

The Effectiveness of Machine Learning Algorithms in Identifying P and S Phases of Earthquakes in Türkiye

Utku Unal¹ , Tolga Bekler^{2,3} , Feyza Nur Bekler⁴

¹ Çanakkale Onsekiz Mart University, School of Graduate Studies, Department of Geophysical Engineering, 34000 Çanakkale, Türkiye

² Çanakkale Onsekiz Mart University, Faculty of Engineering, Department of Geophysical Engineering, 34000 Çanakkale, Türkiye

³ Çanakkale Onsekiz Mart University, Earthquake Research Center, 34000 Çanakkale, Türkiye

⁴ Çanakkale Onsekiz Mart University, Faculty of Health Sciences, Department of Disaster and Emergency Management Administration, 34000 Çanakkale, Türkiye

Keywords

Machine Learning, Phase picking, Türkiye earthquakes,

Highlights

- * Machine Learning
- * Accurate detection of P and S phases
- * Effective use of seismic networks

Aim

This study explores effectiveness of machine learning algorithms in identifying P and S phases in Türkiye Earthquake Data

Location

This study has implemented using KOERI (Kandilli Observatory & Earthquake Research Institute) seismic network earthquake catalogues

Methods

PhaseNet Machine Learning (ML), autoregressive Akaike information criteria

Results

ML algorithm appears to perform better than traditional statistical methods

Supporting Institutions

The author(s) declared that this study has used data from KOERI

Financial Disclosure

The author(s) declared that this study was supported by Çanakkale Onsekiz Mart University with project code FBA-2024-4926

Peer-review

Externally peer-reviewed

Conflict of Interest

The authors have no conflicts of interest to declare

How to cite:

Unal U., Bekler T., Bekler F.N., 2025. The Effectiveness of Machine Learning Algorithms in Identifying P and S Phases of Earthquakes in Türkiye, Turk Deprem Arastirma Dergisi 7(1), 90-100, DOI:10.46464/tdad.1597618.

Manuscript

Research Article

Received: 07.12.2024

Revised: 28.01.2025

Accepted: 04.02.2025

Printed: 30.04.2025

DOI

10.46464/tdad.1597618

Corresponding Author

Utku Unal

Email: utku.unal@outlook.com



Content of this journal is licensed under a Creative Commons Attribution 4.0 International Non-Commercial License




Figure
Successful PhaseNet picks shown in comparison to handpicks

Makine Öğrenmesi Algoritmalarının Türkiye Depremlerinde P ve S Fazlarının Belirlenmesindeki Etkinliği

Utku Ünal ¹ , Tolga Bekler ^{2,3} , Feyza Nur Bekler ⁴ 

¹ Çanakkale Onsekiz Mart Üniversitesi, Lisansüstü Eğitim Enstitüsü, Jeofizik Mühendisliği Bölümü, 34000 Çanakkale, Türkiye

² Çanakkale Onsekiz Mart Üniversitesi, Mühendislik Fakültesi, Jeofizik Mühendisliği Bölümü, 34000 Çanakkale, Türkiye

³ Çanakkale Onsekiz Mart Üniversitesi, Deprem Araştırma Uygulama ve Araştırma Merkezi, 34000 Çanakkale, Türkiye

⁴ Çanakkale Onsekiz Mart Üniversitesi, Sağlık Bilimleri Fakültesi, Acil Yardım ve Afet Yönetimi Bölümü, 34000 Çanakkale, Türkiye

ÖZET

Depremlerin dinamik parametrelerinin belirlenmesine yönelik analizlerde sismik cisim dalgalarının (P ve S fazları) varış zamanlarının doğru tespiti, sismolojik problemlerin çözümünde bir ön koşuldur ve varış zamanlarını temel alan çalışmalara, örneğin yer içi kabuk/manto yapısının anlaşılması gibi ve çeşitli araştırma alanlarına katkıda bulunur. Makine öğrenimi veya daha geniş ve bilinen uygulaması ile yapay zekâ teknolojilerindeki son gelişmeler, sismogramlar kullanılarak cisim dalgalarının varış zamanlarının otomatik olarak tespit edilmesini mümkün kılmaktadır. Türkiye, Avrasya, Afrika ve Arap levhalarının kesişim noktasında yer aldığı için karmaşık tektonik yapısı nedeniyle yüksek sismik aktiviteye sahiptir. Bu çalışmada, KRDAE (Kandilli Rasathanesi ve Deprem Araştırma Enstitüsü) ağına ait 2013-2019 yılları arasındaki Türkiye'de meydana gelen deprem kayıtlarında P ve S fazlarının geliş zamanlarını otomatik olarak tespit eden derin öğrenme algoritmasının başarımlarını değerlendirilmiştir. Sonuçlar, makine öğrenmesinin geleneksel istatistiksel yöntemlere kıyasla daha doğru tahminler yapabildiğini ve insan kaynaklı hataların azaltılmasında etkili olduğunu göstermektedir. Çalışmada elde edilen bulgular, büyük veri tabanlarıyla eğitilmiş derin öğrenme tabanlı sismik faz tespit algoritmalarının, yerel ihtiyaçlara uygun hale getirilmesiyle sismolojik analizlerde doğruluk ve hız artışı sağlayabileceğini ortaya koymaktadır. Gelecekteki çalışmalarda, yerel veriyle de eğitilmiş modellerin karşılaştırmalı olarak incelenmesi ve faz tespitinde uzman müdahalesine ihtiyaç duymayan algoritmaların geliştirilmesi önerilmektedir.

Anahtar Kelimeler

Makine Öğrenmesi, Faz okuması, Türkiye depremleri

Öne Çıkanlar

- * Makine Öğrenmesi
- * P ve S fazı doğru tespiti
- * Sismik ağların etkili kullanımı

Makale

Araştırma Makalesi

Geliş: 07.12.2024

Düzeltilme: 28.01.2025

Kabul: 04.02.2025

Basım: 30.04.2025

DOI

10.46464/tdad.1597618

Sorumlu yazar

Utku Ünal

E-posta:

utku.unal@outlook.com

The Effectiveness of Machine Learning Algorithms in Identifying P and S Phases of Earthquakes in Türkiye

Utku Unal ¹ , Tolga Bekler ^{2,3} , Feyza Nur Bekler ⁴ 

¹ Çanakkale Onsekiz Mart University, School of Graduate Studies, Department of Geophysical Engineering, 34000 Çanakkale, Türkiye

² Çanakkale Onsekiz Mart University, Faculty of Engineering, Department of Geophysical Engineering, 34000 Çanakkale, Türkiye

³ Çanakkale Onsekiz Mart University, Earthquake Research Center, 34000 Çanakkale, Türkiye

⁴ Çanakkale Onsekiz Mart University, Faculty of Health Sciences, Department of Disaster and Emergency Management Administration, 34000 Çanakkale, Türkiye

ABSTRACT

In analyses aimed at determining the dynamic parameters of earthquakes, the accurate detection of the arrival times of primary seismic waves (P and S waves) is a fundamental prerequisite for solving seismological problems. Studies based on these arrival times contribute to various research areas, such as understanding the Earth's crust and mantle structure. Recent developments in machine learning—or more broadly and commonly known as artificial intelligence technologies—have made it possible to automatically detect earthquake waves from waveform data. Due to its complex tectonic structure, Türkiye has high seismic activity, as it is located at the intersection point of the Eurasian, African, and Arabian plates. In this study, the performance of a deep learning algorithm that automatically detects the arrival times of P and S phases in earthquakes occurred in Türkiye from 2013 to 2019 belonging to KOERI (Kandilli Observatory and Earthquake Research Institute) network was evaluated. The results show that machine learning can make more accurate predictions compared to traditional statistical methods and is effective in reducing human-induced errors. The findings of the study reveal that deep learning-based seismic phase detection algorithms trained with large databases can provide increased accuracy and speed in seismological analyses when adapted to local needs. It is recommended that future studies conduct comparative examinations of models also trained with local data and develop algorithms that do not require human intervention in phase detection.

Keywords

Machine Learning, Phase Picking, Türkiye earthquakes

Highlights

- * Machine Learning
- * Accurate detection of P and S phases
- * Effective use of seismic networks

Manuscript

Research Article

Received: 07.12.2024

Revised: 28.01.2025

Accepted: 04.02.2025

Printed: 30.04.2025

DOI

10.46464/tdad.1597618

Corresponding Author

Utku Unal

Email:

utku.unal@outlook.com

1. GİRİŞ

Depremlerin dinamik parametrelerinin analizinde, temel cisim dalgalarının varış zamanlarının hassas tespiti, sismolojik problemlerin çözümünde kritik bir gerekliliktir. Bu varış zamanlarına dayalı çalışmalar, başta kabuk olmak üzere yeriçi yapısının anlaşılması amaçlı çeşitli araştırmalara önemli katkılar sağlamaktadır. Son dönemde yapay zekâ ve makine öğrenimi teknolojilerindeki gelişmeler, dalga şekli verisinden, deprem dalgalarının otomatik tespitini mümkün kılarak bu alanda yeni ve etkin çözüm önerileri sunmaktadır.

Sismik alıcıların sayısına bağlı veri boyutunun artması, analizi yapan kişinin (Genellikle sismoloji alanında çalışan uzmanların) depremin izlenmesi için temel öneme sahip bir aşama olan sismik fazları elle ve kapsamlı bir şekilde tespit etmesini giderek zorlaştırmaktadır. Otomatik faz seçiminde yıllar süren gelişmelere rağmen, deneyimli uzmanların başarımını yakalamak zordur. Daha hassas bir konu olarak, sismoloji uzmanları arasında fazların farklı şekilde değerlendirmesi yorumlamada farklılıklara neden olmanın yanında, depremin yeri/derinliği ile ilgili yatay ve düşey konumlama hatalarına da neden olabilir. Bu tektonizma ile uyumsuz bir görünümün ortaya çıkması ile sonuçlanabilir.

Son yıllarda, makine öğrenmesi ve özellikle derin öğrenme yöntemleri, sismik verilerin analizinde hata payını azaltmak, P ve S fazlarının doğru tespitini hızlandırmak amacıyla tercih edilmektedir (Perol ve diğ. 2018, Ross ve diğ. 2018, Zhu ve Beroza 2019) Örneğin, Ross ve diğ. (2018) derin öğrenme tabanlı bir yöntemle genel sismik faz tespiti gerçekleştirmiş ve geleneksel yöntemlere göre daha yüksek doğruluk elde etmişlerdir. Perol ve diğ. (2018), konvolüsyonel sinir ağları (Convolutional Neural Network, CNN) kullanarak deprem tespiti ve lokasyonu için yeni bir yaklaşım sunmuşlar ve bu yöntemle deprem analizinde önemli iyileştirmeler sağlamışlardır. Mousavi ve diğ. (2019) derin sinir ağlarında transformer yapısı kullanarak eş zamanlı hem deprem tespiti hem de faz tespiti konusunda başarılı sonuçlar elde etmişlerdir. Soto ve diğ. (2020) konvolüsyonel sinir ağıyla faz tanımlaması ve devamında tekrarlayan sinir ağlarıyla varış zamanı tespiti yapan DeepPhasePick algoritmasını geliştirmişlerdir. Benzer şekilde, Zhu ve Beroza (2019), PhaseNet adlı derin sinir ağı tabanlı bir algoritma ile sismik fazların otomatik ve hassas bir şekilde belirlenebildiğini göstermişlerdir. Konvolüsyonel sinir ağı mimarisini kullanan PhaseNet, sismik dalgaların karakteristik özelliklerini öğrenerek sürekli sismogram verileri üzerinde faz belirlemesi yapar. Bu yöntem, sismogramdaki dalga kaydının farklı ölçeklerdeki ve ilk bakışta görülemeyen özelliklerini yakalamak için çok katmanlı derin sinir ağlarını kullanır ve geleneksel sinyal işleme tekniklerine göre daha yüksek doğruluk ve hız sağlar. PhaseNet'in çalışma prensibi, ham sismik verilerin ön işlemeye tabi tutulmadan doğrudan modele girdi olarak verilmesi ve ağı bu veriler üzerinde P ve S fazlarının olasılıklarını çıkarması üzerine kuruludur. Eğitim sürecinde, elle belirlenmiş faz varış zamanları kullanılarak modelin ağırlıkları optimize edilir. Sonuç olarak, PhaseNet, karmaşık jeolojik yapılara sahip bölgelerde bile sismik fazların otomatik ve güvenilir bir şekilde tespitini mümkün kılmaktadır.

PhaseNet algoritmasının Kuzey Kaliforniya'da deneyimli uzmanlar tarafından seçilen milyonlarca sayısal sismogramın veri tabanı kullanarak eğitilmesiyle PhaseNet'in orijinal

modeli oluşturulmuştur. Bu orijinal eğitim verisi farklı aletsel özelliklere sahip sismometrelerin kayıtlarından elde edilmiş ve geniş bir sinyal-gürültü oranı (S/N) aralığını kapsamaktadır. Bu nedenle PhaseNet, farklı koşullara uyum sağlayabilen model parametre uzayına sahiptir. PhaseNet, veri girişi olarak üç bileşenli sayısal zaman serisi olan sismogramları dikkate alır ve örnek başına P ve S fazlarına ait başlangıç zamanı (okuma zamanı) olasılığını çıkarır. Büyük veri tabanı ile belli bir bölge için eğitilmiş derin öğrenme modellerinin başka bölgelere uygulanmasında başarılı sonuçlar alınmasına rağmen farklı makine öğrenmesi modellerinin, eğitildikleri sismik veri tabanı anlamında bölgesel özelliklere sahip olduğu, algılama performansının uygulandığı bölgeye göre belli miktarda değiştiği de bilinmektedir (Münchmeyer ve diğ. 2022). Münchmeyer ve diğ. (2022) çalışmasında PhaseNet'in birbirinden oldukça farklı yerel ve küresel ölçekte sismik ağlardan toplanmış veri üzerinde diğer algoritmalara kıyasla başarıyla çalışmasından hareketle, mevcut çalışmada PhaseNet'in Kuzey Kaliforniya sismik ağından elde edilen veriye dayalı orijinal eğitilmiş modeli Türkiye depremleri üzerinde değerlendirilmiştir. KRDAE (Kandilli Rasathanesi ve Deprem Araştırma Enstitüsü) sismik ağı altındaki istasyonlar ile arşivlenmiş 2013-2019 yıllarını içeren sayısal formdaki deprem sismogramları PhaseNet algoritmasıyla çözümlenmiş ve P ve S fazları geliş zamanları açısından sismologların bulguları ile PhaseNet çözümlmeleri karşılaştırılmıştır. Bu karşılaştırma tüm Türkiye ve farklı tektonik karaktere sahip beş alt bölge dikkate alınarak da yapılmıştır.

2. YÖNTEM

Bu çalışmada PhaseNet'in farklı veri tabanları ile farklı bölgelerdeki yüksek başarı kabiliyeti dikkate alınarak orijinal veri tabanı (NCEDC 2014) eğitilmiş modeli kullanılmıştır. PhaseNet sonuçlarını derin öğrenme kullanmayan klasik yöntemlerle karşılaştırmak amacıyla otoregresif Akaike bilgi kriteri (Akaike 1985) AR-AIC seçicisini kısa süreli ortalama (Short Term Average, STA) ve uzun süreli ortalama (Long Term Average, LTA) oranını da (STA/LTA) izleyerek kullanan Python ObsPy kütüphanesinin ARPick algoritması, aynı veri tabanı üzerinde çalıştırılarak sonuçlar elde edilmiştir. Sonuçların değerlendirmesine konu olacak ara değerleri bulmak için öncelikle P ve S varış zamanları için ayrı ayrı olacak şekilde, uzman tarafından elle bulunan zaman değerleriyle tahmin edilen zaman değerleri arasındaki artıklar/farklar (Δt) hesaplanmış ve histogramları çıkarılmıştır. Tüm değerlendirmeler gerek PhaseNet gerek ARPick için ayrı ayrı ele alınarak karşılaştırma olanağı sağlanmıştır. Makine öğrenmesi algoritmasının sismik faz varış zamanı tahmini doğruluğunun değerlendirilmesinde özel ve etkili bir yaklaşım sunan $\mu(\Delta t)$ (Artıkların/Farkların Ortalaması) ve $\mu(|\Delta t|)$ (Mutlak Artıkların/Farkların Ortalaması) metrikleri kullanılmıştır. Bu kombinasyon, varışları sistematik olarak erken veya geç tahmin etme eğilimini gösteren bir yanlışlık ölçüsü olan $\mu(\Delta t)$ ve yön etkisi olmadan zamanlama farklılıklarının ortalama büyüklüğünü doğrudan yansıtan mutlak farkların ortalaması metriği $\mu(|\Delta t|)$ ikilisinden oluşur. $\mu(|\Delta t|)$, sismolojideki zamanlama doğruluğu gereksinimleriyle yakından uyum gösterir ve hassas faz varış zamanı tahminlerinin kritik olduğu uygulamalar için idealdir. Bu metrikler birlikte hem zamanlama hata boyutunun $\mu(|\Delta t|)$ hem de tahmin yanlışlığının $\mu(\Delta t)$ net ve hedefe yönelik bir görünümünü sunarak bu özel bağlamda model performans değerlendirmesini güçlendirir. Değerlendirmenin diğer hedefi, makine öğrenmesi

algoritmasının tahminlerinin başarımlarını niteliklerini anlamaktır. Bu aşamada, Keskinlik (Precision), Duyarlılık (Recall) ve F1 skoru kriter olarak değerlendirilmiştir. Bu belirleyiciler hata matrisi olarak da adlandırılan ve tahmin edilen değerler

ile gerçek değerleri sınıflandıran bir tabloya (Tablo 1) dayanmaktadır. Bu tablo doğru ve yanlış gerçek değerlerle, doğru ve yanlış tahmin değerlerini sınıflandırmada kullanılır.

Tablo 1: Hata matrisi ve bu çalışmaya uyarlanması
Table 1: Confusion matrix and its usage in this study

Hata Matrisi		TAHMİNLER	
		Pozitif Tahminler PhaseNet tahmin olasılığı ≥ 0.5	Negatif Tahminler $0.3 \leq$ PhaseNet tahmin olasılığı < 0.5
KESİN BİLGİLER	Pozitif Kesin Bilgi	TP (True Positive) Doğru Pozitif Tahmin $ \Delta t \leq 0.2$ sn	FN (False Negative) Yanlış Negatif Tahmin $ \Delta t > 0.2$ sn
	Negatif Kesin Bilgi	FP (False Positive) Yanlış Pozitif Tahmin $ \Delta t > 0.2$ sn	TN (True Negative) Doğru Negatif Tahmin $ \Delta t \leq 0.2$ sn

Böylece sınıflandırılan bilgilerle yapılan tahminlerin Eşitlik 1'de Keskinliği (Precision), Eşitlik 2'de Duyarlılığı (Recall) ve Eşitlik 3'te F1 değerleri hesaplanabilir (Powers 2011).

$$\text{Keskinlik } P = \frac{TP}{(TP+FP)} \quad (1)$$

$$\text{Duyarlılık } R = \frac{TP}{(TP+FN)} \quad (2)$$


$$F1 = 2 \times \frac{P \times R}{(P+R)} \quad (3)$$

F1 skoru, keskinlik ve duyarlılık arasında bir denge sağlar. Pozitif seçimler için eşik değeri yüksek tutulduğunda, sadece en iyi seçimler pozitif olarak belirlenir. Bu durum, toplam doğru seçimlerin sadece küçük bir bölümünü oluşturur. Bu, keskinliğin yüksek, ancak duyarlılığın düşük olmasına yol açar. Eşik değeri düşük tutulduğunda ise, keskinlik düşerken duyarlılık artar. Her iki durumda da F1 skoru düşük çıkar, bunun en temel nedeni bu skorun eşik seçimine karşı daha az duyarlı olmasıdır. Dolayısı ile F1 skoru, algoritmaların performans durumunu daha doğru bir şekilde değerlendirilmesinde önemli bir belirteçdir. PhaseNet ve ARPick sonuçları uzman bulgularıyla karşılaştırılarak bu kriterler üzerinden değerlendirilmiştir. PhaseNet gibi makine öğrenmesine dayalı algoritmalar faz varışı sürelerini 0 ila 1 arasında olan olasılık değeriyle birlikte tahmin eder. Ayrıca bu algoritmalar, bir depremde aynı faz varışı için birden çok

ve farklı olasılık değerlerinde tahmin yapabilir. Bu nedenle çalışmada eğer bir depremde P veya S faz varışı için birden fazla tahmin varsa en yüksek olasılıklı tahmin 0.3 değerinden büyükse doğru kabul edilerek değerlendirmelerde kullanıldı, değilse PhaseNet tahmin yapılamadı sayıldı. Ayrıca PhaseNet için yapılan tahminlerin olasılıkları P ve S fazı varış zamanları için 0.5 eşik değerinden büyükse pozitif bilgi olarak kabul edilmiştir. P ve S fazı gelişleri için 0.2 saniyeden küçük farklar ($|\Delta t|$) doğru pozitif tahmin, bu değerden büyükler ise yanlış pozitif tahmin olarak alınmıştır. Hata matrisinin çalışmamızda PhaseNet tahminlerine nasıl uygulandığı Tablo 1'de özetlenmiştir. Bununla birlikte, PhaseNet'in yaptığı tahminler depremden bağımsız olarak tüm P ve tüm S faz gelişleri için ayrı ayrı değerlendirildiği gibi, uzmanların hem P hem S faz varışını birlikte yapabildiği depremler ayrıca değerlendirilmiştir.

3. VERİ


Çalışmada kullanılan veri tabanı tüm KRDAE (Kandilli Rasathanesi ve Deprem Araştırma Enstitüsü) sismik ağına ait istasyonlar ile toplanmış 2013-2019 yıllarını kapsayan 141.033 adet depreme (Şekil 1) ait üç bileşenli olarak kaydedilmiş SAC (Seismic Analysis Code) formatında sismogramları içermektedir. Depremlerin büyüklüklerine göre histogramı Şekil 2'de gösterilmiştir.



Şekil 1: Çalışmaya konu olan tüm Türkiye'deki 2013-2019 yıllarına ait depremlerin genelleştirilmiş tektonik pencerede (Diri fay haritası, Emre ve diğ., 2013) büyüklüklerine göre episentr (Merkez üssü) dağılımı gösteren harita (GMT 5 (Wessel ve diğ. 2013))

Figure 1: Epicentre distribution map (GMT 5 (Wessel ve diğ. 2013)) of the earthquakes in Türkiye for the years 2013-2019 according to their magnitudes in the generalised tectonic window (Active fault map, Emre et al., 2013)

Veri girişi olarak kullanılan sayısal sismogramlar, elle tespit edilen P dalgası için varış zamanı değeri referans alınarak 30 sn uzunluğa dönüştürülmüştür. Farklı örnekleme değerine sahip olan kayıtlar 100Hz olarak yeniden örneklenmiştir. Tüm bu kayıtlar 1-45Hz filtreden geçirildikten sonra makine öğrenmesi algoritmasına giriş verisi olarak sokulmuştur. Bu veri setinde 1.517.298 adet P fazı varış zamanı vardır. P fazı varış zamanı için tespit edilen sismogramların 474.235 tanesinde S fazı varış zamanı tespiti de bulunmaktadır.




Şekil 2: Çalışmaya konu olan tüm Türkiye'deki 2013-2019 yıllarına ait depremlerin büyüklüklerine göre dağılımı

Figure 2: Distribution of the all earthquakes in Türkiye between 2013-2019 used in the study according to their magnitudes

Bu çalışmadaki değerlendirmeler 2013-2019 yılları arasında Türkiye'de meydana gelen $M > 0.1$ olan tüm depremlerin yanında ayrıca Anadolu tektonik penceresinde hâkim ve farklı tektonik unsurları kapsayan 5 alt bölge oluşturularak yapılmıştır:

1. Birinci Bölge; Kuzey Anadolu Fay zonunun (KAFz) batısını ve Marmara Bölgesini içerir.
2. İkinci Bölge; Kuzey Anadolu Fay zonunun (KAFz) doğusunu içerir.
3. Üçüncü Bölge; Doğu Anadolu Fay zonu (DAFz).
4. Dördüncü Bölge; İç Anadolu Bölgesini içerir.
5. Beşinci Bölge; Ege açılma rejimi bölgesini içerir.

Bu bölgeler Şekil 3'te harita üzerinde izlenebilir, koordinatları ise Tablo 2'de gösterilmiştir.



Şekil 3: Bölgesel değerlendirmeye konu olan bölgelerin basitleştirilmiş tektonik harita (Diri fay haritası, Emre ve diğ., 2013) üzerindeki konumları

Figure 3: Location of the regions subject to regional assessment on the simplified tectonic map (Active fault map, Emre et al., 2013)

	Minimum Enlem	Maksimum Enlem	Minimum Boylam	Maksimum Boylam
Birinci Bölge	39.50	41.30	25.30	32.35
İkinci Bölge	39.30	41.35	32.55	42.00
Üçüncü Bölge	36.80	39.20	35.85	42.40
Dördüncü Bölge	37.20	39.10	30.40	35.55
Beşinci Bölge	36.65	39.40	26.25	30.30

Tablo 2: Şekil 3'de gösterilen Anadolu Bloğu'ndaki farklı tektonik özellikler dikkate alınarak alt inceleme alanlarının sınırları

Table 2: The boundaries of the sub-investigation areas by taking into account the different tectonic features of the Anatolian Block shown in Figure 3

4. BULGULAR

4.1) Tüm Türkiye Depremleri

4.1.1) Tüm P ve S Fazı Geliş Süreleri için Ayrı Ayrı Değerlendirmeler

Veri setimizdeki tüm depremler dikkate alındığında, uzmanlar tarafından yapılan analizlerde bulunan faz varışı tespit sayılarıyla PhaseNet ve ARPick tarafından bulunanlar arasında fark olduğu izlenmektedir (Tablo 3). PhaseNet, bu çalışmada kullanılan 0.30 olasılık seçimi eşiği nedeniyle tüm


depremlerin %74'ünde P fazı tespiti yapabilmıştır. Gerekirse bu seçim eşiğini düşürerek makine öğrenmesi algoritmasının daha güvensiz ama daha çok tespit yapması sağlanabilir. S fazı geliş tespitlerine baktığımız zaman makine öğrenmesi algoritmasının uzmanların bulduklarına göre %79 daha fazla tespit yapabildiğini görüyoruz. Bunun nedeni PhaseNet'in uzmana göre daha iyi S fazı geliş tahmini yapabilmesidir (Zhu ve Beroza 2019). Bu bilgiden hareketle makine öğrenmesi algoritmaları yardımıyla daha fazla P-S faz varışı tespiti olan veri üzerinde çalışmanın olanaklı olabileceği ortaya çıkmıştır.

Tablo 3: 2013-2019 yıllarındaki tüm Türkiye depremleri için uzmanların, PhaseNet'in ve ARPick'in bulduğu tüm P ve S faz varışı sayıları**Table 3:** The number of all P and S phase arrivals identified by seismologists (humans), by PhaseNet and by ARPick for all earthquakes in Türkiye from 2013 to 2019

Ayrı Ayrı Tüm P ve S Fazı Tespitleri Sayıları		
	P Fazı Gelişleri	S Fazı Gelişleri
İnsan	1.517.298	474.235
PhaseNet (Tahmin olasılığı ≥ 0.3)	1.128.864	849.702
ARPick	1.489.576	467.166

P fazı geliş tahminlerinin histogramlarında ilk dikkati çeken, gerek makine öğrenmesinin gerek diğer geleneksel yöntemlerin sistematik olarak erken tahmin eğiliminde olduğudur. PhaseNet, P fazı için ARPick'e göre daha erken tahmin eğiliminde olsa da ortalama mutlak hata anlamında 0.52 saniye daha başarılı sonuç vermiştir (Şekil 4a, Şekil 4b ve Tablo 4). S fazı geliş tespitlerinde ise her iki yöntem de yine sistematik olarak erken tahmin eğilimindedir; ancak ortalama mutlak hata anlamında PhaseNet yaklaşık dört kat daha başarılı sonuçlar vermiştir (Şekil 4c, Şekil 4d ve Tablo 4). Orijinal PhaseNet makalesinde de (Zhu ve Beroza 2019)

görüldüğü gibi PhaseNet S fazı gelişleri için daha iyi bir başarımla sergilemiştir. Güvenilirliği daha fazla ancak nicelik olarak daha az faz varışı sağlamak amacıyla, bu çalışmada kullanılan pozitif tahmin için faz seçimi güven eşiği (0.5) daha da arttırılabilir. Bu, daha düşük OMH değerleri yakalanmasına olanak sağlayacaktır. Ancak bu çalışmada yapılan tespitlerin ötesinde deprem merkezi bulma gibi farklı bir amaç güdülmendiğinden eşik değerinde değişikliğe gerek görülmemiştir. Bu sonuçlar ve değerlendirmeler yerel Türkiye verisiyle eğitilmeden kullanılan makine öğrenmesi algoritmalarının sınırlarını da göstermektedir.

**Şekil 4:** PhaseNet ve ARPick'in bulduğu tüm P (a ve b) ve S (c ve d) faz gelişlerinin uzman bulgularıyla karşılaştırıldığı $\mu(\Delta t)$ histogramları.**Figure 4:** Histograms of $\mu(\Delta t)$ comparing all P (a & b) and S (c & d) phase arrivals detected by PhaseNet and ARPick with respect to expert findings.

PhaseNet'in F1 değeri de beklendiği gibi hem P hem de S dalgası için orijinal çalışmaya (Zhu ve Beroza 2019) göre daha

düşük gerçekleşmekle birlikte ARPick'in söz konusu değerine göre daha yüksektir (Tablo 4).

Tablo 4: PhaseNet ve ARPick'in bulduğu tüm P ve S faz gelişlerinin uzman bulgularıyla karşılaştırıldığı başarımlar tablosu

Table 4: A table comparing the differences in all P and S phase arrivals detected by PhaseNet and ARPick with expert findings

Ayrı Ayrı Tüm P ve S Fazı Gelişleri İçin Uzman Tespitleriyle Algoritma Tespitlerinin Karşılaştırması				
	P Fazı		S Fazı	
	PhaseNet	ARPick	PhaseNet	ARPick
$\mu(\Delta t)$ (Saniye)	-0.864787	-0.270744	-0.323923	-1.210630
$\mu(\Delta t)$ (Saniye)	1.169250	1.689590	0.633367	2.441320
Keskinlik (Precision)	0.466801	0.276414	0.461383	0.098612
Duyarlılık (Recall)	0.911137	0.271363	0.850836	0.097142
F1	0.617327	0.273865	0.598317	0.097871

4.1.2) Farklı Seçim Eşiği İçin Değerlendirmeler

Bu aşamada, pozitif tahmin faz seçim eşiğinin sonuçlara nasıl etki yaptığını göstermek amacıyla Tablo 3'teki veri kullanılarak PhaseNet P ve S dalgası pozitif tahmin faz seçim eşiği 0.50'den 0.70'e çıkarılmış ve Tablo 5'teki sonuçlar elde edilmiştir. Beklendiği gibi PhaseNet daha güvenilirliği yüksek ama daha az sayıda tahmin yapmıştır. Ancak P ve S fazları gelişleri

tahminlerinin hem $\mu(\Delta t)$ hem de $\mu(|\Delta t|)$ değerleri iyileşmiştir. Bu çeşit bir uygulama, buradan çıkan sonuçların kullanılacağı ve sonuçlardaki keskinliğin daha önemli olduğu ancak faz tahmini sayısındaki azlığın sonucu çok etkilemeyeceği bir sonraki değerlendirme için uygunsa kullanılabilir (Deprem merkezi belirlenmesi gibi).

Tablo 5: PhaseNet faz seçim eşiği 0.7'ye çıkarıldığında, tüm P ve S faz gelişleri için başarımlar karşılaştırma tablosu

Table 5: (PhaseNet pick selection probability 0.7) Comparison table for all P and S phase arrivals identified by experts and by PhaseNet

Ayrı Ayrı Tüm P ve S Fazı Tespitleri Sonuçları (Seçim Eşiği 0.70)		
	PhaseNet P	PhaseNet S
Karşılaştırılan PhaseNet Tahminleri Sayısı	593.523	147.810
$\mu(\Delta t)$ (Saniye)	-0.618346	-0.335711
$\mu(\Delta t)$ (Saniye)	0.798865	0.534058

4.1.3) P ve S Fazı Geliş Süresinin Birlikte Bulunduğu Sismogram İçin Değerlendirmeler

Bu çalışmada buraya kadar, bulunan tüm P ve S fazları gelişleri için değerlendirmeler yapıldı. Şimdiki aşamada ise yalnızca hem P hem de S faz varışının birlikte tespit edilebildiği sismogramlar değerlendirilmiştir. Tablo 6'da özetlenen tespit sayılarında PhaseNet tarafından bulunan faz gelişleri sayısının Tablo 3 ile karşılaştırıldığında azaldığı gözlenmektedir.

Bunun nedeni PhaseNet'in uzmanlara göre (474.235 adet uzman okuması) çok daha fazla S fazı geliş tespiti yapmasına rağmen (849.702 adet), tablodaki değerlerin karşılaştırma yapabilmek amacıyla uzmanların bulduklarıyla eşleşen sayıyı göstermesidir. ARPick'in bulduğu S fazı geliş tespitleri ise uzmanlarınki ile uyumludur.


Tablo 6: Hem P hem de S fazı gelişinin birlikte bulunduğu sismogram sayıları.

Table 6: The total counts of all P-S phase arrival pairs detected together

Aynı Depremlerde Birlikte Bulunan P ve S Fazı Sayıları	
	P-S Fazı Gelişleri
İnsan	474.235
PhaseNet	362.580
ARPick	467.166

Şekil 5a, Şekil 5b ve Tablo 7'de görüldüğü gibi, P fazı geliş tahminlerinin histogramlarına baktığımızda hem makine öğrenmesi hem de klasik yöntem için sistematik olarak erken tahmin eğilimi hâlâ izlenmekle birlikte Şekil 5'e göre uzman değerlerine daha yakın sonuçlar üretilmiştir. PhaseNet, ARPick'e göre ortalama mutlak hata anlamında bir önceki

analize benzer biçimde 0.54 saniye daha başarılı sonuç vermiştir. S fazı geliş tespitlerinde ise her iki yöntem de yine sistematik olarak erken tahmin eğilimindedir. Ortalama mutlak hata anlamında PhaseNet yine yaklaşık dört kat daha başarılı sonuçlar vermiştir (Şekil 5c, Şekil 5d ve Tablo 7).



Şekil 5: Hem P hem de S fazı gelişleri birlikte tespit edilebilen sismogramlar için, PhaseNet ve ARPick'in bulunduğu tüm P (a ve b) ve S (c ve d) faz gelişlerinin uzman bulgularıyla karşılaştırıldığı $\mu(\Delta t)$ histogramları

Figure 5: Histograms of $\mu(\Delta t)$ comparing all P (a & b) and S (c & d) phase arrivals detected by PhaseNet and ARPick with respect to expert findings where both P and S phase arrivals were jointly detected in the same seismogram

Aynı biçimde Tablo 4 ve Tablo 6 karşılaştırıldığında, PhaseNet'in F1 değerinin P fazı gelişleri tespiti açısından önemli oranda daha yüksek sonuç verdiği izlenmektedir. P fazı gelişleri

tespitindeki bu iyileşme, uzman tarafından her iki fazın tespit edilebildiği sismogramların gürültüden arınmış ve daha iyi okunabiliyor olmasıyla açıklanabilir.

Tablo 7: Hem P hem de S fazı gelişleri birlikte tespit edilebilen sismogramlar için başarımlar karşılaştırma tablosu

Table 7: Comparison table for all P and S phase arrivals jointly identified for the same earthquake

Aynı Depremlerde Birlikte Bulunan P ve S Fazı Tespitleri İçin Uzman Tespitleriyle Algoritma Tespitlerinin Karşılaştırılması	P Fazı		S Fazı	
	PhaseNet	ARPick	PhaseNet	ARPick
$\mu(\Delta t)$ (Saniye)	-0.362279	-0.167783	-0.341008	-1.210630
$\mu(\Delta t)$ (Saniye)	0.523487	1.064000	0.601282	2.441320
Keskinlik (Precision)	0.616119	0.451679	0.467248	0.098612
Duyarlılık (Recall)	0.963382	0.186922	0.861622	0.119342
F1	0.751577	0.264417	0.605915	0.107991

4.2) Bölgesel Değerlendirme

İncelenen alt bölgelerde uzman tarafından yapılan bulgularla karşılaştırıldığında, Türkiye genelindeki sonuçlarla benzer biçimde P ve S fazı varışı tespitinde makine öğrenmesi sistematik olarak erken tahmin eğilimindedir (Tablo 8), ($P \mu(\Delta t)$ ve $S \mu(\Delta t)$ metrikleri). P dalga varışı tahmininde tüm alt bölgelerde genele göre daha fazla (Daha önce) erken tahmin yapılırken, bu fark en fazla üçüncü bölgede 0.135 saniye, en az birinci ve beşinci bölgelerde sırasıyla 0.006 ve 0.002 saniye olarak gözlenmiştir. P fazı varış tespitinin mutlak hatası ($P \mu(|\Delta t|)$) ise yine en az birinci ve beşinci bölgelerde sırasıyla 0.017 ve 0.021 saniye olarak ve yine en fazla üçüncü bölgede 0.185 saniye olarak gerçekleşmiştir. Tüm alt bölgeler için, S fazı varışında makine öğrenmesi yine Türkiye genelinde olduğu gibi sistematik olarak erken tahmin eğilimindedir ancak bölgeler arasında karşılaştırmada farkın iki kata yakın olabildiği görülmektedir ($S \mu(\Delta t)$ metriği). S fazı varış tespitinin mutlak hatası ($S \mu(|\Delta t|)$) ise bu sefer en az olarak ikinci ve beşinci bölgelerde sırasıyla 0.051 ve 0.024 saniye olarak ve yine en fazla üçüncü bölgede 0.143 saniye olarak

izlenmiştir. Tüm Türkiye ile alt bölgeler arasındaki en yüksek $P \mu(|\Delta t|)$ ve $S \mu(|\Delta t|)$ farklarının oranının sırasıyla %15.8 ve %22.6 biçiminde çok fazla olmaması, PhaseNet'in orijinal eğitim verisinin oldukça farklı jeolojik yapıları içerdiğini ve algoritmanın farklı yer kabuğu özelliklerinin P/S dalgası faz gelişlerine etkisini derinlemesine öğrenebildiği ile açıklanabilir, ancak bu farkın yeterince az olup olmadığı bir tartışma konusudur. Her iki faz da dikkate alındığında, Kuzey Anadolu Fay zonunun (KAFz) batısını ve Marmara Bölgesi'ni içeren birinci bölge ile Ege Bölgesini içeren beşinci bölgenin en iyi sonuçları verdiği görülmektedir. Bu durum PhaseNet'in eğitim setini oluşturan Kaliforniya depremlerini üreten farklı tektonik yapıların mekanizmalarının KAFz Marmara (Allen 1982) ve Ege Bölgelerindeki fayların mekanizması ile benzer karaktere sahip olması ile ilişkilendirilebilir. Üçüncü bölge olan Doğu Anadolu Bölgesi sonuçlarının kötü olması ise gerek bu bölgedeki tektonik karmaşıklık gerekse depremlerin episantr uzaklıklarıyla açıklanabilir. Bu sonuçlar kullanılan öğrenme veri tabanının alındığı bölgenin tektonik karakterinden farklı bölgelerde ayrı ve özgün bir algoritmanın üretilmesinin ve yerel veriyle eğitilmesinin gerekliliğine işaret etmektedir.


Tablo 8: PhaseNet'in bölgeler bazında başarımlar tablosu
Table 8: Performance table for PhaseNet by regions

	Ayrı Ayrı Tüm P ve S Fazı Tespitleri İçin Bölgesel Değerlendirmeler					
	Tüm Türkiye	Birinci Bölge	İkinci Bölge	Üçüncü Bölge	Dördüncü Bölge	Beşinci Bölge
Depremler	141.033	24.895	6.143	11.330	4.056	55.357
Karşılaştırılan P Fazı Gelişleri	1.128.864	257.735	39.776	62.697	24.939	413.351
$P \mu(\Delta t)$ (Saniye)	-0.864787	-0.870961	-0.932448	-0.999302	-0.946663	-0.866642
$P \mu(\Delta t)$ (Saniye)	1.169250	1.151830	1.205980	1.354230	1.267920	1.191050
Karşılaştırılan S Fazı Gelişleri	474.235	79.368	14.545	24.122	8.542	164.767
$S \mu(\Delta t)$ (Saniye)	-0.323923	-0.213509	-0.168512	-0.171475	-0.207802	-0.443457
$S \mu(\Delta t)$ (Saniye)	0.633367	0.535839	0.582283	0.775892	0.535930	0.657004

4.3) Sismogram Örnekleri

Şekil 6'da PhaseNet'in sismogramlar üzerinde nasıl başarımlar gösterdiğine dair örnekler verilmiştir. Şekil 6a'da, düşük gürültülü sismogramlarda P ve S fazlarının tespitlerinin birbirine oldukça yakın olduğu görülmektedir. Bu nedenle PhaseNet'in yaptığı tahminler gerçek pozitif olarak sınıflandırılmıştır. Şekil 6b'de yine düşük sinyal-gürültü (S/N) oranına sahip bir kayıt izlenmektedir. Burada P fazı varış okuma zamanları tespitleri birbirine yakın olsa da S fazı için uzman tespiti ile makine öğrenmesi tespiti arasındaki fark artmıştır. Şekil 6c, gürültülü kayıt nedeniyle uzman tarafından

bulunamayan S fazı geliş süresinin PhaseNet tarafından nasıl tahmin edildiğini göstermektedir. Bu örnek, uzmanların S fazı varış zamanlarını belirleyemediği durumlarda PhaseNet tahminlerinin nasıl kullanılabileceğine dair iyi bir örnektir. Şekil 6d'de, Hem uzaman hem de PhaseNet'in S fazı gelişini yakalayamadığı görülmektedir. Şekil 6e, kaydın sonunda geç gelen S fazına rağmen PhaseNet'in doğru tahmin yapabildiğini gösterebilmesi açısından önemlidir. Şekil 6f'de görüldüğü gibi PhaseNet aynı kayıt içinde iki ardışık depremi yakalayabilmiştir. Bu makine öğrenmesinin güvenilirliği anlamında önemli bir göstergedir.



Şekil 6: PhaseNet faz geliş süresi tespitleri uzman tarafından yapılan tespitlerle karşılaştırmalı olarak gösterilmiştir (Toplam 6 olay sismogramlarla örneklenmiştir (a-b-c-d-e-f). Her olay için, uzman tarafında seçilen P ve S faz varışları, 3 bileşenli mavi renkli kayıtlarda (Yukarıdan aşağıya DB, KG, Düşey bileşenler olmak üzere) sırasıyla düz ve kesikli siyah dikey çizgilerle işaretlenmiştir. Aynı şekilde, PhaseNet P ve S faz varışları sırasıyla kesikli-noktalı ve noktalı dikey çizgilerle işaretlenmiştir. Tüm bu kayıtlarda dikey eksen genliği göstermektedir.)

Figure 6: The PhaseNet phase arrival time detections are shown in comparison with expert detections (A total of 6 events have been shown with seismograms (a-b-c-d-e-f). For every event, the P and S phase arrivals selected by the expert are marked on the 3-component blue records (Top-to-bottom EW, NS, Z components) with solid and dashed black vertical lines, respectively. Similarly, the PhaseNet P and S phase arrivals are marked with dashed-dotted and dotted vertical lines, respectively. In all seismograms, vertical axis is amplitude.)

5. SONUÇLAR

Bu çalışmada, PhaseNet'in, yerel verilerle eğitilmemiş olan orijinal modelinin 2013-2019 yılları arasındaki KRDAE kayıtları üzerinden tüm Türkiye genelinde faz gelişlerini başarıyla tespit edebildiği ortaya konulmuştur. Ayrıca, PhaseNet'in geleneksel ve istatistik yöntemlere göre daha iyi tahminler yapabildiği belirlenmiştir. Makine öğrenmesi algoritması, uzman tarafından tüm Türkiye depremlerinde saptanan varış zamanlarına göre mutlak farkların ortalaması $\mu(|\Delta t|)$ açısından, P fazı varışı tespiti için geleneksel yöntemlere göre 0.52 saniye, S fazı varışı tespiti içinse 1.84 saniye daha doğru tahminde bulunmuştur. Bu çalışmada PhaseNet'in Türkiye verisiyle eğitilmemiş orijinal modelini $\mu(|\Delta t|)$ başarımı, P fazı için 1.17 sn, S fazı içinde 0.63 sn olarak gerçekleşmiştir. Bu sonuçlar PhaseNet'in asıl makalesindeki (Zhu ve Beroza 2019) değerlere göre oldukça yüksek olsa da burada kullanılan yöntemle Biga bölgesi verisiyle yapılan çalışmadaki (Unal ve Bekler 2024) sonuçlara yakın sonuçlar üretilmiştir. Ayrıca yalnızca hem P ve hem de S fazı bulunan sismogramlar değerlendirildiğinde PhaseNet'in $\mu(|\Delta t|)$ başarımı özellikle P fazı varışları anlamında oldukça iyileşmiştir. Bu çalışmada ayrıca, Unal ve Bekler (2024)'ün gösterdiğine benzer biçimde, PhaseNet faz seçim eşiği 0.70'e çıkarıldığında makine öğrenmesi faz varışı tespitlerinin P fazı için %32, S fazı için %16 iyileştiği gözlenmiştir. Makine öğrenmesi algoritmasının Türkiye verisiyle eğitilmemiş modelinin faz seçim eşiği artırılarak anlamlı sonuçlar üretebildiği saptanmıştır. Ek olarak PhaseNet'in Türkiye'nin beş bölgesine ait farklı depremlerde başarımı sınanmış ve bölge bazında minör farklar tespit edilmekle birlikte en iyi sonuçlar Kuzey Anadolu Fay zonunun (KAFz) batısını ve Marmara Bölgesini içeren bölgede görülmüştür. Bu durum PhaseNet'in orijinal modelinin eğitim seti olan Kaliforniya depremlerini üreten tektonik yapının mekanizmasının KAFZ Marmara Bölgesindeki fayların mekanizması ile benzer olması ile açıklanabilir.

Kabuk heterojenitesi, ortam gürültüsü, alet etkisi gibi faktörler, başta temel deprem dalga fazları olmak üzere varış süreleri ve genliklerin uzmanlar tarafından değerlendirmesini olumsuz etkileyebilmektedir. PhaseNet algoritmasının bu durumu tespit ettiği dolayısı ile hatalı faz okumalarının yanında depreme ait

herhangi bir faz örüntüsünün de görülmediği sismogramların depremlerin dinamik parametre analizine dahil edildiği anlaşılmıştır. Modelin yerel veriyle eğitilmemiş olması, orijinal PhaseNet makalesi ile karşılaştırıldığında sonuçların daha olumsuz çıkmasına neden olmuş ve yerel veriyle eğitilen modellerin daha iyi performans gösterebileceğine işaret etmiştir. Makine öğrenmesi tabanlı sismogram fazlarının varış zamanlarının tespit edilmesi, deprem parametrelerinin daha güvenilir ve hızlı çözülmesini sağlayarak geniş sismolojik ağa sahip kurumlar için işlem sayısının, iş gücünün ve istasyon sayısının azaltılmasıyla ekonomik avantajlar sunacaktır.

P ve S gibi temel deprem fazlarının varış zamanlarının doğru ve güvenilir bir şekilde belirlenmesi, farklı yer fiziği problemlerinin çözüm kalitesini doğrudan etkileyen önemli bir faktördür. Sismologların kontrolünde manuel olarak belirlenen fazlar, özellikle S dalgasının seçiminde, deprem büyüklüğü, yerel gürültü seviyesi (S/N), kabuk heterojenitesi ve istasyonun deprem kaynağına olan uzaklığı gibi etkenler nedeniyle hatalara neden olabilmektedir. Bu durum da daha yüksek RMS hatalarına yol açabilir.

Bu çalışmada, belirli bir bölgeye ait büyük ve çeşitlilik içeren veri tabanlarıyla eğitilen derin öğrenme modellerinin, Türkiye deprem verisiyle nasıl çalıştığı incelenmiş, makine öğrenmesi algoritmasının olasılık eşiği parametreleri optimize edilerek farklı amaçlarla kullanılabileceği ortaya konmuştur. Algoritmanın yerel veriyle eğitilmeden dahi S fazı geliş için yüksek başarımla gösterdiği ve daha fazla faz tespitini güven seviyesi yüksek biçimde yapabildiği görülmüştür. Ayrıca Türkiye'deki farklı bölgelerde makine öğrenmesinin değişken başarımla sonuçlar üretebildiği gözlenmiştir. Bu nedenle kimi bölgelere özgü olarak amaca göre daha iyi başarımla bu algoritmanın kullanılabileceği anlaşılmıştır.

Sonuç olarak, gelecekteki çalışmalarda, yerel veriyle eğitilmiş derin öğrenme algoritmalarının başarımlarının karşılaştırmalı olarak incelenmesi gerekmektedir. Bu çalışmaların sonuçlarına göre, gerçek zamanlı faz tespiti için uzman müdahalesine ihtiyaç duymadan yalnızca derin öğrenme algoritmalarının kullanılması üzerine değerlendirmeler yapılabilecektir.

TEŞEKKÜR

Boğaziçi Üniversitesi Kandilli Rasathanesi ve Deprem Araştırma Enstitüsü Bölgesel Deprem-Tsunami İzleme ve Değerlendirme Merkezi'ne veri kullanımını sağladığı için teşekkür ederiz. Bu çalışmadaki hesaplama algoritmalarında kullanılan bilgisayar çevre donanımları, FBA-2024-4926 proje kodlu Çanakkale Onsekiz Mart Üniversitesi Bilimsel Araştırma Projeleri tarafından desteklenmiştir.

KAYNAKLAR

Akaike H., 1985. Prediction and entropy, (In: A Celebration of Statistics, Editörler: Atkinson A. C., Fienberg S.E., 1985, Springer), 1–24 p.

Allen C.R., 1982. Comparisons Between the North Anatolian Fault of Turkey and the San Andreas Fault of California, (In: Multidisciplinary Approach to Earthquake Prediction, Editörler: Işıkara A.M., Vogel A., Progress in Earthquake Prediction Research, vol 2, Vieweg+Teubner Verlag, Wiesbaden).

Emre Ö., Duman T.Y., Özalp S., Elmacı H., Olgun Ş., Şaroğlu, F., 2013. Açıklamalı Türkiye Diri Fay Haritası, Ölçek 1:1.250.000. MTA Genel Müdürlüğü, Özel Yayın Serisi 30, Ankara.

Mousavi S.M., Zhu W., Sheng Y., Beroza G.C., 2019. Cred: A deep residual network of convolutional and recurrent units for earthquake signal detection, Scientific Reports, 9, 10267.

Münchmeyer J., Woollam J., Rietbrock A., Tilmann F., Lange D., Bornstein T., Diehl T., Giunchi C., Haslinger F., Jozinovic D., Michelini A., Saul J., Soto H., 2022. Which picker fits my data? A quantitative evaluation of deep learning based seismic pickers, Journal of Geophysical Research, 127(1), 1-22.

NCEDC, 2014. Northern California Earthquake Data Center, UC Berkeley Seismological Laboratory Dataset.

Perol T., Gharbi M., Denolle M., 2018. Convolutional neural network for earthquake detection and location, Science Advances, 4(2), e1700578.

Powers D.M.W., 2011. Evaluation: From Precision, Recall and F-Measure to ROC, Informedness, Markedness & Correlation, Journal of Machine Learning Technologies, 2(1), 37-63.

Ross Z.E., Meier M.A., Hauksson E., Heaton T.H., 2018. Generalized seismic phase detection with deep learning, Bulletin of the Seismological Society of America, 108(5A), 2894-2901.

Soto H., Schurr B., 2020. DeepPhasePick: A method for detecting and picking seismic phases from local earthquakes based on highly optimized convolutional and recurrent deep neural networks, Geophysical Journal International, 227(2), 1268-1294.

Unal U., Bekler T., 2024. Detection of P and S Wave Phases by Machine Learning using Northwestern Türkiye Local Seismic Network Data, Pure Appl. Geophys., 2024.

Wessel P., Smith W.H.F., Scharroo R., Luis J., Wobbe F., 2013. GMT 5, Generic Mapping Tools: Improved Version Released, EOS, Transactions American Geophysical Union, 94(45), 409-410.

Zhu W., Beroza G.C., 2019. PhaseNet: a deep-neural-network-based seismic arrival time picking method, Geophysical Journal International, 216(1), 261-273.

ARAŞTIRMA VERİSİ (Research Data)

Çalışma kapsamında kullanılan veri Boğaziçi Üniversitesi Kandilli Rasathanesi ve Deprem Araştırma Enstitüsü Bölgesel Deprem-Tsunami İzleme ve Değerlendirme Merkezi'nden temin edilmiştir.

ÇIKAR ÇATIŞMASI / İLİŞKİSİ (Conflict of Interest / Relationship)

Araştırma kapsamında herhangi bir kişiyle ve/veya kurumla çıkar çatışması/ilişkisi bulunmamaktadır.

YAZARLARIN KATKI ORANI BEYANI (Author Contributions)

- Çalışmanın tasarlanması (Designing of the study): T.B.
- Literatür araştırması (Literature research): U.Ü.
- Saha çalışması, veri temini/derleme (Fieldwork, collection/ compilation of data): T.B., U.Ü.
- Verilerin işlenmesi/analiz edilmesi (Processing/analysis of data): U.Ü.
- Şekil/Tablo/Yazılım hazırlanması (Preparation of figures/ tables/software): U.Ü., T.B., F.N.B.
- Bulguların yorumlanması (Interpretation of findings): U.Ü., T.B., F.N.B.
- Makale yazımı, düzenleme, kontrol (Writing, editing and checking of manuscript): U.Ü., T.B., F.N.B.