predicting Future Laboratory Fault Friction Through Deep Learning Transformer Models. *Geophysical Research Letters*, 49(19),

e2022GL098233.

<https://doi.org/10.1029/2022GL098233>

Whitcomb, J. H., Garmany, J. D., Anderson, D. L., 1973. Earthquake Prediction: Variation of Seismic Velocities before the San Francisco Earthquake. *Science*, 180(4086), 632-635.
<https://doi.org/10.1126/science.180.4086.632>

Wiemer, S., Schorlemmer, D., 2007. ALM: An asperity-based likelihood model for California. *Seismological Research Letters*, 78(1), 134-140.