



Makine öğrenimi yöntemleri kullanılarak Türkiye'nin kuzeybatısı için deprem tahmini

Earthquake prediction for the northwest of Turkey with machine learning methods

AYHAN DOĞAN ^{1*} 

¹ Hacettepe Üniversitesi, Başkent OSB Teknik Bilimler Meslek Yüksek Okulu, Ankara, Türkiye

Geliş (received): 10 Haziran (June) 2023 Kabul (accepted): 15 Ağustos (August) 2023

ÖZ

Depremleri önceden tahmin edebilmek insan yaşamı ve konforu için önemli bir konu olmuştur. Ancak karmaşık bir mekanizmaya sahip olan depremler günümüz bilgi ve teknolojisi ile henüz tahmin edilememektedir. Geçmişte depremleri tahmin edebilmek için farklı yöntemler kullanılırken son zamanlarda yapay zeka yöntemlerindeki gelişmelerle birlikte, deprem tahminleri yapabilmek için bu yöntemler de kullanılmaya başlanmıştır. Bu çalışmada Türkiye'nin kuzeybatı bölgesinde gelecekte olma ihtimali bulunan, 6 ve üzeri büyüklükteki depremlerin odak koordinatları ve odak derinlikleri tahmin edilmeye çalışılmıştır. Bu çalışmada karşılaştırmalı olarak altı farklı makine öğrenimi yöntemi (Destek Vektör Makineleri, Gradient Boost, Elastic Net, Bayesian Ridge ve XGBoost) kullanılmış ve tahmin sonuçları karşılaştırılmıştır. Sonuçlar RMSE, MAE ve Düzeltilmiş R² performans metrikleriyle değerlendirilmiştir. Tahmin sonuçları gelecekte Türkiye'nin kuzeybatı bölgesinde Bursa ili sınırları içerisinde İznik Gölü'nün kuzeyinden başlayarak batıya doğru Ekinli, İmralı adasının kuzeybatısı, Avşa adasının kuzeyi ve Marmara adasının kuzeybatısında 6 ve üzerinde depremler olabileceğini göstermektedir.

Anahtar Kelimeler: Makine öğrenimi, Deprem tahmini, Türkiye'nin kuzeybatısı, Odak konumu, Odak derinliği

ABSTRACT

Being able to predict earthquakes has been an important issue for human life and comfort. However, earthquakes with complex mechanisms are quite difficult to predict. While different methods were used to predict earthquakes in the past, these methods have recently been used to make earthquake predictions with the developments in artificial intelligence methods. In this study, the focal coordinates and focal depths of earthquakes with a magnitude of 6 and above, likely to occur in the northwestern region of Turkey, were tried to be estimated. This study used six different machine learning methods (Support Vector Machines, Gradient Boost, Elastic Net, Bayesian Ridge and XGBoost) and compared the prediction results. Results were evaluated with RMSE, MAE, and Adjusted R² performance metrics. The estimation results show that earthquakes of 6 or more may occur in the future in the northwestern region of Turkey, within the borders of

Bursa province, starting from the north of Lake Iznik and going westwards in Ekinli, northwest of İmralı island, north of Avşa island and northwest of Marmara island.

Keywords: Machine learning, Earthquake prediction, Northwest of Turkey, Hypocenter location, Hypocenter depth

<https://doi.org/10.17824/yerbilimleri.1325321>

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

GİRİŞ

Depremler çok eski zamanlardan bu yana insan yaşamını etkileyen çok önemli doğal olaylardan biridir. Bazı araştırmacılar depremin önceden tahmin edilemeyeceğini söylerken (Geller vd., 1997), bazıları ise tahmin edilebilir bir olay olduğunu ileri sürmüşlerdir (Brehm ve Braile, 1998; Kirschvink, 2000; Knopoff, 2000). Geçmişten bu güne depremin tahmin edilebilmesi amacıyla çok çeşitli çalışmalar yapılmıştır. Önceleri hayvan davranışları ve diğer doğa olayları gözlemlenmiş ve bunlar anlamlandırılmaya çalışılmıştır (Rikitake, 1968; Barsukov vd., 1984; Kirschvink, 2000). Bilimsel gelişmelerle birlikte radon gazı ölçümleri, sismik ve elektromanyetik yöntemler başta olmak üzere çeşitli bilimsel yöntemler kullanılarak depremler önceden tahmin edilmeye çalışılmaktadır (Whitcomb vd., 1973; Zmazek vd., 2003; Kùlahcı vd., 2009; Moustra vd., 2011). Ancak şimdiye kadar yapılan çalışmalar genellikle depremi çok kısa süre öncesinde bazı belirtiler ortaya çıktıktan sonra olasılıklı olarak tahmin edebilmektedir (Hayakawa ve Hobara, 2010). Depremde P dalgası birincil dalga olduğundan deprem kayıt istasyonlarına ilk önce bu dalgalar ulaşır ve daha yıkıcı etkiye sahip olan S dalgası ise daha sonra ulaşır. Bu iki dalganın ilerleme hızı arasındaki kısa zaman farkı depremler için uyarı ve acil tedbir amaçlı kullanılabilir. Tüm bunlarla birlikte bilim insanları depremin zamanını, odak konumunu, derinliğini ve büyüklüğünü saatler, günler hatta haftalar öncesinden tahmin edebilmek için yoğun bir

çaba sarf etmektedirler (Marzocchi vd., 2017; Michael vd., 2020). Son yıllarda yapay zeka algoritmalarındaki gelişmeler birçok alanda olduğu gibi deprem tahmini konusunda da umut vermekte olup, çeşitli çalışmalar yapılmıştır. Alarifi vd. (2012) çalışmalarında kuzey Kızıldeniz bölgesinde yapay sinir ağı kullanılarak deprem büyüklüğü tahmini yapmışlardır. Panakkat ve Adeli (2007) çoklu deprem belirteci kullanarak deprem büyüklüğü tahmini için sinir ağı modelleri yapmışlar, Güney Kaliforniya ve San Francisco körfez bölgesi için bir ay sonra olabilecek depremin büyüklüğünü tahmin etmeye çalışmışlar, ancak sonuçlarda yüksek seviyede bir kesinlik bulunmadığını belirtmişlerdir. Kùlahcı vd. (2009) radon gazının değişimini izleyerek deprem tahmini için yapay sinir ağı modeli geliştirmişler ve bunu Doğu Anadolu Fay Sistemi'ndeki deprem tahmin sürecini modellemek için kullanmışlardır. Asencio-Cortés vd. (2017) yapay sinir ağları ile Tokyo'da büyüklüğü 5'in üzerindeki depremleri yedi günlük periyotta tahmin etmeye çalışmışlardır. Çalışmada Gutenberg – Richter yasasına ait parametrelerle birlikte bazı sismik parametreler kullanılmıştır. Sonuçlar en yakın komşular destek vektör makinesi, bayes ağları ve karar ağaçları yöntemleriyle karşılaştırılmış ve genel olarak bu yöntemlerden daha başarılı sonuçlar alındığı belirtilmiştir. Essam vd. (2021) Malezya için deprem tahmininde yapay sinir ağları (YSA) ve rastgele orman (RO) tekniklerinin güvenilirliğini

araştırmışlar, YSA yönteminin daha iyi tahmin performansı gösterdiğini belirtmişlerdir. Bhatia vd. (2023) yapay zeka tabanlı gerçek zamanlı deprem büyüklüğü tahmini için Uyarlanabilir Nöro-Bulanık Çıkarım Sistemi (ANFIS) yöntemini ve özellik sınıflaması için uç katmana iletilen gerçek zamanlı sensör verilerini elde etmek amacıyla da yeni bir Bayes yöntemi kullanmakla birlikte, sonuçların kesinlik, duyarlılık ve özgünlük değerlerinin oldukça iyi olduğunu belirtmişlerdir. Shiuly vd. (2020) yapay sinir ağı ve genetik algoritma kullanılarak Himalaya bölgesi için en yüksek yer ivmesini (PGA) tahmin etmişler, sonuçların diğer zayıflama ilişkileri ile tutarlı olduğunu söylemişlerdir. Bazı çalışmalar ise laboratuvar deneylerine odaklanmıştır. Bu çalışmalarda laboratuvar deneylerinden elde ettikleri verileri kullanarak çeşitli yapay zeka yöntemleriyle depreme kalan süreyi ve depremle ilgili diğer konuları tahmin etmeye çalışmışlardır (Rouet-Leduc vd., 2017; Wang vd., 2022). Can vd. (2014) Türkiye'nin kuzeybatısında bulunan Bilecik'teki deprem tehlikesini tahmin etmek için Poisson gizli Markov modelini kullanmışlardır. Bu model ile 2013 ile 2047 yılları arasında büyüklüğü $M \geq 4$ olabilecek depremlerin yıllık frekanslarını tahmin etmişlerdir.

Bu çalışmada makine öğrenimi yöntemleri kullanılarak Türkiye'nin kuzeybatı bölgesi için gelecekte olma ihtimali bulunan 6 ve üzeri büyüklükteki depremlerin odak koordinatları ve odak derinlikleri tahmin edilmektedir. Bu çalışmada diğer çalışmalardan farklı olarak, karşılaştırmalı olarak önceki çalışmalarda birlikte veya hiç kullanılmayan makine öğrenimi yöntemleri kullanılmakta, tahmin sonuçları karşılaştırılmakta ve Türkiye'nin kuzeybatı bölgesi için farklı deprem tahminleri sunulmaktadır.

MATERYAL VE METOT

Çalışma alanı

Çalışma alanı olarak Türkiye'nin en etkin sismik aktivitelerinin bulunduğu kuzeybatı

bölgesi seçilmiştir. Çalışma alanı 39.423 - 42.147 Güney-Kuzey enlemleri ile 25.631-32.448 Batı-Doğu boylamları arasında yer almaktadır. Harita üzerindeki kırmızı çerçeve içerisinde kalan alan çalışma alanını göstermektedir (Şeki11). Bu bölge sismik olarak aktif olan ve büyük depremler üretebilen Kuzey Anadolu Fay Zonu (KAFZ) ve diğer bölgesel faylar üzerinde bulunmaktadır (Şeki12).

Veri

Çalışma alanı içerisinde 01.01.1900 ile 08.07.2023 tarihleri arasında meydana gelen 3 ve üzeri büyüklükteki depremlere ait katalog bilgileri Amerika Birleşik Devletleri Jeoloji Araştırmaları Kurumu (USGS) web sitesinden alınmıştır (USGS, 2023). Belirtilen büyüklük ve tarihler arasında toplam 2240 deprem verisi bulunmaktadır. Tüm veriler aletsel ölçümlere dayanmaktadır ve deprem oluş zamanı, deprem odak koordinatlarına ait enlem ve boylam, odak derinliği ve deprem büyüklüğü bilgilerini içermektedir. Kullanılan deprem verilerinin sıklığını gösteren histogram Şeki31 'te verilmektedir. 1970'li yıllardan itibaren deprem sayısında önemli bir artış görülmektedir. Bu artışın nedenleri arasında deprem kayıt istasyonlarının sayısındaki artışın da etkili olduğu düşünülmektedir. Bir diğer dikkat çeken durum ise 1990 ile 2010 yılları arasında deprem sayısındaki yüksek artışın, bu yıllardan sonra görece azalmasıdır. Çalışmada kullanılan deprem katalog bilgileri incelendiğinde Çizelge 1'de verilen değerler elde edilmektedir. Bu veriler ışığında, 1900-1970 yılları arasındaki yetmiş yıllık dönemde $M \geq 5$ ve üzeri büyüklükte deprem sayısı yıllık ortalama 0.99, 1971-1990 yılları arasındaki dönemde ortalama yıllık deprem sayısı 0.6, 1991-2010 yılları arasındaki dönemde ortalama yıllık deprem sayısı 1.1, 2011-2023 yılları arasındaki dönemde ortalama yıllık deprem sayısı 0.69'dur. Çalışma alanı içerisinde 1900 yılından bu yana USGS verilerine göre büyüklüğü 6 ve üzeri olan yirmi deprem meydana gelmiştir.

Bunlardan altı tanesinin büyüklüğü 7 ve üzeri olan 1912 Malkara ($M_w=7.23$), 1953 Gönen ($M_w=7.3$), 1957 Düzce ($M_w=7.09$), 1967 Hendek ($M_w=7.29$), 1999 Gölcük ($M_w=7.6$), 1999 Düzce ($M_w=7.2$) depremleridir.

Yöntem

Bu çalışmada USGS web sitesinden alınan

deprem verileriyle yapay zekanın alt bir dalı olan makine öğrenimi yöntemleri kullanılarak tahminler gerçekleştirilmiştir. Makine öğrenimi işlemleri gerçekleştirilirken verinin %70'i eğitim, %30'u test amacıyla kullanılmıştır. Yapılan tüm eğitim ve testlerin başarı ölçütü olarak performans değerlendirme metrikleri (RMSE, MAE, Düzeltilmiş R^2) kullanılmıştır.



Şekil 1. Çalışma alanı

Figure 1. Study area

Çizelge 1. Yıllara göre deprem büyüklük değerlerine göre deprem sayıları

Table 1. Number of earthquakes according to earthquake magnitude values by years

Deprem büyüklük değerlerine göre deprem sayıları		
Yıl aralığı	$M \geq 5$ ve üzeri	$M \geq 6$ ve üzeri
1900-1970	69	15
1971-1990	12	2
1991-2010	22	2
2011-2023	9	1

Makine öğrenimi yöntemi olarak; Destek Vektör Makineleri (DVM), Gradient Boost (GB), Elastic Net (EN), Bayesian Ridge (BR), XGBoost (XGB) yöntemleri kullanılmıştır. Makine öğrenimi modeli için deprem oluş tarihi, saati, enlem, boylam, derinlik ve büyüklük bilgileri kullanılmıştır. Tüm makine öğrenimi yöntemlerinin model eğitimleri ve testleri aynı veri alanlarıyla gerçekleştirilmiştir. Tahminler 6 ve üzeri deprem büyüklüğü için yapılmıştır. Tahminler sonucunda odak koordinatlarına ait enlem ve boylam değerleri ile odak derinlikleri elde edilmiştir.

Destek Vektör Makineleri

DVM ilk kez 1995 yılında ortaya atılmıştır (Cortes ve Vapnik, 1995). Bu yöntemde veriler birbirinden bir hiper düzlem ile ayrılır. Bu işlem, veri noktalarını iki sınıf arasında bir çizgi ile ayırmak şeklinde gerçekleştirilir. DVM

aykırı değerlere karşı dirençli bir yöntemdir. Özellikle vektörlerinde aykırı değerleri bulur ve sınıflandırmayı etkilemeyecek şekilde bu aykırı değerleri yok sayar. Bu yöntem sınıflandırma ve regresyon problemlerinde başarıyla kullanılmaktadır (Soman vd., 2009).



Şekil 2. Çalışma alanı ve yakınındaki fay segmentleri (MTA, 2023)


Figure 2. Fault segments in the study area and nearby (MTA, 2023)

Gradient Boost

Gradyan artırma yöntemleri çeşitli pratik uygulamalarda önemli başarı göstermiş güçlü makine öğrenimi tekniklerindedir. Bu yöntemde öğrenme işlemleri, yanıt değişkeninin daha doğru bir tahminini elde etmek için ardışık olarak yeni modeller kullanır. Bu yöntemde temel fikir, yeni temel öğrencileri, tüm toplulukla ilişkili kayıp fonksiyonunun negatif gradyanı ile maksimum düzeyde ilişkilendirilecek şekilde oluşturmaktır. Yöntemde, kayıp fonksiyonu seçilebilir ve bu esneklik model tasarımına önemli düzeyde özgürlük sağlar (Natekin ve Knoll, 2013). GB, hem pratik uygulamalarda, hem de çeşitli makine öğrenimi ve veri madenciliği işlerinde başarı ile uygulanmaktadır (Pittman ve Brown, 2011).

Elastic Net

EN, regresyon modellerini düzenli hale getirmek için lasso ve ridge tekniklerinden gelen cezaları kullanır. Bu yöntem, istatistiksel modellerin daha iyi düzenlenmesi için eksikliklerinden öğrenerek lasso ve ridge tekniklerini birleştirir. EN yönteminin tahmin edicisini bulma prosedüründe, lasso ve regresyon tekniklerini içeren iki aşama vardır. Önce ridge regresyon katsayıları bulunur, ardından katsayıların bir lasso türü büzülmesi kullanılarak ikinci adım gerçekleştirilir. EN yöntemi, değişken seçimi ve düzenlemeyi aynı anda gerçekleştirir. Boyutsal verilerin kullanılan örnek sayısından fazla olduğu durumlarda en uygundur. Gruplamalar ve değişken seçimi, bu tekniğin kilit rolleridir (Zou ve Hastie, 2005; Owen, 2007; De Mol vd., 2009).



Şekil 3. $M \geq 3$ için deprem sıklığı histogramı

Figure 3. Histogram of earthquakes frequency for $M \geq 3$

Bayesian Ridge

BR, nokta tahminleri yerine olasılık dağıtıcıları kullanarak doğrusal regresyon formüle ederek, doğal bir mekanizmanın yetersiz verilerden veya kötü dağıtılmış verilerden kurtulmasını sağlar. Çıktı veya yanıtın, tek bir değer olarak tahmin edilmek yerine bir olasılık dağılımından alındığı varsayılır. Matematiksel olarak, tamamen olasılıksal bir model elde etmek için, yanıtın Gauss dağılımı olduğu varsayılır (Horel, 1962; Hoerl ve Kennard, 1970; Shi vd., 2016). Bu yöntemin hiyerarşik veri yapısıyla başa çıkma kabiliyeti yüksektir (Huang ve Abdel-Aty, 2010).

XGBoost

XGB, en popüler artırma ağacı algoritmalarından biridir. Problem çözmedeki yüksek performansı ve özellik mühendisliği için minimum gereksinimleri nedeniyle yaygın olarak kullanılmaktadır (Möller vd., 2016;

Tamayo vd., 2016). Bu yöntem derin öğrenme algoritmalarıyla karşılaştırıldığında, XGB işlemci üzerinde çalışan küçük veri kümeleri için kullanımının daha kolay olduğu kabul edilmektedir. XGB'un üstünlüğü, ağaç oluşturmaya yönelik güvenilir amaç işlevinde saklıdır. Ayrıca, maksimum derinlik ve bölme eşiği gibi çeşitli etkili parametrelere hizmet eder. XGB iki aşırı uydurmadan kaçınma stratejisi uygular: büzülme ve sütun alt örnekleme. Büzülme, bir ağacın model üzerindeki etkisinin çok büyük olmamasını ve sonraki ağaçlar için daha fazla alan sağlamasını sağlamak için tüm yaprakların puanlarının her yinelemede bir büzülme ağırlığını ile çarpacağını belirtir. Sütun alt örnekleme, rastgele ormanla aynı şekilde, özneliklerin yalnızca bir kısmıyla bir ağaç oluşturmaya olanak tanır (Chen ve Guestrin, 2016; Dong vd., 2020; Song vd., 2020).

BULGULAR

Türkiye'nin kuzeybatısında seçilen çalışma alanına ait 1900-2023 yılları arasındaki büyüklüğü 3 ve üzeri olan depremlere ait katalog bilgileri kullanılarak, gelecekte olabilecek büyük depremlere ait deprem odak konumu ve derinliği tahmin edilmeye çalışılmıştır. Bu tahminleri yapabilmek için altı farklı makine öğrenme yöntemi kullanılmıştır. Önce eğitimler gerçekleştirilmiş, sonra eğitilen modeller kullanılarak testler gerçekleştirilmiştir.

Çalışma alanında gelecekte olması muhtemel depremler 6 ve üzeri büyüklükte (Mw) dikkate alınarak tahmin edilmeye çalışılmıştır. Yapılan çalışmalar sonucunda olası depremler için elde edilen tahmin sonuçları Çizelge 2'de verilmektedir. Bu tahmin sonuçlarının harita üzerindeki konumları Şekil 4'te gösterilmektedir. Şekil 4'te harita üzerinde görüldüğü gibi büyüklüğü 6 ve üzeri olabilecek deprem tahminlerinin konumları,

aktif fay segmentleri üzerinde veya KAFZ yakınındadır.

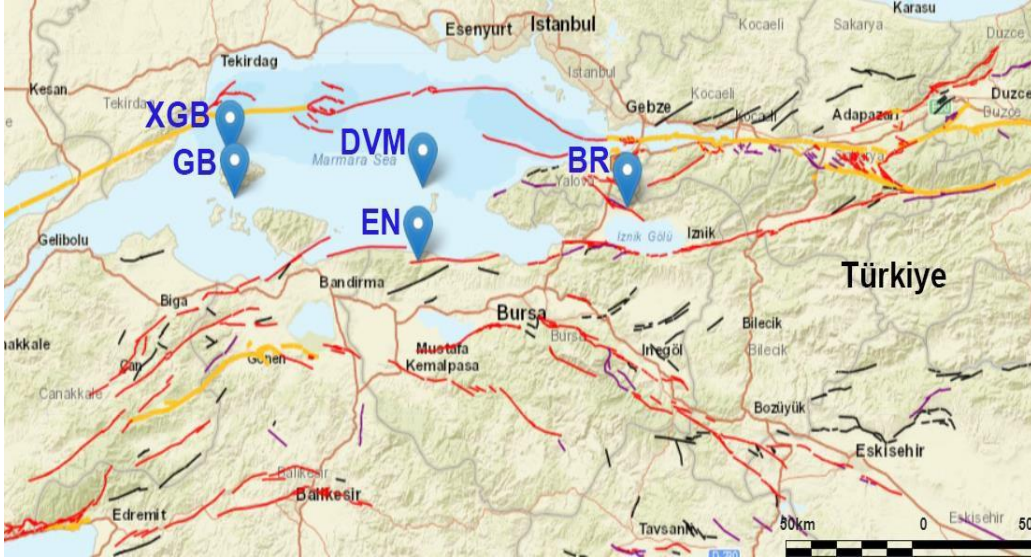
BR ve EN yöntemlerinden elde edilen tahminlere ait koordinatlar fay segmentleri üzerindedir. XGB ve GB yönteminden elde edilen sonuçlar KAFZ'nun Marmara denizi içerisinden geçen kısmına oldukça yakındır. DVM yönteminden elde edilen sonuç ise Marmara denizi ortasında İmralı adası yakınındadır. Depremlerin faylanmalardan kaynaklandığı hipotezi çok uzun süredir kabul görmektedir (Evison, 1963). Bu hipoteze göre çalışmada bulunan tahmin sonuçlarının fay segmentlerine yakın olması sonuçların doğruluğuna katkı sağlamaktadır. Bununla birlikte bazı tahmin sonuçları sismik boşluklara da işaret ediyor olabilir (McCann vd., 1979).

Deprem büyüklüğü 6 ve üzeri olabilecek depremler için elde edilen tahmin sonuçlarına ait performans metrikleri Çizelge 3'de verilmektedir.

Çizelge 2. Büyüklüğü 6 ve üzeri olan deprem tahmin sonuçları

Table 2. Earthquake prediction results with magnitude 6 and above

Makine Öğrenimi Yöntemi	Odak		
	Enlem	Boylam	Derinlik (km)
DVM	40.55442646	28.42908374	14.71953054
GB	40.5427408	27.60509308	13.52770139
EN	40.36743171	28.48630377	12.69927881
BR	40.54068591	29.46539747	16.3778283
XGB	40.658737	27.550915	10.055244



Şekil 4. Büyüklüğü 6 ve üzeri olabilecek depremlerin farklı makine öğrenim yöntemlerinden elde edilen tahmin sonuçları (Mavi renkli yer işaretleri: DVM, GB, EN, BR, XGB)

Figure 4. Prediction results from different machine learning methods for earthquakes of magnitude 6 and above (Blue landmarks: DVM, GB, EN, BR, XGB)

TARTIŞMA ve SONUÇ

Depremleri önceden tahmin edebilmek can kaybını azaltmak için çok önemlidir. Bu nedenle geçmişten günümüze çeşitli bilimsel çalışmalar yapılmıştır. Yapay zeka yöntemleri ve onun alt dalı olan makine öğrenimi de son zamanlarda daha çok kullanılmaya başlanan yeni tahmin araçlarıdır. Deprem mekanizmasının karmaşık olması deprem tahminlerini çok zorlaştırmaktadır. Makine öğrenimi yöntemleri bu karmaşık mekanizmayı çok sayıda deprem verisini birlikte kullanarak günümüz bilgisayar teknolojisinin de yardımıyla daha tahmin edilebilir hale getirmektedir.

Bu çalışmadan elde edilen sonuçlar incelendiğinde, farklı performans metriklerine

göre tahmin başarıları değişmekle birlikte başarı oranları arasında büyük farklılıklar yoktur. RMSE metriğine göre enlem tahmin başarıları tüm yöntemlerde 0.50-0.54 aralığında, boylam tahmin başarıları 2.09-2.14 aralığında, derinlik tahmin başarıları ise 9.55-9.85 aralığındadır. MAE metriğine göre enlem tahmin başarıları tüm yöntemlerde 0.39-0.41 aralığında, boylam tahmin başarıları 1.86-1.94 aralığında, derinlik tahmin başarıları ise 6.56-7.01 aralığındadır. Düzeltilmiş R^2 metriğine göre enlem tahmin başarıları tüm yöntemlerde 0.04-0.21 aralığında, boylam tahmin başarıları 0.61-0.69 aralığında, derinlik tahmin başarıları ise 0.08-0.15 aralığındadır. DVM ve EN yöntemi ile GB ve XGB yönteminden elde edilen odak koordinatları görece olarak birbirine yakındır.

Çizelge 3. Büyüklüğü 6 ve üzeri olabilecek depremlerin farklı makine öğrenim yöntemlerinden elde edilen tahmin sonuçlarına ait performans metrikleri

Table 3. Performance metrics of estimation results obtained from different machine learning methods of earthquakes with magnitude 6 and above

		DVM	GB	EN	BR	XGB
RMSE	Enlem	0.54	0.51	0.51	0.50	0.51
	Boylam	2.09	2.12	2.13	2.09	2.14
	Derinlik	9.82	9.81	9.55	9.77	9.85
MAE	Enlem	0.41	0.40	0.39	0.39	0.40
	Boylam	1.86	1.92	1.94	1.90	1.93
	Derinlik	6.56	6.97	6.72	6.88	7.01
Düzeltilmiş R ²	Enlem	0.21	0.05	0.05	0.04	0.05
	Boylam	0.61	0.66	0.67	0.61	0.69
	Derinlik	0.14	0.14	0.08	0.13	0.15

Olası depremlerin odak derinlik tahminleri yaklaşık 10.05-16.42 km arasında değişmektedir. Tüm esnek hesaplama yöntemlerinde olduğu gibi bu çalışmada bulunan tahmin değerleri, performans metrik değerlerinden de anlaşılacağı gibi belirli bir güven aralığında değişkenlik göstermektedir. Bununla birlikte sonuçlar yöneticiler ve planlayıcılar açısından gerekli tedbirlerin alınması için önemli bilgiler sunmaktadır. Zaman içerisinde deprem katalog bilgilerinin artmasıyla tahmin başarı oranlarının yükselmesi de beklenen bir durumdur.

Makine öğrenimi tahmin sonuçları birlikte değerlendirildiğinde deprem olma ihtimali olan yerler, Türkiye'nin kuzeybatı bölgesinde Bursa ili sınırları içerisinde İznik Gölü'nün kuzeyinden

başlayarak batıya doğru Marmara adasının kuzeybatısına kadar yaklaşık 170 km'lik bir hat üzerinde odaklanmaktadır. Daha önce farklı yöntemler kullanılarak yapılan başka çalışmalarda da Marmara denizinde büyük bir deprem beklentisi olduğu bazı araştırmacılar tarafından dile getirilmiştir. Bu çalışmanın sonuçları da gelecekte Marmara denizi kıyılarında veya içerisinde 6 ve üzeri büyük depremler olabileceği ihtimalini güçlendirmektedir. Tüm bunların yanı sıra deprem mekanizmasının karmaşık yapısı itibarıyla çok sayıda parametreye bağlı olduğu ve bu parametrelere ait tüm verinin elimizde bulunmadığı da unutulmamalıdır. Bu çalışmada sunulan tahmin sonuçları kullanılan deprem katalog bilgileriyle sınırlıdır. Aletsel

dönem öncesine ait veriler çok sınırlıdır ve bu çalışmada kullanılmamıştır. Depremlerin meydana gelme olasılıkları ve bunların dönüş periyotları farklı olduğundan deprem katalog verilerinin artması ve depremle ilişkili başka verilerin yada özelliklerin de kullanımıyla ileride daha doğru tahminler yapmak mümkün olabilecektir.

KATKI BELİRTME

Yazar yapıcı eleştirileri için hakemlere teşekkür eder.

KAYNAKLAR

- Alarifi, A. S. N., Alarifi, N. S. N., Al-Humidan, S., 2012. Earthquakes magnitude predication using artificial neural network in northern Red Sea area. *Journal of King Saud University - Science*, 24(4), 301-313. <https://doi.org/10.1016/j.jksus.2011.05.002>
- 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>
- 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>
- Bhatia, M., Ahanger, T. A., Manocha, A., 2023. Artificial intelligence based real-time earthquake prediction. *Engineering Applications of Artificial Intelligence*, 120, 105856. <https://doi.org/10.1016/j.engappai.2023.105856>
- Brehm, D. J., Braille, L. W., 1998. Intermediate-term earthquake prediction using precursory events in the New Madrid seismic zone. *Bulletin of the Seismological Society of America*, 88(2), 564-580.
- Can, C., Ergun, G., Gokceoglu, C., 2014. Prediction of earthquake hazard by hidden Markov model (around Bilecik, NW Turkey). *Open Geosciences*, 6(3), 403-414. [doi:10.2478/s13533-012-0180-1](https://doi.org/10.2478/s13533-012-0180-1)
- Chen, T., Guestrin, C. 2016. Xgboost: A scalable tree boosting system, *Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining*, 13-17 August, San Francisco California, 785-794.
- Cortes, C., Vapnik, V., 1995. Support-vector networks. *Machine Learning*, 20(3), 273-297. <https://doi.org/10.1007/BF00994018>
- De Mol, C., De Vito, E., Rosasco, L., 2009. Elastic-net regularization in learning theory. *Journal of Complexity*, 25(2), 201-230. <https://doi.org/10.1016/j.jco.2009.01.002>
- Dong, W., Huang, Y., Lehane, B., Ma, G., 2020. XGBoost algorithm-based prediction of concrete electrical resistivity for structural health monitoring. *Automation in Construction*, 114, 103155. <https://doi.org/10.1016/j.autcon.2020.103155>
- 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>
- Evison, F., 1963. Earthquakes and faults. *Bulletin of the Seismological Society of America*, 53(5), 873-891.
- Geller, R. J., Jackson, D. D., Kagan, Y. Y., Mulargia, F., 1997. Earthquakes cannot

- be predicted. *Science*, 275(5306), 1616-1616.
- 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>
- Hoerl, A. E.,Kennard, R. W., 1970. Ridge regression: Biased estimation for nonorthogonal problems. *Technometrics*, 12(1), 55-67.
- Horel, A., 1962. Application of ridge analysis to regression problems. *Chemical Engineering Progress*, 58, 54-59.
- Huang, H.,Abdel-Aty, M., 2010. Multilevel data and Bayesian analysis in traffic safety. *Accident Analysis & Prevention*, 42(6), 1556-1565.
- Kirschvink, J. L., 2000. Earthquake prediction by animals: Evolution and sensory perception. *Bulletin of the Seismological Society of America*, 90(2), 312-323.
- Knopoff, L., 2000. The magnitude distribution of declustered earthquakes in Southern California. *Proceedings of the National Academy of Sciences*, 97(22), 11880-11884.
<https://doi.org/10.1073/pnas.190241297>
- Külahcı, F., İnceöz, M., Doğru, M., Aksoy, E.,Baykara, O., 2009. Artificial neural network model for earthquake prediction with radon monitoring. *Applied Radiation and Isotopes*, 67(1), 212-219.
<https://doi.org/10.1016/j.apradiso.2008.08.003>
- Luu, Q.-H., Lau, M. F., Ng, S. P.,Chen, T. Y., 2021. Testing multiple linear regression systems with metamorphic testing. *Journal of Systems and Software*, 182, 111062.
<https://doi.org/10.1016/j.jss.2021.111062>
- Marzocchi, W., Taroni, M.,Falcone, G., 2017. Earthquake forecasting during the complex Amatrice-Norcia seismic sequence. *Science Advances*, 3(9), e1701239.
<https://doi.org/10.1126/sciadv.1701239>
- McCann, W. R., Nishenko, S. P., Sykes, L. R.,Krause, J., 1979. Seismic gaps and plate tectonics: Seismic potential for major boundaries. *pure and applied geophysics*, 117(6), 1082-1147. 10.1007/BF00876211
- 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>
- Montgomery, D. C., Peck, E. A.,Vining, G. G. 2021. *Introduction to linear regression analysis*. John Wiley & Sons, USA, 688s.
- 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>
- Möller, A., Ruhlmann-Kleider, V., Leloup, C., Neveu, J., Palanque-Delabrouille, N., Rich, J., Carlberg, R., Lidman, C.,Pritchett, C., 2016. Photometric classification of type Ia supernovae in the SuperNova Legacy Survey with supervised learning. *Journal of Cosmology and Astroparticle Physics*, 2016(12), 008.
<https://doi.org/10.1088/1475-7516/2016/12/008>

- MTA. 2023. Geosciences Map Viewer. <http://yerbilimleri.mta.gov.tr/anasayfa.aspx> (Erişim Tarihi: 10.07.2023).
- Natekin, A., Knoll, A., 2013. Gradient boosting machines, a tutorial. *Frontiers in neurorobotics*, 7, 21. <https://doi.org/10.3389/fnbot.2013.00021>
- Owen, A. B. 2007. A robust hybrid of lasso and ridge regression. ss 59-72. Joseph S. Verducci, Xiaotong Shen and Lafferty, J., ed. 2007. *Contemporary Mathematics*, 226s.
- Panakkat, A., Adeli, H., 2007. Neural network models for earthquake magnitude prediction using multiple seismicity indicators. *International journal of neural systems*, 17(01), 13-33. <https://doi.org/10.1142/S0129065707000890>
- Pittman, S. J., Brown, K. A., 2011. Multi-scale approach for predicting fish species distributions across coral reef seascapes. *PloS one*, 6(5), e20583. <https://doi.org/10.1371/journal.pone.0020583>
- Ricciardi, C., Ponsiglione, A. M., Scala, A., Borrelli, A., Misasi, M., Romano, G., Russo, G., Triassi, M., Improta, G., 2022. Machine learning and regression analysis to model the length of hospital stay in patients with femur fracture. *Bioengineering*, 9(4), 172. <https://doi.org/10.3390/bioengineering9040172>
- 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>
- Shi, Q., Abdel-Aty, M., Lee, J., 2016. A Bayesian ridge regression analysis of congestion's impact on urban expressway safety. *Accident Analysis & Prevention*, 88, 124-137. <https://doi.org/10.1016/j.aap.2015.12.001>
- Shiuly, A., Roy, N., Sahu, R. B., 2020. Prediction of peak ground acceleration for Himalayan region using artificial neural network and genetic algorithm. *Arabian Journal of Geosciences*, 13(5), 215. <https://doi.org/10.1007/s12517-020-5211-5>
- Soman, K., Loganathan, R., Ajay, V. 2009. Machine learning with SVM and other kernel methods. PHI Learning Pvt. Ltd., New Delhi, 477s.
- Song, K., Yan, F., Ding, T., Gao, L., Lu, S., 2020. A steel property optimization model based on the XGBoost algorithm and improved PSO. *Computational Materials Science*, 174, 109472. <https://doi.org/10.1016/j.commatsci.2019.109472>
- Tamayo, D., Silburt, A., Valencia, D., Menou, K., Ali-Dib, M., Petrovich, C., Huang, C. X., Rein, H., Van Laerhoven, C., Paradise, A., 2016. A machine learns to predict the stability of tightly packed planetary systems. *The Astrophysical Journal Letters*, 832(2), L22. <https://doi.org/10.3847/2041-8205/832/2/L22>
- USGS. 2023. Search Earthquake Catalog,. <https://earthquake.usgs.gov/earthquakes/search> (Erişim Tarihi: 08.07.2023).
- 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(12), e2022GL099888. <https://doi.org/10.1029/2022GL099888>

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>

Zmazek, B., Todorovski, L., Džeroski, S., Vaupotič, J., Kobal, I., 2003. Application of decision trees to the analysis of soil radon data for earthquake prediction. *Applied Radiation and Isotopes*, 58(6), 697-706.
[https://doi.org/10.1016/S0969-8043\(03\)00094-0](https://doi.org/10.1016/S0969-8043(03)00094-0)

Zou, H., Hastie, T., 2005. Regularization and variable selection via the elastic net. *Journal of the Royal Statistical Society Series B: Statistical Methodology*, 67(2), 301-320. <https://doi.org/10.1111/j.1467-9868.2005.00503.x>