

**T.C.  
İSTANBUL AYDIN ÜNİVERSİTESİ  
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**



**ALGORİTMA İLE YAPAY ZEKA YÖNTEMİNİ KULLANARAK  
DEPREM TAHMİNİ**

**DOKTORA TEZİ**

**Turgut PURA**

**Bilgisayar Mühendisliği Anabilim Dalı  
Bilgisayar Mühendisliği Programı**

**EYLÜL, 2023**



**T.C.**  
**İSTANBUL AYDIN ÜNİVERSİTESİ**  
**LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**



**ALGORİTMA İLE YAPAY ZEKA YÖNTEMİNİ KULLANARAK**  
**DEPREM TAHMİNİ**

**DOKTORA TEZİ**

**Turgut PURA**  
**(Y1713.610005)**

**Bilgisayar Mühendisliği Anabilim Dalı**  
**Bilgisayar Mühendisliği Programı**

**Tez Danışmanı: Dr. Öğr. Üyesi Peri GÜNEŞ**

**EYLÜL, 2023**

## ONAY FORMU

## ONUR SÖZÜ

Doktora tezi olarak sunduđum "Algoritma İle Yapay Zeka Yöntemini Kullanarak Deprem Tahmini" adlı alıřmanın, tezin proje safhasından sonuçlanmasına kadarki bütün süreçlerde bilimsel ahlak ve geleneklere aykırı düşecek bir yardıma başvurulmaksızın yazıldıđını ve yararlandıđım eserlerin Kaynaka 'da gösterilenlerden olduđunu, bunlara atıf yapılarak yararlanılmıř olduđunu belirtir ve onurumla beyan ederim. (13/09/2023)

Turgut PURA

## ÖNSÖZ

Bu tez çalışmasındaki rehberliği ve destekleri ile eğitimime olan katkılarından ötürü danışman hocam Dr. Öğr. Üyesi Peri GÜNEŞ'e teşekkür etmek istiyorum. Bu tezin hazırlanması boyunca yaptıkları çok değerli yorum ve geri bildirimler için Prof. Dr. Ali GÜNEŞ'e teşekkür etmek istiyorum. Deprem Tahmini üzerine bilgi paylaşımında bulunan ve tez çalışmamda desteklerini esirgemeyen çok değerli eniştem Prof. Dr. Mümtaz Hisarlı ve ablam Yük. Müh. Pınar DENİZ HİSARLI'ya teşekkür etmek istiyorum. Tez çalışmamda yapmış olduğu değerli önerilerinden dolayı Dr. Öğr. Üyesi Şenay KOCAKOYUN AYDOĞAN'a teşekkür etmek istiyorum. Ayrıca yaşamım boyunca ve özellikle doktora çalışmam süresince desteklerini hiçbir zaman esirgemeyen arkadaşlarıma, aileme, annem Serap PURA ve yeğenim Deniz HİSARLI'ya çok teşekkür etmek istiyorum.

Eylül, 2023

Turgut PURA

# ALGORİTMA İLE YAPAY ZEKA YÖNTEMİNİ KULLANARAK DEPREM TAHMİNİ

## ÖZET

Depremler, genel tanımıyla bir doğa olaydır. Bu doğa olayı, önemli hasarlara, can kaybına ve diğer ekonomik etkilere yol açabilen bir felaket olabilmektedir. Deprem gibi doğa olaylarını önceden tahmin etme olasılığı, bahsedilen sebepleri en aza indirecektir. Bu çalışmada, veri toplama, işleme ve değerlendirme süreçleri gerçekleştirilmiştir. Depremlerin tahmin edilmesi için veri setleri hazırlanmıştır. Veri setleri, RNN (tekrarlayan sinir ağı) yöntemi kullanılarak deprem tahmini yapılmıştır. Bu çalışma, 1990-2022 yılları arasında Türkiye sınırları içinde yer alan Düzce iline ait 3.0 ve üzeri büyüklükteki depremlere ait sismik veriler üzerinde gerçekleştirilmiştir. Yöntemin öğrenme potansiyelini artırmak ve gerçek deprem büyüklüğüne yakın sonuçlar ortaya koymak için depremin, b ve d değerleri hesaplanmıştır. Ayrıca elde edilen sonuçlara, Ay ile Dünya arasındaki mesafe verilerinin dahil edilmesiyle performansın önemli ölçüde artırılacağı gösterilmiştir. Türkiye'nin belirli bir zaman aralığında depremlerin tespit edilmesi, yapay sinir ağları kullanılarak depremle ilgili sismik verilerin sınıflandırılması ve gelecekteki tahminlerin üretilmesi, bu çalışmanın önemini vurgulamaktadır.

**Anahtar Kelimeler:** Deprem, Tekrarlayan sinir ağı, Tahmin, Yapay sinir ağı

# EARTHQUAKE PREDICTION USING ARTIFICIAL INTELLIGENCE METHOD WITH ALGORITHM

## ABSTRACT

Earthquakes are natural events by their general definition. This natural event can be a disaster causing significant damage, loss of life, and other economic effects. The possibility of predicting a natural event like an earthquake will minimize the mentioned reasons. In this study, data collection, processing, and evaluation were conducted. Earthquake forecasting was performed using the data and the RNN (Recurrent Neural Network) method. This study was carried out on seismic data with a magnitude of 3.0 and above belonging to Düzce Province between 1990 and 2022. To increase the learning potential of the method and to achieve results closer to the actual earthquake magnitude, the b and d values of the earthquake were calculated. Additionally, the results showed that the performance could be significantly improved by incorporating data regarding the distance between the Moon and the Earth. The detection of earthquakes within a specific time interval in regions of Turkey, the classification of earthquake-related seismic data using artificial neural networks, and the generation of predictions for the future highlight the importance of this study.

**Keywords:** Earthquake, RNN, Prediction, Artificial neural network



# İÇİNDEKİLER

## Sayfa

ONUR SÖZÜ .....	i
ÖNSÖZ.....	ii
ÖZET.....	iii
ABSTRACT .....	iv
İÇİNDEKİLER .....	v
KISALTMALAR LİSTESİ.....	vii
ÇİZELGELER LİSTESİ.....	viii
ŞEKİLLER LİSTESİ.....	ix
<b>I. GİRİŞ .....</b>	<b>1</b>
A. Temel Kavramlar .....	1
B. Tezin Önemi ve Amacı.....	5
<b>II. LİTERATÜR TARAMASI.....</b>	<b>7</b>
<b>III. ÇALIŞMA ALANININ GENEL ÖZELLİKLERİ .....</b>	<b>20</b>
A. Düzce İli.....	20
<b>IV. MATERYAL VE ANALİZ AŞAMASI.....</b>	<b>21</b>
A. Materyal.....	21
B. Analiz Aşaması.....	21
1. Deprem Tahminine Genel Bakış.....	21
2. Verilerin Düzenlenmesi .....	22
3. Veri Analizi Ve Tahmin Süreçleri .....	22
4. Yapay Sinir Ağları .....	23

a. Yapay sinir ağlarında eğitim, öğrenme ve test .....	26
b. Zaman serisi.....	26
c. Rassal orman (Random Forest) .....	26
d. Regresyon Analizi .....	27
e. Çok katmanlı algılayıcı (Multi-Layer Perceptron – MLP).....	27
f. SMOreg algoritması .....	27
g. Ay'ın Dünya'dan uzaklığı .....	28
<b>V. YÖNTEM, SINIFLANDIRMA VE UYGULAMA .....</b>	<b>29</b>
A. Veriler .....	29
1. Zaman Serisi Analizi.....	30
2. Rassal Orman (Random Forest) Oluşturulması .....	30
3. Regresyon Analizi.....	33
4. Çok Katmanlı Algılayıcı (Multi-Layer Perceptron – Mlp).....	35
5. SMOreg Algoritması.....	37
<b>VI. MATERYAL VE METHOD DEĞİŞİMİ .....</b>	<b>41</b>
A. Deprem Büyüklüğünün Hesaplanması .....	41
B. B-Değeri ve D-Değeri Hesaplama.....	42
C. RNN (Recurrent Neural Network).....	44
<b>VII.SONUÇLAR VE DEĞERLENDİRİLMESİ .....</b>	<b>46</b>
<b>VIII. SONUÇLAR VE TARTIŞMALAR .....</b>	<b>48</b>
<b>IX. KAYNAKÇA .....</b>	<b>57</b>
<b>ÖZGEÇMİŞ.....</b>	<b>70</b>

## KISALTMALAR LİSTESİ

- ANN** : Yapay Sinir Ađı
- CV** : Varyasyon Katsayı
- DVM** : Destek Vektör Makineleri
- GP** : Genetik Programlama
- KNN** : En Yakın Komşu
- LSTM** : Uzun-Kısa Süreli Hafıza
- M** : Büyüklük
- MCC** : Matthews Korelasyon Katsayısı
- P** : Primary
- RNN** : Yinelemeli Sinir Ađı
- S** : Secondary
- SES** : Sismik Elektrik Sinyalleri
- SRG** : Toprak Radon Gazı
- SSN** : Sismik Algılama Düğümleri
- SVM** : Destek Vektör Makineleri
- TYSA** : Tekrarlı Yapay Sinir Ađı
- UKVH** : Uzun-Kısa Vadeli Hafıza
- VIF** : Varyans Şişirme Faktörü
- YSA** : Yapay Sinir Ađı

## ÇİZELGELER LİSTESİ

	<b><u>Sayfa</u></b>
Çizelge 1. Deprem İstasyon Listesi.....	2
Çizelge 2. Düzce İli 2001 Nisan Ayı Deprem Kayıtları.....	6
Çizelge 3. Olasılık ve Tahmin Verileri .....	39
Çizelge 4. Düzce İli 1990 İle 2022 Arası Depremler ( $M \geq 3$ ) .....	42
Çizelge 5. RNN Formülleri .....	45
Çizelge 6. Model Değerlendirmesi.....	47
Çizelge 7. Tahmin ve Gerçek Deprem Verileri.....	49
Çizelge 8. Gerçek ve Tahmin Edilen Büyüklük Verileri .....	53

## ŞEKİLLER LİSTESİ

### Sayfa

Şekil 1. Deprem İstasyon Haritası.....	1
Şekil 2. Deprem Sinyali Örneği .....	4
Şekil 3. Tahmin İçin Oluşturulan Sekiz Sözde Formül.....	8
Şekil 4. 17.11. 2021 Düzce İli Depremi Ve Artçı Depremlerin Haritası .....	20
Şekil 5. Yapay Sinir Ağı (YSA) Modeli .....	24
Şekil 6. Çok Katmanlı Yapay Sinir Ağı.....	25
Şekil 7. 1990-2022 Yılları Arası Düzce İli Deprem Dağılımı .....	30
Şekil 8. Random Forest Veri Eklenmesi .....	31
Şekil 9. Verilen Listesi .....	31
Şekil 10. Eksik Verilerin Kaldırılması .....	32
Şekil 11. Verilen Listelenmesi .....	32
Şekil 12. Eğitim ve Test Verilerinin Belirlenmesi .....	33
Şekil 13. Eğitim Aşaması .....	33
Şekil 14. Model Başarısı.....	33
Şekil 15. Regresyon Fonksiyonu Ekleme.....	34
Şekil 16. Verilen Modele Dahil Edilmesi.....	34
Şekil 17. Eksiksiz Verilerin Listesi .....	35
Şekil 18. Belirli Bir Aralığın İlişki Dağılımı.....	35
Şekil 19. Veri Setinin Uyum Oranı .....	35
Şekil 20. Verilerin Modele Dahil Edilmesi .....	36
Şekil 21. Eğitim Aşaması .....	36

Şekil 22.	Model Oluşturulması.....	37
Şekil 23.	Model Doğruluk Oranı .....	37
Şekil 24.	WEKA Model Seçimi .....	37
Şekil 25.	Verilerin Modele Dahil edilmesi.....	38
Şekil 26.	Verilen Periyodik Dağılımı .....	38
Şekil 27.	Aylık Tahmin, Oran, Derinlik, Büyüklük .....	40
Şekil 28.	Tahmin Edilen Gün Pik Oranları .....	40
Şekil 29.	Deprem Büyüklük Dağılımı .....	42
Şekil 30.	Düzce Kasım ve Aralık Deprem Dağılımı .....	48
Şekil 31.	Tahmin Edilen Deprem Büyüklük Dağılımı .....	49
Şekil 32.	Düzce 1999 Yılı -Ağustos Ayı Deprem Dağılımı.....	51
Şekil 33.	Tahmin Edilen Büyüklük Verileri.....	52

# I. GİRİŞ

## A. Temel Kavramlar

Doğa olayları sürekli bir değişim halindedir. Bu değişikliklerin kontrolü merkezler tarafından izlenmekte ve elde edilen veriler kayıt altına alınmaktadır. Doğal olaylardan biri de depremdir (Al-Baghdadi, Mozahim Hamdoon ve Janan Yosief, 2020). Geçmişten günümüze dünyanın her köşesinde irili ufaklı birçok deprem meydana gelmiştir. Bu deprem verileri, bölgedeki istasyonların sinyalleri ile deprem izleme merkezinde kaydedilir (Deschamps, Iannaccone & Scarpa, 1984: 29-36). Türkiye genelinde yer alan deprem istasyon haritası Şekil 1'de ve deprem istasyon listesi Çizelge 1'de gösterilmiştir.



Şekil 1. Deprem İstasyon Haritası

Kaynak: (düzce.gov.tr, 2022)

Kaynak: (koeri.boun.edu.tr, 2022)

Çizelge 1. Deprem İstasyon Listesi

GENİŞ BANT İSTASYONLAR (BROAD BAND)									
#	İstasyon Kodu	Yer	N Derece	E Derece	H (m)	Sensör	Digitizer	İletişim	Yazılım
1	AKKU	Akkuyu-Gülnar-MERSİN	361.588	335.508	144	3ESPC	DM24	Uydu	Scream
2	ANTB	ANTALYA A	368.998	306.538	20	6T	DM25	İnternet	Scream
3	<a href="#">ARMT</a>	Armutlu-YALOVA	405.683	28.866	320	3ESP	DM24	Uydu	Scream
4	<a href="#">AYDB</a>	AYDIN	379.467	278.908	1246	3ESPC	DM24	Uydu	Scream
5	BALB	BALIKESİR	39.64	27.88	120	3T	DM24	Uydu	Scream
6	BERE	Bereket-Gülnar-MERSİN	363.476	332.228	1383	3T	DM24	GSM-GPRS	Scream
7	<a href="#">BGKT</a>	Boğazköy-İSTANBUL	41.181	28.773	80	3ESP	DM24	Uydu	Scream
8	BLCB	Bağcıva-İZMİR	383.853	27.042	150	3T	DM24	İnternet	Scream
9	<a href="#">BODT</a>	Bodrum-MUĞLA	370.622	273.103	379	3ESP	DM24	Uydu	Scream
10	<a href="#">CEYT</a>	Ceyhan-ADANA	370.107	357.478	100	3ESP	DM24	Uydu	Scream
11	<a href="#">CRLT</a>	Çorlu-TEKİRDAĞ	41.129	27.736	230	3ESP	DM24	Uydu	Scream
12	<a href="#">DALY</a>	Dalyan	368.162	286.532	100	3T	DM24	Uydu	Scream
13	<a href="#">DAT</a>	Datça-MUĞLA	367.308	275.767	1100	3T	DM24	Uydu	Scream
14	DKL	Dikili-İZMİR	390.713	269.053	35	3ESPC	DM24	Uydu	Scream
15	<a href="#">ELL</a>	Elmalı-ANTALYA	367.483	299.085	1230	3T	DM24	Uydu	Scream
16	<a href="#">ERIK</a>	Erikli-ÇANAKKALE	406.708	265.132	38	3ESP	DM24	Uydu	Scream
17	<a href="#">EZN</a>	Ezine-ÇANAKKALE	398.255	263.247	48	3ESP	DM24	Uydu	Scream
18	<a href="#">FETY</a>	Fethiye-MUĞLA	366.353	290.835	200	3ESP	DM24	Uydu	Scream
19	<a href="#">GADA</a>	Gökçeada-ÇANAKKALE	401.908	258.987	59	3T	DM24	Uydu	Scream
20	<a href="#">HDMB</a>	Hadim-KONYA	36.964	32.486	1946	3T	DM24	Uydu	Scream
21	<a href="#">HRTX</a>	Hereke-KOCAELİ	40.801	29.673	573	3ESP	DM24	Uydu	Scream
22	<a href="#">IKL</a>	İşıkli-MERSİN	362.367	336.845	126	3ESPC	DM24	Uydu	Scream
23	ISK	Kandilli-İSTANBUL	410.657	290.592	132	3T	DM24	Yerel Ağ	Scream
GENİŞ BANT İSTASYONLAR (BROAD BAND) (devam)									
24	KCTX	Karacabey-BURSA	402.627	283.353	445	3ESP	DM24	Uydu	Scream
25	KEBE	Keben-Silifke-MERSİN	36.447	33.713	776	3T	DM24	GSM-GPRS	Scream
26	<a href="#">KRTS</a>	Karataş-ADANA	36.573	35.375	53	3ESP	DM24	Uydu	Scream



Çizelge 1. (Devamı) Deprem İstasyon Listesi

GENİŞ BANT İSTASYONLAR (BROAD BAND)									
#	İstasyon Kodu	Yer	N Derece	E Derece	H (m)	Sensör	Digitizer	İletişim	Yazılım
27	<a href="#">LAP</a>	Lapseki- ÇANAKKA LE	403.703	267.593	230	3ESP	DM24	Uydu	Scream
28	MLSB	Milas- MUĞLA Marmara	372.953	277.765	500	40T	DM24	Uydu	Scream
29	<a href="#">MRMT</a>	Adası- BALIKESİ R	40.609	275.832	213	3T	DM24	Uydu	Scream
30	<a href="#">RKY</a>	Şarköy- TEKİRDA Ğ	406.875	271.777	687	3ESP	DM24	Uydu	Scream
31	SILI	Silişk- MERSİN	363.672	339.239	126	3T	DM24	GSM- GPRS	Scream
32	<a href="#">SILT</a>	Şile- İSTANBUL	41.153	29.643	100	3ESP	DM24	Uydu	Scream
33	<a href="#">SLVT</a>	Silivri- İSTANBUL	41.23	28.21	180	3ESP	DM24	Uydu	Scream
34	<a href="#">TAHT</a>	Tahtaköy- HATAY	363.755	361.855	278	3ESPC	DM24	Uydu	Scream
35	TEKE	Tekeli- Bozyazı- MERSİN	361.426	331.142	173	3T	DM24	GSM- GPRS	Scream
36	TEVE	Tevekalı- Gülнар- MERSİN	364.357	334.432	848	3T	DM24	GSM- GPRS	Scream
37	<a href="#">YER</a>	Yerkesik- MUĞLA	371.362	282.858	729	3T	DM24	Uydu	Scream
38	YLV	YALOVA	405.658	29.3708	879	3T	DM24	GSM- GPRS	Scream


Kaynak: (mta.gov.tr, 2022)

Kaynak: (koeri.boun.tr, 2022)

Kaydedilen veriler sismologlar tarafından incelenir ve ölçeklenir (Ishibashi, 2004: 47(2-3)). Ancak deprem meydana geldikten sonra büyüklük tam olarak hesaplanabilmektedir. Depremden sonra artçı sarsıntılar meydana gelirse yine aynı şekilde hesaplama işlemi sonradan ölçülebilir (van der Elst ve Shaw, 2015: 5771-5778).

Yer kabuğunda, biriken enerji kayaçların kırılma sınırını aştığında kırılmalar (faylanma) meydana gelmektedir. Levhaların birbirlerine göre oluşan hareketleri sonucunda biriken enerjinin aniden boşalmasıyla birlikte deprem oluşmaktadır (Çelik, E., Atalay ve Bayer, 2014: 730-733). Yaşanan depremin türüne göre mutlaka filtrelenmesi gerekmektedir. Levha hareketine bağlı olarak gerçekleşen depremler Tektonik depremlerdir (Özdoğan, 1993: 53-68). Diğer deprem türleri ise volkanların püskürmesi sonucu oluşan Volkanik depremler ve

yer altında bulunan mağaraların, kömür ocaklarında galerilerin, tuz ve jipsli arazilerinin erimesi sonucu oluşan Çöküntü depremlerdir (Karakuş, 2014: 97-116). Oluşan bir tektonik depremin ölçeklenmesi için öncelikle depremin oluşturduğu sinyaller Şekil 2’de ki gibi incelenir.



Şekil 2. Deprem Sinyali Örneği

Depremin, Primary - (P) ve Secondary - (S) dalgaları formüller kullanarak hesaplanır ve depremin büyüklüğü bilimsel olarak sonuçlandırılır (Inalegwu, 2015).

Depremin tahmini ve önceden ölçeklendirilmesi için hala net bir çözüm bulunamamıştır. Bunun nedeni, tahmin etme, belirsizlik ve ani meydana gelme olasılığı, depremi tahmin etmenin çok zor olmasıdır (Purnomo, 2020). Depremi önceden tahmin etmek için pek çok araç ve algoritma geliştirilmiş ancak yine de kesin sonuç veren yapıya ulaşamamıştır. Depremin tahminine yönelik çalışmalar halen devam etmektedir. Deprem tahmininde temel amaç, insanlara maddi ve manevi destek sağlamak olarak düşünülebilir. Ayrıca, devletin ekonomik olarak zarar görmesi de engellenmiş olacaktır (Huang, Wang, Zhao, Xin ve Xiang, 2018: 149-160).

Deprem tahmini için yapılan çalışmaları incelediğimizde, sadece Türkiye’de değil tüm dünyada da çalışmalar yapılmaktadır. Dünyada öncü olarak görülen Çin, ülke çapında çalışmalara öncülük eden bir ülkedir. Bunun nedeni, Çin, deprem bölgesi ve sismik faaliyetleri yüksek bir ülke olmasıdır (Yılmaz, 2019: 241-256). Son on yılda ve daha önceki yıllarda deprem tahmini için yapılan çalışmaları incelediğimizde, tahmin edilen ilk deprem 1975 Haicheng depremidir (Wang, Chen, Sun, Wang, 2006: 757-795). Ancak ilk deprem öngörülebilir olmasına rağmen 1976 Tangshan depremi tahmin edilememiştir. Öngörülemeyen bu deprem sonucunda 250.000 ölüm ve 160.000 yaralanma meydana gelmiştir (Koçak ve Mengi, 2004).

Bugüne kadar depremleri tahmin etmek için birçok yöntem, olasılık hesaplama ve analiz tekniği kullanılmıştır. Yapay zeka yöntemleri, makine öğrenmesi gibi en yaygın olarak deprem tahmininde kullanılan yöntemlerdir (Azam, Sharif, Yasmin ve Mohsin, 2014: 1495-1502). Son yıllarda yapılan araştırmalar incelendiğinde, yapay zekanın insan veya doğa olaylarını tahmin etmek ve farklı alanlardaki problemleri çözmek için kullanıldığı görülmektedir (Brykov, Petryshynets, Pruncu, Efremenko, Pimenov, Giasin ve Wojciechowski, 2020). Tahmin sırasında kullanılacak verilerin zamana göre dağılımı ve verilerin sınıflandırılması önemlidir. Zaman serileri, çoğunlukla veri sınıflandırmada kullanılan bir tekniktir. Bir zaman serisine, kronolojik sırayla listelenen bir veri koleksiyonu diyebiliriz (Faouzi ve Janati, 2020: 1-6). Bu seri kullanılarak oluşan verilerin değerlendirilmesi ve analiz edilmesi için fırsat sunmaktadır (Krischer, Megies, Barsch, Beyreuther, Lecocq, Caudron ve Wassermann, 2015).

## **B. Tezin Önemi ve Amacı**

Araştırmanın amacı, istasyonlar tarafından ölçülüp, büyüklük hesaplanan sismik verilerden yararlanarak bölgeye ait Ay'ın dünyaya uzaklığı bilgilerini ve deprem oluşumundan etkilenen diğer veri setlerini dahil ederek yaşanacak büyüklük ve olasılığı günlük olarak tahmin etmektir. Deprem tahmininde birçok sınıflandırma, farklı veri setleri, farklı lokasyonlar ve yaklaşımlarda bulunulmuştur. Bu çalışmada, Türkiye'nin Marmara Bölgesinde yer alan coğrafi konumu, 40° 49' 59" Kuzey ile 31° 10' 0" Doğu gps koordinatları olan Düzce ili seçilmiştir. Çalışma alanı olarak seçilen Düzce ili, Marmara Bölgesinde yer alan yoğun deprem faaliyetlerine sahip bir il olduğu için seçilmiştir. Çizelge 2'de Düzce iline ait 01.04.2001 – 30.04.2001 yıllarına ait örnek sismik veriler gösterilmiştir.

Çizelge 2. Düzce İli 2001 Nisan Ayı Deprem Kayıtları

Tarih	Zaman	Derinlik	Büyükük	Mesafe	Yer
1.04.2001	01:18:47.50	9	3,9	0046.54	Düzce
4.04.2001	18:56:08.50	5	2,5	0046.54	Düzce
5.04.2001	21:49:42.40	7	2,6	0046.54	Düzce
6.04.2001	04:37:59.30	8	3,0	0046.54	Düzce
7.04.2001	13:30:53.50	5	2,7	0046.54	Düzce
10.04.2001	20:24:22.20	7	3,2	0046.54	Düzce
17.04.2001	04:42:52.80	4	3,2	0046.54	Düzce
18.04.2001	21:06:03.10	8	3,7	0046.54	Düzce
19.04.2001	18:15:02.00	6	2,8	0046.54	Düzce
19.04.2001	19:10:31.50	11	2,5	0046.54	Düzce
23.04.2001	14:08:18.00	8	2,6	0046.54	Düzce
24.04.2001	23:45:18.10	8	2,9	0046.54	Düzce

Düzce ili üzerinde deprem durumun belirlenmesi, zamana bağı olarak deprem büyüklüğünün ve deprem olma olasılığının nasıl değişeceğinin ortaya konması, deprem tahmininin öngörülmesi, hata oranı hesaplaması ve kullanılan tahmin yöntemi, diğer iller içinde kullanılması açısından önem taşımaktadır.

Çalışmada, Sismik verilerin b ve d katsayıları hesaplanarak doğruluk oranları iyileştirilmiştir. Veriler, RNN yöntemi kullanılarak tahmin ve test süreçlerine tabi tutulmuştur. Sonuçlar, gerçek verilerle karşılaştırılmıştır.

## II. LİTERATÜR TARAMASI

Çalışmanın bu bölümünde, deprem tahmini için yapılmış olan yapay sinir ağları, makine öğrenmesi, hata hesaplama gibi yöntemler kullanılarak, literatürde çalışılmış olan analizler hakkında bilgi toplanmıştır.

### A. Yapılan Çalışmalar

Deprem tahminine yönelik yapılan çalışmalar incelendiğinde birçok yöntem, analiz ve sonuç ile karşılaşılmıştır. Bu sonuçlardan bazıları amaca yaklaşmış, bir kısmı ise amaca ulaşamamıştır. Yapılan literatür çalışması sonucunda aşağıda yer alan analizler incelenmiştir:

Alves (2006) tarafından yapılan çalışmada, deprem tahmini için yapay sinir ağı öneren ilk kişilerden birisidir. Yazar, Alves'in finansal tahmin görevlerinde başarılı bir şekilde uygulanan kaotik doğasının sismik aktiviteye benzeyen yaklaşımlarından ilham almıştır. Bu yöntemi, Portekiz, Azorlar bölgesinin sismik verileri üzerinde test etmiştir. Alves, Temmuz 1998'deki (MMI = 8) ve Ocak 2004'teki (MMI = 5) depremleri doğru tahmin ettiğini bilimsel olarak belirtmiştir. Ancak, hiçbir istatistiksel ölçüm hesaplanmamıştır, bu nedenle bu yaklaşımın performansı objektif olarak değerlendirilmemiştir.

Panakkat ve Adeli (2007) ile Adeli ve Panakkat (2009) yaptığı çalışmalarda, deprem tahmini problemini, önceden tanımlanmış bir zaman serisi içerisindeki en büyük sismik büyüklük aralıklarının bulunduğu çıktı sınıfları olarak düzenlemiştir. Düzenlediği bu veri setini bir sonraki ay için önceden tanımlanmış bir bölgedeki en büyük depremin büyüklüğünü tahmin etmek için kullanmıştır. Yapılan çalışmada, bir bölgenin sismik potansiyelini değerlendirmek için kullanılabilir, matematiksel olarak hesaplanmış sekiz sözde deprensellik göstergesini hazırlamışlardır (Şekil 3).

Symbol	Description	Mathematical expression
$T_{\theta}$	Elapsed time	$T = t_n - t_1$
$M_{mean}$	Mean magnitude	$M_{mean} = \frac{\sum_{i=1}^n M_i}{n}$
$dE^{1/2}$	The rate of square root of seismic energy	$dE^{1/2} = \sum E^{1/2} / T$ ( $E = 10^{(11.8 + 1.5M)}$ ergs)
$\beta$	b-value (the slope of Gutenberg-Richter curve)	$\beta = \frac{n \sum (M_i \log N_i) - \sum M_i \sum \log N_i}{(\sum M_i)^2 - n \sum M_i^2}$
$\eta$	Mean square deviation	$\eta = \frac{\sum (\log_{10} N_i - (a - bM_i))^2}{n - 1}$ ( $b = \beta$ ; $a = \frac{\sum (\log_{10} N_i + bM_i)}{n}$ )
$\Delta M$	Magnitude deficit	$\Delta M = M_{max,observed} - M_{max,expected}$ ( $M_{max,expected} = \frac{a}{b}$ )
$\mu$	Mean time between characteristic events	$\mu = \sum (t_i \text{ characteristic}) / n_{\text{characteristic}}$
$c$	Coefficient of variation	$c = \frac{STD \text{ of the observed times}}{\mu}$

Şekil 3. Tahmin İçin Oluşturulan Sekiz Sözde Formül

2009'da Neural Networks'te yayınlanan makalede yazarlar, oluşturdukları formülleri kullanarak tahmin için bir Olasılıksak Sinir Ağının (PNN) mimarisini önermişlerdir. Model, Güney Kaliforniya sismik bölgesi (33.8- 35.4 N° ve 114.75-119.25 W°) verileri üzerinde test edilmiştir ve 4.5 ila 6.0 büyüklüğündeki depremler için iyi bir tahmin doğruluğunun verdiğini kanıtlamışlardır. Ancak PNN, büyüklüğü 6.0'dan büyük depremler için tatmin edici bir performans göstermemiştir.

Reyes (2013) yaptığı çalışmada, Applied Soft Computing'de yayınlanan makalede, Yapay Sinir Ağları kullanılarak deprem tahmini için bir yöntem önermiştir. Sistem iki tür tahmin sağlamak üzere tasarlanmıştır:

a) Beş gün içinde eşik büyüklüğünden daha büyük bir depremin meydana gelme olasılığı ve

b) önceden tanımlanmış bir büyüklük aralığında sismik bir olayın meydana gelme olasılığı.

Parametreler, sırasıyla büyüklük ve depremin oluşma sıklığına göre ana şok ve artçı şoklar arasındaki ilişkileri tanımlayan Bath Yasası ve Omori-Utsu Yasasını kullanmışlardır. Yapılan bu çalışma, Şili'nin dört sismik bölgesi üzerinde analiz edilmiştir: Talca (35-36 G° ve 71-72 B°), Santiago (33-34 G° ve

71-72 B°), Pichilemu (34- 34.5 G° ve 72-72.5 W °) ve Valparaíso (32,5-33,5 S° ve 71- 72 W°). Hepsi aynı mimariyi paylaşmasına rağmen, her alana farklı bir ileri beslemeli geri yayılım yapay sinir ağı uygulanmıştır. Karşılaştırmalı analiz, en yakın komşu (KNN), destek vektör makineleri (SVM) ve K-ortalama kümeleme yoluyla standart sınıflandırma yöntemleri kullanılarak gerçekleştirilmiştir. Parametrelerin, bireysel olarak ayarlanmasına rağmen, önerilen yapay sinir ağının performansı bölgeye bağlı olarak büyük ölçüde değişiklik göstermiştir: değerler, Talca için %17.4, Santiago için %41.7, Pichilemu için %86,7 ve Valparaíso için %87'dir.

Cortés (2018) yapmış olduğu Computers & Geosciences'da yayınlanan çalışmada, yedi gün içindeki en büyük sismik olayın büyüklüğünü tahmin etme girişiminde bulunulmuştur. Panakkat ve Adeli tarafından önerilen deprensellik göstergeleri, girdi verisi olarak kullanılmıştır. Tüm veriler üzerinde modeli eğitmek sadece 18 dakika sürmüştür. Sonuçlara dayanarak, yazarlar, daha karmaşık regresör topluluklarının kullanılmasının, büyük depremler için tahminlerin doğruluğunu artıracığı sonucuna varmışlardır.

Moustra ve diğerleri (2011), Uzman Sistemler ve Uygulamalarda yayınlanan çalışmasında, farklı girdiler kullanarak deprem tahmini için yapay sinir ağının doğruluğunu değerlendirmek istenmiştir:

- İlk vaka çalışması, yalnızca zaman serisi deprem büyüklüğü verileri kullanılarak bir sonraki günün en büyük sismik olayının tahmin edilmesine yönelik,
- İkincisi çalışması, bir sonraki sismik olayın büyüklüğünü tahmin etmek için Sismik Elektrik Sinyallerinin (SES) kullanımına yöneliktir.

İlk durum için, ileri beslemeli bir geri yayılım sinir ağı kullanılmıştır. Bir girdi dosyası, her gün için maksimum büyüklük değerini içermektedir. Modelin sonucunda ortaya çıkan doğruluk oranı %58,02 olarak belirtilmiştir. İkinci durumda ise, büyüklük zaman serilerini kullanarak kayıp verileri oluşturmak için YSA kullanıldı. Büyüklük tahmininin doğruluk oranı, ilk veri setinde %60'ın biraz üzerinde olduğu belirtilmiştir.

Asim (2017), Natural Hazards dergisinde yayınlanan makalesinde, deprem tahmini incelemesi yapmıştır. Aylık olarak 5,5 ve üzeri büyüklükteki depremler için tahminler gerçekleştirmiştir. Adeli ve Panakkat tarafından önerilen sekiz deprensellik göstergesi, farklı makine öğrenimi sınıflandırıcılarına girdi seti olarak kullanılmıştır. Model, Hindukuş bölgesindeki depremleri tahmin etmek için kullanılmıştır. Sonuçları analiz edildiğinde, gözlemlenen her sistemin bir şekilde tatmin edici sonuçlar verdiğini belirtilmiştir.

Çam ve Duman (2016), Yapay Sinir Ağı Yöntemiyle Deprem Tahmini: Türkiye Batı Anadolu Fay Hattı Uygulaması isimli çalışmada, gerçekleşecek depremleri önceden kesin bilen, genelleştirilebilecek bir yöntemin günümüze kadar daha bulunamadığı bilgisini hatırlatmıştır. Yapılan bu çalışmada, Gutenberg-Richter ilişkisine bağlı ve deprem tahminlerinde kullanılan b değerini temel alan bir ileri beslemeli geri yayımlı yapay sinir ağı geliştirilmiştir. Türkiye'nin batısında yoğun sismik aktiviteye sahip dört farklı bölgeye ait deprem verileri kullanılarak yapay sinir ağı eğitilmiştir. Eğitim aşamasından sonra aynı bölgeler için daha sonraki tarihlere ait deprem verileri test için kullanılmış ve ağın başarısı ortaya konmuştur. Çalışmanın sonuçları incelendiğinde, ağın gerçekleşmeyecek dediği deprem tahmin sonuçları tüm bölgelerde oldukça yüksek çıkmıştır. Ayrıca ağın gerçekleşecek dediği deprem tahmin sonuçları, çalışılan bölgeler için belli bir oranda farklı sonuçlar vermiştir.

Balkasoğlu (2018), çalışmada Tekrarlı Yapay Sinir Ağlarının (TYSA) deprem tahmininde kullanımına yönelik bir uygulamanın gerçekleştirilmesini amaçlamıştır. Bu amaçla, Uzun-Kısa Vadeli Hafıza (UKVH) ağlarının bölgesel deprem tahmininde kullanılması sağlanmıştır. UKVH ağlarının ardışık veri kümeleri üzerinde elde ettikleri başarımlar dikkate alınarak bu ağların derin bir versiyonunun deprem verileri üzerinde uygulaması gerçekleştirilmiştir. Öncelikle beş katmanlı derin bir UKVH ağ modeli tasarlanmıştır. Deneysel çalışmalar için Türkiye bölgesinde Bingöl ili merkez alınarak bu merkez etrafındaki belirlenen yarıçaplı dairesel deprem tahmin alanları oluşturulmuştur. Bu dairesel alan içerisinde zamana bağlı olarak ardışık bir şekilde meydana gelen depremler UKVH ağının eğitiminde kullanılmıştır. Eğitimi tamamlanan ağın aynı bölge üzerinde gelecekte meydana gelecek depremleri tahmin etmesi sağlanmıştır. Dairesel olarak 50km, 100km ve 200km yarıçapında tahmin bölgeleri



kullanılmıştır. Bu yarıçaplar arasında meydana gelen 2 ve 9 şiddetleri arasındaki hareketlilikler kullanılmıştır. Elde edilen tahmin sonuçları değerlendirildiğinde, uygulamanın deprem tahminlerini kayda değer bir doğrulukta tahmin ettiği gözlemlenmiştir.

Köle (2016), yaptığı çalışmasını, tektonik açıdan Çankırı ili üzerinde gerçekleştirmiştir. Çalışmanın amacı, seçili stokastik yöntem yardımıyla Çankırı il sınırları içerisinde farklı deprem olma olasılıklarının ve dönüş periyotlarının hesaplanmasıdır. Çalışma genelinde, Richter ölçeğine göre dört ve dörtten büyük olan deprem verilerinden faydalanılmıştır. Çankırı ili için Gutenberg – Richter (1954) büyüklük – sıklık (frekans) bağıntısından itibaren Poisson (1838) yöntemi kullanılarak farklı büyüklüklerdeki depremlerin oluşma olasılıkları ve dönüş periyotları hesaplanmıştır. Çalışma sonuçlarına göre; Çankırı’da 100 yıllık dönemde, büyüklüğü ( $xM$ ) 6,0, 6,5 ve 7,0 olan yıkıcı depremlerin ortaya çıkma olasılığı sırası ile %78, %45 ve %26 olarak hesaplanmıştır.

Sebatlı-Sağlam ve Çavdur (2022), çalışmasında ileri beslemeli geri yayımlı bir yapay sinir ağı ile depremin büyüklüğü, derinliği ve afetzedelerin merkez üssüne olan uzaklıklarına bağlı olarak deprem şiddeti tahmini yapılmıştır. Farklı yapay sinir ağı tasarımları için deprem şiddeti tahmin edilerek uygun bir ağ tasarımı elde edilmiştir. Ardından söz konusu uygun ağ tasarımı için farklı eğitim algoritmaları kullanılarak ağ eğitilmiş ve bu algoritmalar arasından en uygun eğitim yöntemi belirlenmiştir. Farklı ağ tasarımlarının ve eğitim algoritmalarının performansları, ortalama karesel hata ve korelasyon katsayısı cinsinden analiz edilmiştir. Performans parametrelerinin ortalaması açısından, iki gizli katman ve her bir katmanda sırasıyla beş ve on gizli nöronun bulunduğu ağ yapısı en uygun tasarım olarak belirlenmiştir. Söz konusu ağ yapısı için Bayes Düzenlemesi ile Levenberg-Marquardt eğitim algoritmasının kullanıldığı durumda performans parametreleri açısından en iyi sonuçlar gözlenmiştir.

Özmen (2011), Kastamonu ve Yakın Çevresi İçin Deprem Olasılığı Tahminleri isimli çalışmasında, I. derece deprem bölgesinde yer alan Kastamonu ilini incelemiştir. Kastamonu’nun depremselliği kent merkezini 150 km çevreleyecek şekilde çizilen bölge içine düşen, 1900-2011 yılları arasında meydana gelmiş ve magnitüdü  $M \geq 4.0$  olan deprem verilerinden yararlanarak incelenmiştir. Depremlerin büyük bir çoğunluğu Kastamonu’nun güneyinde

Kuzey Anadolu Fay Zonu, Dodurga fayı, Eldivan – Elmadağ tektonik kaması, Merzifon fayı ve Taşova – Çorum fay zonu üzerinde meydana gelmiştir. Çalışmada, Kastamonu kent merkezini 50, 100 ve 150 km çevreleyecek şekilde çizilen ve sismotektonik bölge olarak kabul edilen dairesel alanlarda meydana gelmiş  $M \geq 4.0$  olan deprem verilerinden yararlanarak her bölge için Gutenberg – Richter magnitüd – frekans bağıntısındaki a ve b parametrelerini bulmak, bu parametrelerden yararlanarak ve Poisson modelini kullanarak farklı büyüklükteki depremlerin meydana gelme olasılıkları ve bunların dönüş periyotlarını tahmin etmektir. Her bölgenin deprem oluşma olasılıkları 10, 20, 30, 40, 50, 75 ve 100 yıl ve büyüklüğü 5.0, 5.5, 6.0, 6.5, 7.0 ve 7.5 olan depremler için hesaplanmıştır. Bu çalışma ile 150 km yarıçaplı bir bölge içinde büyüklüğü  $M \geq 7.5$  olan bir depremin 100 yıl içinde gerçekleşme olasılığı % 75 olarak bulunmuştur.

Özmen (2013), Ankara için Deprem Olasılığı Tahminleri isimli çalışmasını, Ankara ili üzerinde gerçekleştirmiştir. Çalışmasında, Ankara kent merkezini 50, 100 ve 150 km çevreleyecek şekilde çizilen ve sismotektonik bölge olarak kabul edilen yerlerde meydana gelmiş  $M \geq 4.0$  olan deprem verilerinden yararlanarak her bölge için Gutenberg – Richter büyüklük – sıklık bağıntısındaki a ve b parametrelerini bulmak, bu parametrelerden yararlanarak ve Poisson yöntemini kullanarak farklı büyüklükteki depremlerin meydana gelme olasılıklarını ve dönüş periyotlarını tahmin ederek Ankara'nın deprem tehlikesini belirleme çalışmalarına katkı sağlamayı hedeflemiştir. Çalışmanın amacı, geliştiren yeni bir teori olan deprem patlama teorisine dayalı kısa vadeli bir deprem tahmin yazılımı geliştirmeyi ve doğrulamayı amaçlamaktadır.

Tareen, Nadeem, Kearfott, Abbas, Khawaja ve Rafique (2019)'nın deprem tahmini üzerine yaptıkları çalışmada, radon anomalilerinin meteorolojik parametreler ve deprem oluşumu ile korelasyonu rapor edilmiştir. Bu makale, toprak radon zaman serisi verilerine dayalı betimleyici istatistiksel analiz ve kutu grafiği koşullu deprem tahminini bildirmektedir. Muzaffarabad'ın altından geçen bir fay hattı üzerinden bir yıllık süre için veri toplanmıştır. Toprak radon gazı (SRG), RTM 1688-2 radyometrik alet kullanılarak ölçülmüştür. Topraktaki radon aralığı, 14349 Bqm-3, sıcaklık, basınç ve bağıl nem aralıkları sırasıyla %38,50 CO<sub>2</sub>, 29mbar ve %67 olarak bulunmuştur. SRG verileri, zaman serilerinin normal dağılıma uyduğunu göstermektedir. Varyasyon katsayısı (CV) değerleri, toprakta

ve metrolojik parametrelerde kaydedilen radon deęerlerinin tutarlılıęını gsterir. Varyans ŐiŐirme faktr (VIF) ve Durbin Watson testi (d), deęiŐkenler arasında orta dzeyde oklu baęlantı ve otokorelasyon olduęunu gstermektedir. Kutu grafikleri ve meteorolojik parametreler kullanılarak radon zaman serilerinin analizi, deprem ncesi yeraltı sismik faaliyetlerine baęlı olarak radon konsantrasyonlarında (aykırı deęerler, deęiŐken IQR'ler, ilk eyrek deęerler ve medyan deęerler) belirli modeller gsterir. Bu modellere dayanarak, karmaŐık tahmin sistemleri kullanılmadan deprem daha erken tahmin edilebileceęi gzlenmiŐtir. Boxplots ayrıca, bu alıŐmada llen meteorolojik faktrlerin daęılımında nemli bir model bulunmadıęını da tahmin etmiŐtir. Bu alıŐma, depremi tahmin etmeye ynelik ilk giriŐimdir.

Asim, Idris, Iqbal ve Martınez-lvarez (2018) yapmıŐ oldukları alıŐmada, sismik gstergelerin Genetik Programlama (GP) ve AdaBoost (GP-AdaBoost) tabanlı topluluk yntemi ile birleŐtirilmesiyle bir deprem tahmin sistemi nermiŐlerdir. Sismik gstergeler, blgenin sismik durumu hakkında maksimum bilgi elde etmek iin gstergelerin hesaplandıęı yeni bir metodoloji ile hesaplanmaktadır. Hesaplanan sismik gstergeler, bir Deprem Tahmini sistemi (EP-GPBoost) geliŐtirmek iin GP-AdaBoost algoritması ile birlikte kullanılır. Kurulum, depremden on beŐ gn nce, 5.0 ve zeri byklkteki depremler iin tahminler saęlamak zere dzenlenmiŐtir. Hindukush, Őili ve Gney Kaliforniya blgeleri deney iin kullanılmıŐtır. EP-GPBoost, sırasıyla GP ve AdaBoost'un gl arama ve glendirme yeteneklerinin iŐbirlięi sayesinde deprem tahmininde gzle grlr bir geliŐme saęladıęı grlmüŐtr. Deprem tahmin sistemi, aędaŐ sonulara kıyasla, dikkate alınan  blge iin doęruluk, kesinlik ve Matthews Korelasyon Katsayısı aısından geliŐmiŐ sonular gstermektedir.

Gentili, ve Di Giovambattista (2022) yapmıŐ oldukları alıŐmada, ana Őoka benzer veya daha byk deprem byklęine sahip gl depremleri tahmin etmek iin sismik kmeleri analiz eden NESTORE isimli bir makine ęrenimi yaklaŐımını nermektedirler. Yntem, ana Őoktan sonraki ilk saatlerde ya da gnlerde sismisiteyi analiz eder ve ardından gl bir deprem olma olasılıęını ngrr. Analiz, zaman iindeki bilgi artıŐını simle etmek iin zamanın eŐitli aŐamalarında gerekleŐtirilmektedir. Ayrıca, bir jackknife yaklaŐımına

(rNESTORE) dayalı daha sağlam bir NESTORE yöntemi geliştirmektedirler ve bunu California sismisitesine başarıyla uygulamaktadırlar.

Şentürk, Saqib ve Adil (2022) yaptıkları çalışmada, Çoklu Ağ tabanlı Hibrit Uzun Kısa Süreli Bellek (Multi-Network-based Hybrid Long Short Term Memory) (N-LSTM) modelini önermiştir. Önceden amaçlanan modeller, kaybolan gradyan, patlayan gradyan, belirsizlik ve parametre yanlılığı gibi sorunlar yaşandığı gözlenmiştir. LSTM, kaybolan ve patlayan gradyan problemlerinin üstesinden gelmek için kullanılmaktadır. Yöntem üzerinde, 25 Nisan 2015'te meydana gelen Mw 7.8 Nepal Depremi (EQ) kullanılarak modelin çalışması gözlenmiştir. Önerilen model, yaklaşmakta olan EQ'dan yaklaşık 14 gün önce önemli bir negatif anomali tespit edilmiştir. Ayrıca, ana şoka kadar dört gün boyunca (21-24 Nisan 2015) TEC değerlerinin pozitif anomaliler açısından kademeli olarak arttığı, TEC zaman serisinde kademeli artışlar olarak gözlenmiştir. N-LSTM sonucu, iyonosferik anomali tespitinin klasik yöntemi 30 günlük çalışan medyan ile uyumludur. Ayrıca, gezegensel K-endeksi (Kp), bozucu fırtına zamanı (Dst), güneş radyo akısı (F10.7) ve güneş rüzgar hızı (VSW) endekslerini de çalışmada incelenmiştir. Sonuçlar, iyonosferik TEC anomalilerinin gece saatlerinde uzay havasından daha baskın olarak EQ fenomeninden kaynaklandığını belirlenmiştir. Ayrıca, N-LSTM, iyonosferik TEC ve anormallik tespiti için yeterli kısa vadeli tahmin performansı sağlamıştır.

Essam, Kumar, Ahmed, Murti, ve El-Shafie (2021), Malezya Yarımadası'nın doğu kıyısında yer alan Terengganu, son kırk yılda üç deprem yaşamış ve sismolojik olarak aktif Manila Açması'nın bulunduğu Güney Çin Denizi civarındaki konumu nedeniyle depremlerden etkilenme veya depremlerden etkilenme potansiyeline sahip olduğu için analiz alanı olarak seçerek çalışmalarını gerçekleştirmişlerdir. Terengganu'da deprem ivmesi, derinlik ve hız gibi yer hareketi parametrelerini tahmin etmek için bir araç olarak yapay sinir ağı (YSA) modelleri önerilmektedir. Ancak bu çalışma, YSA sonuçlarının Rassal Orman (RF) sonuçlarıyla karşılaştırmasını sunmaktadır. Modelleri geliştirmek için kullanılan veriler, Terengganu'da iki kanal için altı sismoloji istasyonu tarafından toplandı ve Malezya Meteoroloji Departmanı tarafından sağlandı. Veriler, her bir kanaldaki her bir yer hareketi parametresi için altı sete bölündü ve her set, eğitim için beş istasyon ve test için bir istasyondan oluşan farklı bir

gruplandırmadan gelen verileri kullandı. Deprem derinliği, giriş parametresi olarak yalnızca ilgili çıktı parametresi olan deprem derinliği kullanılarak, tek değişkenli doğrulukla modellenemedi. Deprem ivmesi ve hızı, tek değişkenli doğrulukla modellenememiştir ve deprem derinliği bir girdi parametresi olarak eklenerek iyileştirilmiştir. Seçilen dört performans kriteri kullanılarak sonuçların analizine ve değerlendirilmesine dayanan YSA modelleri, deprem ivmesi, derinliği ve hızını tahmin etmede iyi performans gösterdiği sonucuna varılmıştır.

Jena, Naik, Pradhan, Beydoun, Park ve Alamri (2021)'nin yaptıkları araştırmada, Hindistan'ın tamamı için deprem hassasiyetini değerlendirmek için ilk kez LSTM modeli uygun Geospatial Information Systems (GIS) teknikleri ile uygulanmıştır. Hindistan'da, mevcut sismik güvenlik açığı değerlendirmesinin çoğu, geleneksel teknikleri kullanan şehir veya eyalet düzeyindedir. Arazi kullanımı, jeoloji, jeomorfoloji, fay dağılımı, ulaşım kolaylığı, nüfus yoğunluğu gibi çeşitli faktörlerin tümü, sosyal, yapısal ve jeoteknik kırılganlık haritalarını geliştirmek için kullanılmıştır. Sonuçlar, Delhi, Hindistan'ın NE bölgesi, Gujrat'ın büyük bölümleri, Batı Bengal ovasının etrafındaki alanların yüksek ila çok yüksek sismik kırılganlık sergilediğini göstermektedir. Bu model %87.8 doğruluk, duyarlılık (%90) ve özgüllük (%84.9) elde etmiştir. Mevcut analiz, risk azaltma müdahalelerine daha fazla ihtiyaç duyan bölgelerin önceliklendirilmesine yardımcı olabileceği düşünülmektedir.

Asim, Moustafa, Niaz, Elawadi, Iqbal ve Martínez-Álvarez (2020), yaptıkları çalışmada, Kıbrıs bölgesi için deprem kataloğuna dayalı sismisite analizine odaklanmaktadır. Bunu, makine öğrenme teknikleri kullanılarak sismik özelliklerin hesaplanması ve sismik aktivitenin kısa vadeli tahmini takip etmektedir. Deprem kataloğu geçici olarak incelenmiştir ve gürültülü veriler çıkartılmıştır. Daha sonra bölgenin iç sismik durumunu ifade etmek için temizlenmiş deprem kataloğuna dayalı olarak altmış sismik özellik hesaplanmıştır. Bu sismik özellikler daha sonra ilgili sismik aktivite ile makine öğrenme teknikleri kullanılarak modellenmektedir. Sismik aktivite tahmini için Yapay Sinir Ağları, Destek Vektör Makineleri ve Rassal Ormanlar olmak üzere üç makine öğrenme algoritması kullanılmıştır. Yapı, 3.0, 3.5, 4.0 ve 4.5'lik moment büyüklük eşikleri için beş gün öncesi, bir hafta öncesi, on gün öncesi ve on beş gün öncesi tahminleri elde etmek üzere tasarlanmıştır. Matthews

korelasyon katsayısına (MCC) dayanarak, Rassal Orman kullanılarak elde edilen tahminlerin, tüm tahmin periyotlarında 3.0 ve 3.5 büyüklük eşikleri için en doğru olduğu bulunmuştur. Benzer şekilde, Destek Vektör Makinesi kullanılarak elde edilen tahminler, 4.0 ve 4.5 büyüklük eşikleri için diğer tekniklerden daha iyi performans gösterdiği izlenmiştir.

Al Banna, Ghosh, Al Nahian, Taher, Kaiser, Mahmud ve Andersson (2021), yaptıkları çalışmada bir deprem oluşumu ve yer tahmini modelini önermişlerdir. Hafıza tutma yeteneği nedeniyle model oluşturmak için uzun kısa süreli hafızanın (LSTM) iyi bir seçenek olduğu bulunmuştur. Keras tuner kullanılarak, çeşitli LSTM mimarileri ve yoğun katmanların kombinasyonlarından oluşan aday modellerden en iyi model seçilmiştir. Bu seçilen model, bir sonraki ayın depremlerini tahmin etmek için özellikler olarak Bangladeş deprem kataloğundaki sismik göstergeleri kullanmıştır. Modelin %74,67 olan deprem oluşum tahmin doğruluğunu iyileştirmek için LSTM mimarisine dikkat mekanizması eklenmiştir. Ek olarak, deprem merkez üssünü önceden tanımlanmış bir konumdan bir mesafe olarak tahmin etmek için LSTM ve yoğun katmanlar kullanılarak bir regresyon modeli inşa edilmiş ve bu da 1.25'lik bir ortalama karekök hatası sağladığı gözlenmiştir.

Bai ve Tahmasebi (2022), Derin öğrenme modeli ConvNetQuake'in sismik olayları tespit etme ve bulma konusundaki başarılı uygulamasından esinlenerek, sismik olayların tespitini ve konum doğruluğunu iyileştirmek için dikkat tabanlı uzun kısa süreli bellek tam evrişimli ağ (LSTM-FCN) modeli kullanılmıştır. Ayrıca farklı özellikleri ayrı ayrı çıkarmak ve daha iyi sınıflandırma için ve bir vektör olarak birleştirmek için FCN ve LSTM'nin paralel bir yapısını kullanılmıştır. Eğitilen modelin, ConvNetQuake modeline kıyasla yüzde 14,5 iyileştirmeyi temsil eden yüzde 89,1'lik bir sınıflandırma doğruluğuna sahip olduğunu gösterilmiştir. Ayrıca, ConvNetQuake modeli yalnızca sismik olayları kabaca altı coğrafi bölgeden birinde sınıflandırmayı düşünmüştür. Ancak modelde, nispeten yüksek bir doğruluk korunurken, sismik olayları 15'e kadar daha fazla sayıda bölge olarak sınıflandırarak daha yüksek bir çözünürlükle bulunacağı görülmüştür. Ayrıca, dahil edilen dikkat mekanizmasının, önemli özellik haritalarını ve girdilerini otomatik ve seçici bir şekilde geliştirerek

sınıflandırma performansını etkili bir şekilde iyileştirebileceğini çalışmada ifade edilmiştir.

Shi ve Cheng (2022) yaptıkları çalışmada, Sichuan ve Yunnan ( $24^{\circ}\text{K}$ - $32^{\circ}\text{K}$ ,  $98^{\circ}\text{D}$ - $106^{\circ}\text{D}$ ) bölgesindeki deprem kataloğuna dayalı olarak, depremlerin mekansal ve zamansal şiddet dağılım özelliklerini yansıtan 16 sismisite göstergesi kullanılmıştır. Çalışma alanının 9 alt bölgesinde, gelecek yıl maksimum deprem büyüklüğünü tahmin etmek için kayan uzay-zaman penceresi ve uzun kısa süreli bellek (LSTM) sinir ağı kurulmuştur. İki farklı eğitim test modeli, eğitim seti: test seti=8:2 ve eğitim seti: test seti=7:3, geçmiş depremleri geriye dönük olarak tahmin etmek için kurulmuştur. Sonuçlar, eğitim seti: test seti=7:3 modelinin Ocak 1970 ile Eylül 2004 arasındaki deprem kataloğundan öğrenebileceğini ve 2008 Wenchuan depreminin geriye dönük olarak tahmin edilebileceğini göstermektedir. 2010-2019 yılları arasında M6'nın üzerindeki depremlerin geriye dönük tahmininin R puanı 0.407'dir ve yukarıdaki depremlerin geriye dönük tahmininin doğruluğu M7 %92.31 kadar yüksektir.

Sarkar, Roy, Kumar ve Das (2021) yaptıkları çalışmada, bir Çok Katmanlı Algılayıcı-sınıflandırıcı, MMI ölçeğinde hasar veren yoğunluklarla ilgili önceden eğitilmiş bir Tepe Yer Hızlandırma eşiğini aşma olasılığını tahmin ederek, takip eden şiddete dayalı uyarı sağlamak için modellenmiştir. Sınıflandırıcının denetimli öğrenmesi, p dalgasının başlangıcından sonra kuvvetli hareket sinyalinden çıkarılan sismik özellikleri kullanılmıştır. Yoğunluk sınıfı tahmininin F puanını %79'dan %91'e yükselten katmanlı bir diferansiyel özellik penceresi yeniden örneklemesi uygulanmaktadır. Eğitilen model, Gerçek Zamandan Daha Hızlı (FTRT) simülasyon ortamında gerçekleştirilmiş ve %89 doğrulukla tahminde bulunarak erken uyarı için deprem şiddet sınıflarının tahmini için kayan pencerelerle test edilmiştir. Hindistan Ulusal Başkent Bölgesi'nden yaklaşık sekiz bin deprem dışı sismik olaydan oluşan bir sismik veri seti, dört yıllık bir süre boyunca gelişmiş sismik algılama düğümleri (SSN'ler) filosu kullanılarak oluşturulur. Oluşturulan bu veri kümesindeki çapraz veri kümesi doğrulaması %95,98 doğruluk göstermiştir.

Murwantara, Yugopuspito ve Hermawan (2020) yaptıkları çalışmada, Endonezya bölgesine ait, 100'den fazla aktif volkan ve yılda çok sayıda sismik aktivite ile çoğu deprem bölgesini incelemiştir. 2 yerel yönetim organı ve 8 meşru

uluslararası kaynaktan toplanan orta ve uzun vadeli deprem geçmişi verilerini kullanmaktadır. Multinomial Logistic Regresyon, Support Vector Machine ve Naïve Bayes olan Machine Learning algoritmaları ile orta-uzun vadeli bir tahminde bulunarak performanslarını karşılaştırılmıştır. Yapılan analizde, Destek Vektör Makinesinin diğer yöntemlerden daha iyi performans gösterdiği tespit edilmiştir. Çok Terimli Lojistik Regresyonun 0,777, Naïve Bayes'in 0,922 ve Destek Vektör Makinesinin 0,751 olduğu durumlarda, verilerin en uygun çizgi etrafında ne kadar yoğunlaştığına dair bizi yönlendiren Hata Karesi Kökü hesaplama sonuçları karşılaştırılmıştır. Gelecekteki depremi tahmin etmede Destek Vektör Makinesi, mevcut deprem raporuna önemli mesafe ve büyüklük üreten diğer iki yöntemden daha iyi performans gösterdiği belirlenmiştir.

Kollam ve Joshi (2020) yaptıkları çalışmada, veri için sismik istasyonlar, belirli bir bölgedeki zeminin titreşimi ve hareketi ile ilgili verileri sürekli olarak izlenmiştir ve toplanmıştır. Toplanan veriler, Karayip bölgesindeki depremlerin oluşumunu tahmin etmek için model tarafından işlenmiştir. Burada, Grafik İşlem Birimi (GPU) kullanarak depremleri tahmin etmek için bir Paralel Destek Vektör Regresyon (PSVR) modeli kullanılmıştır. GPU kullanan bir PSVR uygulamasında, GPU üzerinde Genel Amaçlı Hesaplama için ünlü bir programlama yapısı olan Computing Unified Device Architecture (CUDA) çerçevesi kullanılmıştır. Bu yeni hesaplanan PSVR modeli, Merkezi İşlem Birimi (CPU) ve GPU'daki Scikit Learn ve LibSVM kitaplığı ile karşılaştırıldığında eğitim hızında önemli bir gelişme gösterdiği gözlenmiştir. Ayrıca %92'lik bir doğruluk elde ettiği görülmüştür.

Florios, Contopoulos, Tatsis, Christofilakis, Chronopoulos, Repapis ve Tritakis (2021) yaptıkları çalışmada, dar bir zaman-uzay içinde deprem tahmini için potansiyellerini test etmek adına, genelleştirilmiş doğrusal Lojistik Regresyon—LogReg ve doğrusal olmayan Rassal Orman—RF olmak üzere iki çok-parametrik istatistiksel yöntemle genişletilmiş bir Schumann Rezonans kayıtları zaman serisini analiz etmişlerdir. Analizde, 48 saat büyüklük penceresi, gözlem alanımızdan 250 km ve Richter ölçeğinin 4 büyüklüğünden daha yüksek olaylar incelenmiştir. LogReg yöntemi, 10 dakikalık kayıt aralıklarımız içinde sinyalin gücünü ana sismik haberci parametresi olarak tanımlanmıştır. RF



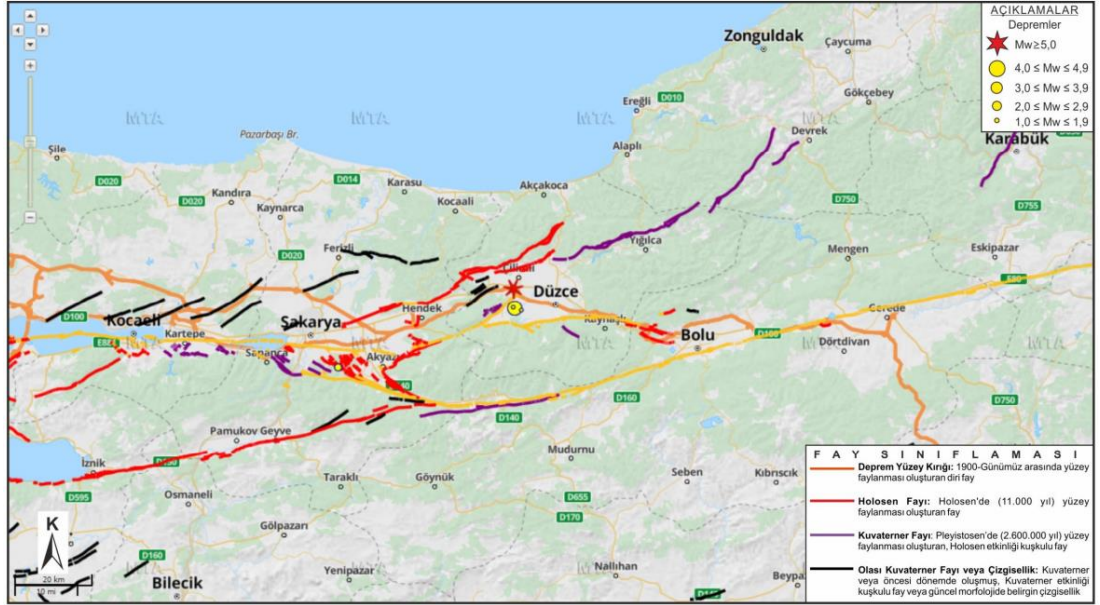
yöntemi, çalışan veri örneğinin yeni verilerle sürekli zenginleştirilmesiyle gelecek umut verici sonuçlar elde ettiği görülmüştür.

### III.ÇALIŞMA ALANININ GENEL ÖZELLİKLERİ

#### A. Düzce İli

Çalışma alanı olarak, Türkiye'nin Marmara Bölgesi sınırları içinde yer alan Düzce ili seçilmiştir. Düzce konumu, 40.8333 enlem ve 31.1667 boylamda yer almaktadır (Öztürk ve Toprak, 2016: 902-910). Düzce ilinin seçilmesinin esas nedeni I. derece deprem bölgesinde (aktif deprem kuşağı) yer alması ve bu il üzerinde daha önceden bir çalışma yapılamamasıdır.

Düzce bölgesi, güneybatıya doğru 0.5-3 derecelik eğime sahip ova üzerinde yer almaktadır. Bölgenin güneyinde bulunan Düzce Fay hattına yaklaşık 7 km mesafededir. Bölge içerisinde yer alan Gölyaka ilçesi, 17 Ağustos depreminde kırılma gösteren aktif fayın üzerinde bulunmaktadır. Düzce ilinin harita üzerinde, fay hattı görüntüsü Şekil 4'de gösterilmiştir (koeri.boun.tr, 2022).



Şekil 4. 17.11.2021 Düzce İli Depreminin Ve Artçı Depremlerin Haritası

Kaynak: (koeri.boun.tr, 2022)

## **IV. MATERYAL VE ANALİZ AŞAMASI**

### **A. Materyal**

Çalışmamın en önemli amacı, Marmara Bölgesi sınırlarında yer alan Düzce iline ait deprem istasyonlarından elde edilen deprem büyüklükleri (Magnitude(M)), Enlem(N), Boylam(E), Derinlik(km), Lokasyon ve Zaman verileri ile birlikte Ay'ın Dünyaya Uzaklığı, depremin b ve d kat sayılarının deprem üzerindeki etkilerinin beraber değerlendirilmesidir. Bu amaç doğrultusunda, Düzce iline ait enlem ve boylam bilgileri, dairesel bir çevre belirlenerek, 1990 – 2022 arasında meydana gelmiş deprem büyüklükleri ele alınmıştır. Deprem büyüklüğünü destekleyecek ve depremin oluşumunda etkisi olduğu düşünülen Ay'ın Dünyaya Uzaklığı, veri seti olarak sisteme dahil edilmiştir. Bu veriler, depremin gerçekleştiği tarihe yakın zaman dilimi içinde oluşan Ay'ın dünyaya uzaklık bilgisidir.

Gerçek deprem büyüklüklerinin b ve d kat sayıları hesaplanmıştır. Veri seti oluşturulmuştur.

Ayrıca tahmin ve test aşamasında kullanılmak üzere, 2022 – 2030 tarihleri arasında yaşanacak Ay'ın dünyaya uzaklık bilgisi, veri tabanında kayıtlı tutulmaktadır.

### **B. Analiz Aşaması**

#### **1. Deprem Tahminine Genel Bakış**

Depremin gerçekleşmesinden önce yaşanacak depremin olasılığının hızlı tespiti için Yapay Zekanın (Derin Öğrenme / Makine Öğrenimi) sağladığı olanaklardan faydalanarak araştırmaların yapılıp, sonuçların değerlendirilmesi önemlidir. Deprem verileri, statik bir yapıya sahip olmadığı ve sürekli değişkenlik gösterdiği için depremin tahmin olasılığı oldukça zordur (Khan, Choi ve Kwon, 2020: 800). Farklı veri setleri, mevcut yaklaşımlar üzerinde deneme çalışmaları yapılarak doğruluk oranı ortaya çıkarılmalıdır. Geçmiş dönemlerde

yapılan çalışmalar göz önünde bulundurulduğunda, tek bir veri özellik seti ile %100 doğruluk oranına ulaşılmadığı sonucuna varılmıştır. Bir depremin oluşumunu incelerken depremin olduğu bölge, derinliği, bölgenin coğrafi yapısı, atmosferik yapısı gibi öz nitelikler tahmin aşamasında kullanılan veri setleri olmalıdır. Depremin meydana gelmeden önceki ve sonraki durumların incelenmesi gerektiği ve benzerlik oranlarının değerlendirilmesi doğru bir sonuca ulaşmak için gerekli verilerdir. Deprem meydana gelmeden önce ve sonrasında minimum ve maksimum hava durumu, hava basıncı, ayın ve güneşin bölgeye uzaklığı vb. nitelikler değerlendirme aşamasında ek katman olarak kullanılmalıdır. Özellik veri seti arttıkça olasılık tahmin oranının da doğru orantılı olarak artacağı düşünülmektedir.

## **2. Verilerin Düzenlenmesi**

Sismik veriler, Kandilli Rasathanesi Deprem Araştırma Enstitüsü tarafından bilimsel olarak ölçülen verilerdir. Depremin meydana gelmesinden sonra sismologlar tarafından ölçülen sismik veriler, sunuculara kaydedilmektedir. Kayıt edilen bu veriler, oluşturulan .xml uzantılı dosya ile eş zamanlı olarak kendi veri tabanımıza eklenmektedir. Veriler arasında eksik veri bulunmamaktadır. Bu veriler içinde yer alabilecek gürültü, patlatma vb. kaynaklar yok edilerek tasarım yapılmıştır.

## **3. Veri Analizi Ve Tahmin Süreçleri**

Günümüzde kullanılan, bilgiye yönelik birçok sistem, veri analizinin tam anlamıyla sağlanması için yetersiz düzeyde kalmakta ve analizin sağlanması için çok gelişmiş sistemlere ihtiyaç duymaktadır (Garcia, 2014). Analizi iyi yapan bir sistemin geliştirilmesi için en önemli kaynak, ihtiyaç duyulan bilginin tam ve net olarak sağlanmasıdır. Bilginin eksiksiz elde edilmesi ve düzenlenmesi için veri madenciliğinden faydalanılabilir. Veri madenciliği, birçok alanı (yapay zeka, makine öğrenimi, veri işleme ve görselleştirme vb.) birbirine bağlayan geniş boyutlu bir kavramdır (Özekes, 2003).

Makine öğrenmesi, edinilen bilginin elektronik ortamda detaylı analizi, bilginin öğrenmesi ve bu öğrenilen bilgi doğrultusunda gelecekte oluşacak yeni bilgileri değerlendirip, geçmiş deneyimlere bağlı olarak sonuç üretebilmesidir (Kutlugün, 2017). Makine Öğrenmesi, tıp, kimya, bilişim, jeoloji, jeofizik vb.

birçok alanda veri analizi için kullanılmaktadır. Jeofizik alanında makine öğrenmesi yaygın olarak kullanılmakta ve birçok çalışma literatürde yer almaktadır. Bu alandaki çalışmaların çoğu, depremin önceden tahmini ya da deprem oluşuktan sonra depremin etkilerini en aza indirme ile ilgili çalışmalardır. Diğer birçok alanda olduğu gibi Jeofizik alanında da makine öğrenmesi önemli bir kavramdır. Bunun nedeni, sistem üzerinde, geleneksel yöntemleri kullanarak, verileri analiz yapmak için gerekli yetkinin insanda olması yerine, tüm yetki ve yönlendirmeyi yonteme ait algoritmaya bırakmaktır (Obermeyer ve Emanuel, 2016: 1216–1219). Kullanılan yonteme ait algoritmanın, verileri iyi deęerlendirmesi gerekmektedir: verileri doęru sonuca gtrme, eksik ya da hatalı verileri denetleme, gçl ve hızlı deęerlendirme – yanıtlama vb. (Kononenko, 2001: 89–109).

Makine öğrenmesi kullanan birçok alan olduğu ve her alan birbirinden farklı veri setleri kullandığı için tek bir model ya da yontemin kullanılması mümkün deęildir. Bu nedenle verilere gre model ve yontem seęilmeli ya da yeni bir yapı retilmelidir (Alpaydin, 2014). Bununla birlikte, algoritmanın kullanımı olduğu kadar veri seti de önemlidir. No Free Lunch Teoremi ile de makine öğrenmesi için kullanılan algoritmaların birbirleri ile eę dzeyde olduğu belirtilmiştir (Zakaria ve Zamli, 2017).

Makine Öğrenmesi algoritmalarının haricinde Ensemble Yontemler (Topluluk Öğrenmesi) sıklıkça kullanılan yaklaşımlardır (Zhou, 2009: 270–273). Bireysel yapılan tahminler yerine, grup tahminlerinin toplu sonuçları deęerlendirilmektedir. Diğer bir ifade ile Rassal Orman (Random Forest, RF), Destek Vektr Makineleri (Support Vector Machine) ve Lojistik Regresyon (Logistic Regression) kullanarak sınıflandırıcı topluluk ile grubun verdięi ortak tahmin, sonu olarak deęerlendirilir. Tahmin için Linear Regression, Multiple Linear Regression, Polynomial Regression, Decision Tree, Random Forest, Vector Regression sıklıkla kullanılan algoritmalarlardır (Gltepe, 2019). Bylece, doęruluk bir kademe daha artmış olmaktadır (Zhou, 2009: 270–273).

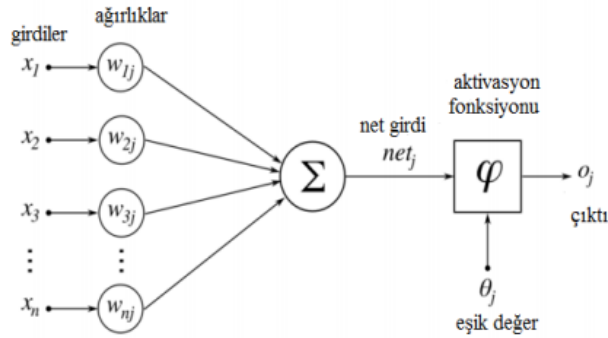
#### **4. Yapay Sinir Aęları**

Makine Öğrenmesi matematiksel ve istatistiksel yontemler kullanarak mevcut verilerden ıkarımlar yapan, bu ıkarımlarla bilinmeyene dair tahminlerde

bulunan bir yöntemdir. Makine öğrenmesi 1950'lerin sonlarında yapay zeka tekniği olarak tanıtılmaktadır (Bingöl, Aslı, Örmecioğlu ve Arzu, 2020: 2197-2210).

Doğrusal yapıya sahip olmayan veriler üzerinde analiz yapabilmek ve verileri düzenleyebilmek için Yapay Sinir Ağlarını, sınıflandırma, tahmin etme, regresyon gibi işlemler için kullanabiliriz (Yiğiter, Sarı ve Başakın, 2017). Yapay Sinir ağları ile aynı insan beynini kullanıyormuş gibi verileri analiz edip, bilgileri hafızada tutup, yeni bilgiler üretebiliriz. Yapay sinir ağlarını aynı insan beynindeki nöronlara benzetebiliriz (Uysal, 2009). İnsan beyninde nöronların birbirine bağlı olması gibi yapay sinir ağlarında da verinin girişi, işlenmesi ve çıkışı gibi değişik seviyelerde bütün işlem yapısının birbiri ile bağ kurması ile oluştuğunu söylemek mümkündür (Öztemel, 2003).

İnsan beynindeki nöronlara benzetilen yapay sinir ağlarını Şekil 5'de belirtilen görsel gibi düşünebiliriz. Girdi değerleri  $x_1, x_2, \dots, x_n$  ve ağırlık değerleri  $w_1, w_2, \dots, w_n$  olarak ifade edilmiştir (Mazanoğlu, 2017).

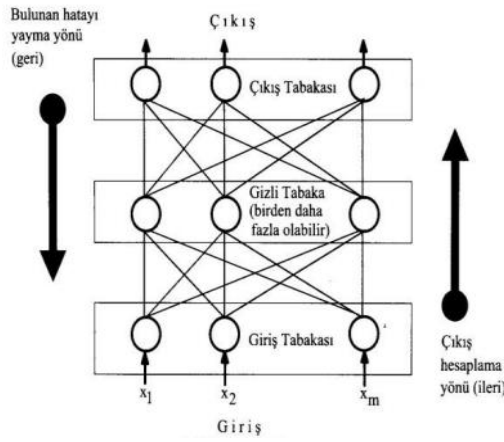


Şekil 5. Yapay Sinir Ağı (YSA) Modeli

Kaynak: (Mazanoğlu, 2017)

Şekil 5'te belirtilen model en basit haliyle YSA'nın yapısını ifade etmektedir (Mazanoğlu, 2017). Bu model üzerinden doğru bir eğitimi sağlamak istersek ağırlık değerleri revize edilerek yeni çıktılar oluşturabiliriz. Ayrıca kullanılan veriler doğrusal bir yapıya sahip olmadığı için çok katmanlı bir yapı kullanmak faydalı olacaktır. Şekil 6'da belirtilen görselde çok katmanlı bir YSA'nın yapısı gösterilmiştir (Ataseven, 2013). Bir insan beyni olarak düşündüğümüzde, bir olayı ya da bir kavramı tam anlamıyla öğretmek ve algılatmak için değişik yollar deneriz. Böylece insan beyni eğitilerek gelecekte

karşısına çıkan benzer bir olay karşısında tahmin yürütebilecektir. YSA da en yakın sonucu bulmak en iyi yaklaşım modeli olarak değerlendirilir.



Şekil 6. Çok Katmanlı Yapay Sinir Ağı

Yapay Zeka Modelinde Sinirsel Ağ (Neural Network), Artificial Sinirsel Ağ (Neural Network) (ANN) olarak adlandırılır. ANN'in formülü,  $f = X \rightarrow Y$  'dir. Formülde,  $f(x)$  fonksiyonu,  $X$  ve  $Y$ 'nin birbiri ile birleşmesinden oluşmaktadır (Senyücel, 2008). ANN yapısal olarak incelendiğinde, bir sistemin öğrenmesi için 3 temel yol bulunmaktadır: Öğretmenli (Supervised) Öğrenme, Destekleyici (Reinforcement) Öğrenme, Öğretmensiz (Unsupervised) Öğrenme. Öğretmenli (Supervised) Öğrenme, girdi ve çıktı verilerinin bir örneği sisteme eğitim verisi olarak aktarılır, sistem denetlenir. Girdi verisine ait tüm nitelikler, bulunması beklenen verinin tahmini için kullanılır (Zhu ve Goldberg, 2009: 1-130). Destekleyici (Reinforcement) Öğrenme, pekiştirmeli Öğrenme olarak adlandırılır. Aynı bir birey, bir bilgiyi nasıl öğreniyorsa, Reinforcement Öğrenme de aynı mantıkla işlemektedir. Sisteme girdi verisine ihtiyaç duymadan, diğer bir ifade ile eğitim verisine ihtiyaç duymadan, yapılan denetimler için kullanılır. Burada öğrenme, çevre ile bağlantı kurarak, denetleyerek ve sonuçları gözlemleyerek gerçekleşir (Szepesvári, 2010: 1-103). Öğretmensiz (Unsupervised) Öğrenme, herhangi bir denetim ya da gözetim olmadan sadece verilerin işlenmesidir. Burada yapılan işlem verilerin düzenliliğinin sağlanması ve kuralla uygunluğunun olmasıdır (Bayrak ve Kirci, 2019: 252-291). İstatistiksel açıdan incelediğimizde, yoğunluk tahmini (density estimation) olarak adlandırılır (Alpaydin, 2004).

### **a. Yapay sinir ağlarında eğitim, öğrenme ve test**

Bir yapay sinir ağı düşünüldüğünde sistemin eğitilmesi, belirlenen katmanlar arasındaki ağırlık değerlerinin net olarak belirlenmesi ile oluşmaktadır. Kullandığımız sistem üzerine yeni varlıklar ve bu varlıkların ağırlık değerleri eklenerek sonuca ulaşmak istenilir. Yapay sinir ağlarında var olan verimizin sisteme tanıtılması gerekmektedir (Ergezer, Dikmen ve Özdemir, 2003: 14-17). Bu tanıtım işleminde kullanılan veri seti, sistemin eğitim veri seti olarak adlandırılır. Eğitim veri seti, girdi ve çıktı veri setlerinden oluşmaktadır. Yapay sinir ağına kullandığımız verilerin ağırlık oranları değiştirilerek en uygun sonuca ulaşmak hedeflenir. Eğer girdi ve çıktı verileri beklenen sonuca eriştiyse, ağırlık değerleri kullanılmaya devam edilir. Kullanılan ağ sistemini test etmek için eğitimde kullanılmayan farklı veri setleri sisteme dahil edilir. Çıkan sonuç kontrol edilerek, sistemin performansı kontrol edilir (Akıllı ve Hülya, 2014: 39-45).

### **b. Zaman serisi**

Zaman serisi, belirli bir zaman periyodu içinde yer alan veri noktalarının bir listesi olarak düşünülmektedir. Veriler eşit aralıklarla alınarak tutulmaktadır. Bir veri setinin zaman serisi olarak adlandırılabilmesi için zamana bağlı bir değişim olması gerekmektedir (Parzen, 1961: 951-989). Birbiri ardına alınan veriler, birbirlerini etkileyebilir. Birçok zaman serisi örneği mevcuttur: hava durumu kayıtları, ekonomi verileri, güneşteki leke sayıları, sismik veriler. Tahmin aşaması için zaman serileri sıklıkla kullanılmaktadır (Härdle, Lütkepohl ve Chen, 1997).

### **c. Rassal orman (Random Forest)**

Rassal orman (Random Forest), parametre hesabı yapılmadan da iyi sonuçlar vermesi hem regresyon hem de sınıflandırma aşamalarında yaşanabilecek problemlere uygulanabilir olmasından dolayı Random Forest, en çok kullanılan makine öğrenmesi modellerinden birisi olarak kabul edilmektedir (Ali, Khan, Ahmad ve Maqsood, 2012). Rassal orman modeli ezberleme özelliğini minimuma indirmek için hem veri setinden hem de öznitelik setinden rassal olarak farklı alt setleri seçmektedir. Ayrıca seçtiği verileri de eğitim aşamasına sokmaktadır (Schonlau ve Zou, 2020). Bu bağlamda, kullanılan bu



yöntemle birçok karar ağacı oluşturuluyor ve her bir karar ağacı bireysel olarak tahminde bulunabilmektedir.

#### **d. Regresyon analizi**

Regresyon analizi, kullanılacak olan iki veya daha fazla değişken arasındaki ilişkiyi analiz etmek ve bu analiz sonucunu istatistiksel olarak kullanmamıza olanak sağlayan bir yöntemdir. Regresyon analizinde, hangi faktörlerin önemli olduğunu, hangi faktörlerin göz ardı edilebileceğini ve birbirlerini nasıl etkilediklerini anlamaya yardımcı olur. Regresyon tanımını genel olarak incelediğimizde, bağımlı bir değişken ile bir veya daha fazla bağımsız değişken arasındaki ilişkiyi tahmin etmek için kullanılan bir dizi istatistiksel yaklaşımdır (Sykes, 1993).

#### **e. Çok katmanlı algılayıcı (Multi-Layer Perceptron – MLP)**

Çok Katmanlı Algılayıcılar (MLP), XOR Problemi'ni yanıt bulmak için yapılan çalışmalar sonucu ortaya çıkmıştır. Veri setlerinde tek giriş için bir nöron yeterli olmayabilir. Paralel işlem yapan birden fazla nörona ihtiyaç duyulduğunda katman kavramı devreye girer. MLP yapısında, giriş katmanı gelen verileri alarak ara katmana gönderir. Gelen bilgiler bir sonraki katmana aktarılırlar. Ara katman sayısı en az bir olmak üzere probleme göre değişir ve ihtiyaca göre ayarlanır. Her katmanın çıkışı bir sonraki katmanın girişi olmaktadır. Böylelikle çıkışa ulaşılmaktadır (Riedmiller ve Lernen, 2014: 7-24). Her işlem elemanı yani nöron bir sonraki katmanda bulunan bütün nöronlara bağlıdır. Ayrıca katmandaki nöron sayısı da probleme göre belirlenir. Çıkış katmanı önceki katmanlardan gelen verileri işleyerek ağın çıkışını belirlenir. Sistemin çıkış sayısı çıkış katmanında bulunan eleman sayısına eşittir. Tahmin için kullanılan veri setleri üzerinde sıklıkla kullanılan bir yöntemdir (Noriega, 2005).

#### **f. SMOreg algoritması**

SMOreg algoritmasını incelediğimizde yapı olarak destek vektör makineleri (DVM) olarak adlandırılan yöntemleri uygulamaktadır. Bu yöntemler 1960 yılında Vladimir Vapnik ve Alexey Chervonenkis tarafından geliştirilmiş, verileri istatistiksel olarak inceleyen bir makine öğrenmesi yöntemidir (Kara ve ŞAMLI, 2021: 141-168). SMOreg Algoritması veri madenciliği ve tahminleme aşamalarında sıklıkla kullanılan bir algoritmadır (Güven ve Bilgin, 2014:5-7).

### **g. Ay'ın Dünya'dan uzaklığı**

Ay'ın Dünya'dan uzaklığı, Ay'ın Dünya çevresindeki yörüngesi boyunca değişen uzaklığın hesaplanmasıyla elde edilir (Yılmaz, Misli ve Aristarchus, 2016:1-8).

$$\text{Uzaklık} = \sqrt{[(x_2 - x_1)^2 + (y_2 - y_1)^2 + (z_2 - z_1)^2]} \quad (3)$$

Bu formülde,  $(x_1, y_1$  ve  $z_1)$ , Dünya'nın merkezinin koordinatlarını, ve  $(x_2, y_2$  ve  $z_2)$ , Ay'ın merkezinin koordinatlarını temsil eder. Koordinatlar genellikle üç boyutlu kartezik koordinat sisteminde sunulur. Ay ile Dünya arasındaki uzaklık, yörüngelerinin elips şeklinde olması ve diğer gök cisimleriyle olan çekim etkileşimleri gibi çeşitli faktörler nedeniyle sabit değildir. Ortalama uzaklık yaklaşık 384,400 km veya 238,900 mil kadardır. Bu uzaklığı elde etmek için kullanılan formül, Ay'ın Dünya çevresindeki yörüngesinin elips şeklinde olması ve Ay'ın Dünya çevresindeki yörüngesi boyunca değişen uzaklıkla ilişkili olarak hesaplanır (Gimsa, 2020).

1990 ile 2022 yılları arasında Düzce İli'nde meydana gelen depremlerin tarihleri ve yerleri temel alınarak, Ay'ın Dünya'dan ortalama uzaklığı [timeanddate.com](http://timeanddate.com) adresinde bulunabilir ([timeanddate.com](http://timeanddate.com), 2022).

## V.YÖNTEM, SINIFLANDIRMA VE UYGULAMA

### A. Veriler

Bu tez çalışmasında, Marmara Bölgesinde yer alan ve deprem yoğunluğu fazla olan Düzce iline ait deprem tahmin uygulaması geliştirilmiştir.

Çalışmada kullanılan sismik veriler (depremin büyüklüğü, enlem ve boylam bilgisi), Boğaziçi Üniversitesi Kandilli Rasathanesi Deprem Araştırma Enstitüsü'ne ait veri tabanından otomatik olarak çekilip, 1990 ile 2022 yılları arasındaki gerçek veriler kullanılmıştır. Güncel verilerin otomatik olarak sisteme yansıtılması için bir xml dosyası hazırlanmıştır. Ayrıca elde edilen verilerin saklanması için veri tabanı tasarımı gerçekleştirilmiştir. Veri tabanında tüm güncel veriler otomatik olarak kayıt edilmektedir:

- Büyüklük,
- Enlem,
- Boylam,
- Merkez üssü vb.

Kaydedilen verilerin bir kısmı, tektonik veriler olmayacağı için endüstriyel faaliyetler gibi patlayıcı kullanarak oluşan deprem dışı faaliyetleri elemek amacıyla veri seti üzerinde veri filtreleme işlemi sağlanmıştır.

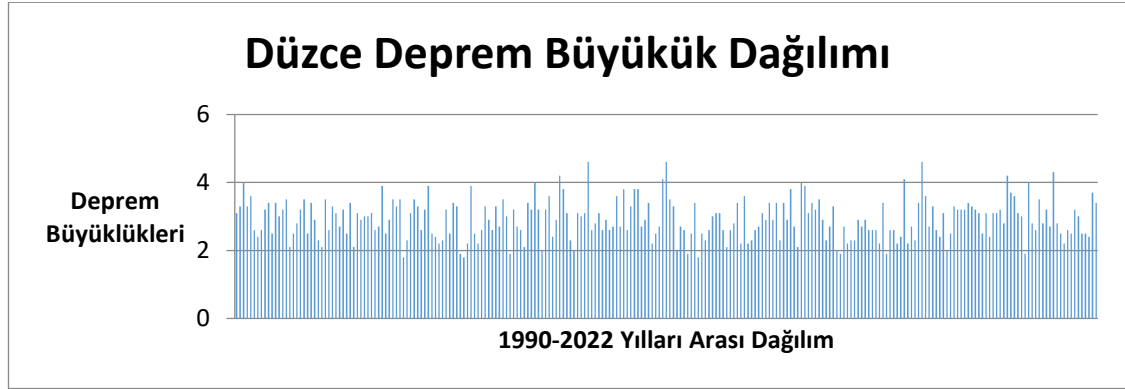
Yeni bir tahmin sistemi tasarlanmadan, ön çalışma olarak, belirtilen zaman aralığında ortalama büyüklükler analiz edilmiştir. Belirtilen zaman aralığı için deprem büyüklükleri kullanılarak, hazır bir tahmin yaklaşımı üzerinden deprem tahmini gerçekleştirilmiştir ve sonuçları incelenmiştir.

Mevcut veriler ile deprem tahmini yetersiz kaldığı için, depremi etkileyeceği düşünülen diğer veri setleri, alanında uzman sismologlarla görüşülmüştür. Kullanılacak veri setleri olarak, Ay'ın Dünyaya Uzaklığı,

depremin b ve d katsayıları verileri sistemin tahminine ara katman olarak eklenmiştir.

## 1. Zaman Serisi Analizi

Düzce iline ait deprem büyüklükleri ve zaman aralığındaki dağılımı incelenmiştir. Şekil 7’de Düzce iline ait zaman grafiği gösterilmiştir.



Şekil 7. 1990-2022 Yılları Arası Düzce İli Deprem Dağılımı

Düzce iline ait grafiği incelediğimizde deprem büyüklüğünün pik değeri ortalama olarak en fazla  $3.5 < M > 4.2$  arasında olduğu gözlenmiştir. Zaman serisi analizi sonucunda kullanılan veri seti değerleri ile deprem büyüklükleri doğrultusunda riskli bir bölgede yer aldığı ve düzgün bir dağılım sergilemediği gözlenmektedir.

## 2. Rassal Orman (Random Forest) Oluşturulması

Random Forest sınıflandırma problemlerinin çözümünde yaygın olarak kullanılan bir algoritma olduğu yapılan literatür araştırılmasında görülmüştür. Düzce iline ait veri setlerinin analiz aşamasında ilk olarak Random Forest uygulanmıştır ve veri setleri pandas dataframe’i olarak Şekil 8 ve Şekil 9’da ki gibi eklenmiştir.

```
import pandas as pd
import numpy as np
```

```
df = pd.read_csv("ornekcsv.csv",encoding='unicode_escape',sep=";")
```

```
df.dropna(inplace=True)
print(df)
```

Şekil 8. Random Forest Veri Eklenmesi

	Olus tarihi	Olus zamani	Enlem	Boylam	Derinlik	Buyukluk	Yer \
0	24.05.1992	05:33:01.80	407.500	309.900	10	3.3	Duzce
1	11.04.1993	06:03:33.60	408.900	307.700	3	2.8	Duzce
2	23.02.1994	02:05:26.00	407.400	309.900	27	2.6	Duzce
3	14.02.1995	16:15:39.90	408.800	313.800	11	3.3	Duzce
4	14.02.1995	14:58:48.90	408.900	313.800	6	3.5	Duzce
...	...	...	...	...	...	...	...
1048	9.05.2022	11:40:00.11	408.787	310.502	7,3	2.2	Duzce
1049	11.05.2022	14:25:23.60	409.232	316.813	5,5	2.2	Duzce
1050	21.05.2022	20:58:29.20	406.768	310.477	5	1.5	Duzce
1051	22.05.2022	18:19:28.45	407.777	310.013	9,1	2.3	Duzce
1052	30.05.2022	04:03:23.38	408.362	310.167	10,3	1.7	Duzce

	Hava Sicaklik Max	Hava Sicaklik Min	Ruzgar Azami Hizi ( \h) \
0	2.0	4.0	18.0
1	0.0	3.0	0.0
2	0.0	3.0	0.0
3	0.0	4.0	15.0
4	0.0	4.0	15.0
...	...	...	...
1048	11.0	15.0	1.0
1049	9.0	15.0	1.0
1050	9.0	12.0	0.0
1051	8.0	13.0	15.0
1052	9.0	11.0	13.0

	Hava Basinc (mb)	Ay ile Dunya Arasi uzaklik
0	1023.8	404.387
1	1012.2	404.751
2	1012.2	404.830
3	1003.4	356.653
4	1003.4	357.278
...	...	...
1048	1008.2	406.580
1049	1004.9	406.274
1050	1004.9	405.418
1051	1001.6	404.556
1052	1001.6	404.328

[1053 rows x 12 columns]

Şekil 9. Verilen Listesi

Değişken veri seti olarak kullanılan sütunlar features dataframe'ine tanımlanmaktadır. Tahmin edilmek istenen sütun ise labels dataframe'i olarak tanımlanmaktadır. Modelin eğitimi sırasında Sklearn kütüphanesi kullanılmaktadır ve değişkenlerde ayrı dataframe'ler olarak kabul edilmiştir. Veriler arasında eksik veri olmaması Şekil 10'da analiz edilmiştir ve head() fonksiyonu kullanarak Şekil 11'de ifade edildiği gibi ilk 5 veri satırı listelenmiştir:

```
Data columns (total 12 columns):
#   Column                               Non-Null Count  Dtype
---  -
0   Olus tarihi                           1053 non-null   object
1   Olus zamani                            1053 non-null   object
2   Enlem                                  1053 non-null   float64
3   Boylam                                 1053 non-null   float64
4   Derinlik                               1053 non-null   object
5   Buyukluk                               1053 non-null   float64
6   Yer                                     1053 non-null   object
7   Hava Sicaklik Max                     1053 non-null   float64
8   Hava Sicaklik Min                     1053 non-null   float64
9   Ruzgar Azami Hizi ( \h)               1053 non-null   float64
10  Hava Basinc (mb)                      1053 non-null   float64
11  Ay ile Dunya Arasi uzaklik            1053 non-null   object
```

Şekil 10. Eksik Verilerin Kaldırılması

```
df.head()
```

	Enlem	Boylam	Buyukluk	Derinlik	Hava Sicaklik Max	Ruzgar Azami Hizi ( \h)	Hava Basinc (mb)	Ay ile Dunya Arasi uzaklik
0	407.5	309.9	3.3	10	2.0	18.0	1023.8	404.387
1	408.9	307.7	2.8	3	0.0	0.0	1012.2	404.751
2	407.4	309.9	2.6	27	0.0	0.0	1012.2	404.830
3	408.8	313.8	3.3	11	0.0	15.0	1003.4	356.653
4	408.9	313.8	3.5	6	0.0	15.0	1003.4	357.278

Şekil 11. Verilen Listelenmesi

Bu aşamadan sonra modelin eğitimine Sklearn kütüphanesi kullanarak başlamadan önce veri setinin eğitim ve test veri seti şeklinde ayrılması gerekmektedir. Bu bağlamda, eğitilen modelin başarısı ortaya konulabilecektir. X\_train ve y\_train'i model eğitiminde X\_test ve y\_test ise modelin başarısını ölçmek amacıyla kullanılması hedeflenmiştir. Bu işlem gerçekleştirebilmek için Sklearn kütüphanesi içinde bulunan model\_selection.train\_test\_split fonksiyonu kullanılmıştır. Veri setinin, test seti için ayrılacağı oranı test\_size parametresi ile belirlenmiştir ve geriye kalan veri seti oranı ise eğitim için atanmıştır. Şekil 12'de belirtildiği gibi veri setinin %40'ı test setine ve %60'ı eğitim olarak atanmıştır. Bu bağlamda eğitim ve test verileri oluşturulmuştur.

```
x_train,x_test,y_train,y_test=train_test_split(x,y,test_size=0.40,random_state=60)
```

Şekil 12. Eğitim ve Test Verilerinin Belirlenmesi

Veri setlerinin oluşması aşamasından sonra Random Forest modelinin eğitimine başlanmıştır. Bu kısımda ilk aşama olarak bir sınıflandırıcı (classifier) nesne tanımlaması yapılmıştır. İkinci aşama olarak fit fonksiyonu içine değişken ve etiket setleri eklenmiştir. Model, varsayılan parametre değerleri ile eğitim işlemi gerçekleştirilmiştir (Şekil 13).

```
classifier = DecisionTreeClassifier()  
classifier.fit(X_train,y_train)
```

Şekil 13. Eğitim Aşaması

Gerçekleştirilen bu aşamadan sonra model eğitimi gerçekleştirilmiş ve yeni değişkenler ile tahmin yapma aşaması için hazır duruma geçilmiştir. Bu durumda sisteme test için ayrılan değişken değerleri kullanarak modelin başarısı ölçülebilir hale gelmiştir. Şekil 14’de görüldüğü gibi model başarısı %88.6 olarak gerçekleşmiştir.

```
from sklearn import metrics  
y_pred = classifier.predict(X_test)  
metrics.accuracy_score(y_test,y_pred)
```

```
0, 8865897501923641
```

Şekil 14. Model Başarısı

### 3. Regresyon Analizi

Linear Regression (Doğrusal regresyon), verilerin gelecekte tahmini ile ilgili kullanılan bir analizdir. Sisteme tanımlanan numerik girdi ve çıktıları değerleri arasında bağlantı kurarak, karmaşık olan verileri tek bir doğru olarak tanımlar (Uyanık ve Güler, 2013). Regresyon formülü,

$$y = ax + b \quad (\text{denklem 1})$$

olarak tanımlanır. Formülü incelediğimizde, bağımlı değişken y, bağımsız değişken x, katsayı değeri a, sabit değer b’dir.

Multiple Linear Regression (Çoklu Doğrusal Regresyon), sıklıkla kullanılan linear algoritmadır. Linear algoritmadan farklı olarak birden fazla bağımsız değişkenle çalışmaktadır (Tranmer ve Elliot, 2008). Linear Regresyon formülü,

$$y = b_0 + a x_1 + b x_2 + c a x_3 + d \quad (\text{denklem 2})$$

olarak tanımlanmaktadır. Girilen birden fazla bağımsız değişkenler ile tahmin yapmak için kullanılır.

Genel regresyon denklemi temel olarak hedef olarak belirtilen değişkenleri sürekli değerler alır ve ayrıca birer sınıf ifade etmezler. Ancak sürekli değişkenlerin kesikli hale getirilmesi ile regresyon modelleri sınıflandırma için kullanılabilir. Genel regresyon denklemi,

$$Y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n \quad (\text{denklem 3})$$

şeklinde ifade edilir. Bu denklemi detaylı incelediğimizde,  $Y$  değişkeni hedef değişkeni  $X$  değişkenleri ise özellik değişkenlerini göstermektedir.  $\beta$  katsayıları, sklearn içerisinde coef,  $\beta_0$  ise intercept\_ olarak kaydedilir. Regresyon analizinde en iyi çizgiyi çizmeye çalışırız.

Yapılan çalışmada öncelikle regresyon fonksiyonu Şekil 15’de çağrılmıştır:

```
from sklearn.linear_model import LinearRegression
lm = LinearRegression()
```

Şekil 15. Regresyon Fonksiyonu Ekleme

Veri seti, pandas çerçevesine alıp regresyon modeli oluşturulmuştur ve veriler Şekil 16’da ifade edildiği gibi listelenmiştir:

```
import pandas as pd
```

```
df = pd.read_csv("ornekcsv.csv", encoding='unicode_escape', sep=";")
df.head()
```

	Olus tarihi	Olus zamani	Enlem	Boylam	Derinlik	Buyukluk	Yer	Hava Sıcaklık Max	Hava Sıcaklık Min	Ruzgar Azami Hızı ( \h)	Hava Basınc (mb)	Ay ile Dünya Arası uzaklık
0	24.05.1992	05:33:01.80	407.5	309.9	10	3.3	Duzce	2.0	4.0	18.0	1023.8	404.387
1	11.04.1993	06:03:33.60	408.9	307.7	3	2.8	Duzce	0.0	3.0	0.0	1012.2	404.751
2	23.02.1994	02:05:26.00	407.4	309.9	27	2.6	Duzce	0.0	3.0	0.0	1012.2	404.830
3	14.02.1995	16:15:39.90	408.8	313.8	11	3.3	Duzce	0.0	4.0	15.0	1003.4	356.653
4	14.02.1995	14:58:48.90	408.9	313.8	6	3.5	Duzce	0.0	4.0	15.0	1003.4	357.278

Şekil 16. Verilen Modele Dahil Edilmesi


Her sütun içinde yer alan veriler incelenmiş ve eksik veriler ortadan kaldırılmıştır. Kaldırılan veriler doğrultusunda her bir sütun içerisinde 1053 adet veri tutulmaktadır (Şekil 17).



Data columns (total 8 columns):		
#	Column	Non-Null Count
0	Enlem	1053 non-null
1	Boylam	1053 non-null
2	Buyukluk	1053 non-null
3	Derinlik	1053 non-null
4	Hava Sicaklik Max	1053 non-null
5	Ruzgar Azami Hizi ( \h)	1053 non-null
6	Hava Basinc (mb)	1053 non-null
7	Ay ile Dunya Arasi uzaklik	1053 non-null

Şekil 17. Eksiksiz Verilerin Listesi

Büyüklik veri seti ve diğer veri setlerini ayırma işlemleri gerçekleştirilir. Bu aşamadan sonra veri setleri arasındaki ilişki değerlendirilmiştir. Değerlendirme sonucunda veriler arasında pozitif yönlü bir ilişkinin olduğu gözlemlenmiştir. Veri setine ait belirtilen aralıktaki ilişki Şekil 18’de gösterilmiştir.



Şekil 18. Belirli Bir Aralığın İlişki Dağılımı

Son aşama olarak, model içine yerleştirilmiş olan veri setlerinin uyum oranı Şekil 19’ da ifade edildiği gibi %89 olarak hesaplanmıştır.

```
y_predicted = lineer_regresyon.predict(X.values.reshape(-1,1))
r2_score(y,y_predicted)

0.8971708595884971
```

Şekil 19. Veri Setinin Uyum Oranı

#### 4. Çok Katmanlı Algılayıcı (Multi-Layer Perceptron – Mlp)

Çok Katmanlı Perceptron (MLP), en basit yapay sinir ağı türüdür. Perceptron'lar insan beyninden ilham almış ve sorunları çözmek için işlevselliğini simüle etmeye çalışmaktadır. MLP’de bu algılar birbirine bağlı ve paralel bir yapıya sahiptir. Bu paralelleştirmedeki esas amaç, daha hızlı hesaplamaya

yardımcı olmaktır. Bu aşamada, Çok Katmanlı Perceptron kullanarak deprem büyüklük tahminini gerçekleştirilmiştir.

Öncelikle Panda'ın read CSV (CSV oku) işlevi kullanılarak gerekli veri seti yapıya dahil edilip, veriler Şekil 20'de listelenmiştir:

```
import pandas as pd

df = pd.read_csv("ornekcsv.csv",encoding='unicode_escape',sep=";")
df.head()
```

	Olus tarihi	Olus zamanı	Enlem	Boylam	Derinlik	Buyukluk	Yer	Hava Sicaklik Max	Hava Sicaklik Min	Ruzgar Azami Hizi ( \h)	Hava Basinc (mb)	Ay ile Dünya Arasi uzaklik
0	24.05.1992	05:33:01.80	407.5	309.9	10	3.3	Duzce	2.0	4.0	18.0	1023.8	404.387
1	11.04.1993	06:03:33.60	408.9	307.7	3	2.8	Duzce	0.0	3.0	0.0	1012.2	404.751
2	23.02.1994	02:05:26.00	407.4	309.9	27	2.6	Duzce	0.0	3.0	0.0	1012.2	404.830
3	14.02.1995	16:15:39.90	408.8	313.8	11	3.3	Duzce	0.0	4.0	15.0	1003.4	356.653
4	14.02.1995	14:58:48.90	408.9	313.8	6	3.5	Duzce	0.0	4.0	15.0	1003.4	357.278

Şekil 20. Verilerin Modele Dahil Edilmesi

Model performansını değerlendirmek için veri setini eğitim setine ve test setine bölme işlemi gerçekleştirilmiştir:

```
from sklearn.model_selection import train_test_split

x=df.drop("Buyukluk",axis =1)
y=df["Buyukluk"]

x_train,x_test,y_train,y_test=train_test_split(x,y,test_size=0.40,random_state=60)
```

Şekil 21. Eğitim Aşaması

Bir sonraki aşama ise büyüklük için bir tahmin modeli oluşturmaktır. Burada yapılması istenen esas amaç, MLPClassifier kullanarak bir tahmin oluşturmaktır. İlk olarak, MLPClassifier modülünün içe aktarım işlemi gerçekleştirilmiştir ve MLPClassifier() işlevini kullanarak MLP Classifier nesnesi yaratılmıştır. Sonraki işlem olarak modeli, fit() fonksiyonu kullanarak eğitim setine yerleştirmektir. Bu işlem sonrasında, tahmin() fonksiyonu kullanılarak test veri seti üzerinden bir tahmin gerçekleştirilmektir (Şekil 22).

```

from sklearn.neural_network import MLPClassifier

# Create model object
clf = MLPClassifier(hidden_layer_sizes=(6,5),
                    random_state=5,
                    verbose=True,
                    learning_rate_init=0.01)

# Fit data onto the model
clf.fit(X_train,y_train)

```

Şekil 22. Model Oluşturulması


Çalışmanın bu aşamasında, test veri seti üzerinde tahminlerde bulunulmuştur. Test veri setinin mevcut gerçek verilere dayanarak model doğruluğu değerlendirilmiştir. Şekil 23’ de ifade edildiği gibi %82 olarak hesaplanmıştır.

0.8257259173610263

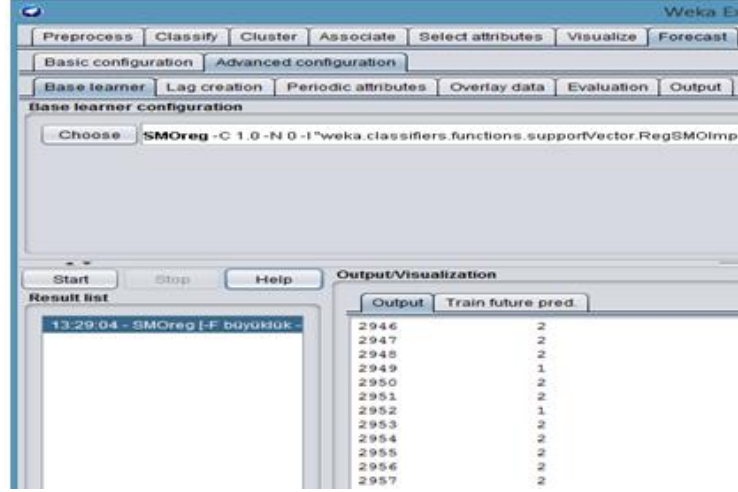
Şekil 23. Model Doğruluk Oranı

## 5. SMOreg Algoritması

SMOreg algoritması temel olarak destek vektör makineleri olarak bilinen yöntemleri kullanır. Makine öğrenmesi algoritmalarının ve veri ön işleme (data pre-processing) gibi gereksinimlerin bir arada sunulduğu WEKA uygulaması içinde yer alan SMOreg algoritması kullanılmıştır (Şekil 24). Veri setinin %40’ı test verisi olarak ve %60’ı eğitim verisi olarak kullanılmıştır. Sisteme 1990 – 2022 arası veriler eklenmiştir ve tahmin analizi yapılmıştır (Şekil 25).




Şekil 24. WEKA Model Seçimi



Şekil 25. Verilerin Modele Dahil edilmesi

Düzce ili için Şekil 26’da belirtilen, sismik veriler periyodik olarak gösterilmiştir:




Şekil 26. Verilen Periyodik Dağılımı

Tahmin ve gerçek veriler karşılaştırıldığında sonuçlar Çizelge 3’de gösterilmiştir. 30.04.2022 ile 31.05.2022 tarihleri arası tahmin, oran, derinlik ve büyüklük bilgisini Şekil 27’de gösterilmiştir.


Çizelge 3. Olasılık ve Tahmin Verileri

Tarih	İhtimal(%)	Tahmin(M)	Derinlik(km)	Oluşan(M)
30.04.2022	76	1,6	7,6	0
1.05.2022	10	2,4	3,3	0
2.05.2022	32	2	7,2	0
3.05.2022	0	0	0	0
4.05.2022	32	2,1	6,5	0
5.05.2022	54	2,4	6,3	0
6.05.2022	54	3,1	8,3	0
7.05.2022	10	2,7	12,8	0
8.05.2022	0	0	0	1,3
9.05.2022	1	3,5	8,3	2
10.05.2022	15	1,2	11,4	0
11.05.2022	44	2,2	5,1	2
12.05.2022	0	2,6	3,3	0
13.05.2022	11	2,6	5,1	0
14.05.2022	26	2,2	3,3	0
15.05.2022	0	0	0	0
16.05.2022	22	2,5	10	0
17.05.2022	3	4,1	3	0
18.05.2022	29	2,6	8	0
19.05.2022	15	2,6	4	0
20.05.2022	15	3	2	0
21.05.2022	59	2,9	6,4	0
22.05.2022	73	2,5	8	2,3
23.05.2022	32	2,3	7,2	0
24.05.2022	44	2,5	9,9	0
25.05.2022	15	2,4	4,6	0
26.05.2022	29	2,1	12,1	0
27.05.2022	31	3,6	7,8	0
28.05.2022	29	2,2	9,1	0
29.05.2022	12	2,4	6,5	0
30.05.2022	15	2	4,9	1,7
31.05.2022	2	1,2	5,3	0
1.06.2022	26	2,9	7,8	0
2.06.2022	11	1,5	16,1	0
3.06.2022	15	2,1	7,3	0
4.06.2022	0	0	0,0 9,6	0
5.06.2022	19	1,3	12	0
6.06.2022	16	2,1		0



Şekil 27. Aylık Tahmin, Oran, Derinlik, Büyüklük

İnceleme yapılan 30 günlük zaman dilimi içinde tahmin doğruluğunun pik değerine 22.05.2022 tarihinde %73 oranla ve 11.05.2022 tarihinde %44 oranla erişildiği Şekil 28’ de gösterilmiştir. 22.05.2022 tarihinde , %73,0 olasılık tahminli 2,5 büyüklüğünde deprem gerçekleşmesi ve derinliğin 8,0 olması öngörülmüştür. Gerçek deprem verisi incelendiğinde, 2,3 büyüklüğünde ve 9,0 derinliğinde deprem gerçekleşmiştir. 11.05.2022 tarihinde, %44 tahmin olasılığı ile 2,2 büyüklüğünde ve 5,1 derinliğinde deprem gerçekleşebileceği ön görülmüştür. Aynı gün içerisinde 4.5 derinliğinde, 2.0 büyüklüğünde deprem gerçekleştiği resmi olarak yayımlanmıştır.



Şekil 28. Tahmin Edilen Gün Pik Oranları

## VI. MATERYAL VE METHOD DEĞİŞİMİ

Bu bölümde araştırma modeli, araştırmanın değişkenleri, kullanılan veri toplama araçları, deneysel süreç, verilerin hazırlanması ve analizi, tahmin aracı ve verinin yorumlanmasına ilişkin bilgiler yer almaktadır.

### A. Deprem Büyüklüğünün Hesaplanması

Depremin hesaplanması için Primary - (P) ve Secondary - (S) dalgaları, formüller kullanarak değerlendirilir ve depremin büyüklüğü bilimsel olarak sonuçlandırılır (Wu ve Zhao, 2006). P veya sıkıştırma dalgalarında, kayanın titreşimi yayılma yönündedir. P dalgaları, yer içerisinde en hızlı yayılan ve sismometreler tarafından ilk algılanan dalgalardır (Yamasaki, 2012). P- dalga hızı aşağıdaki formül ile hesaplanır:

$$V_p = \sqrt{((\lambda + 2\mu)) / \rho} \quad (\text{denklem 4})$$


S veya kayma dalgalarında kaya, dalga yayılma yönüne dik olarak salınır. Kayada, S dalgaları genellikle P dalgalarının yaklaşık %60'ı kadar hızlı hareket eder ve S dalgası her zaman P dalgasından sonra gelir (Nuttli, 1961: 237–246).

$$V_s = \sqrt{\mu / \rho} \quad (\text{denklem 5})$$

Birinci aşamada, P dalgalarının başladığı andan S dalgalarının başladığı ana kadar geçen süre hesaplanır, nomogramda işaretleme yapılır ve ona karşılık gelen km değeri okunur. Bu istasyonun merkez üssüne uzaklığıdır. İkinci aşamada, en güçlü S dalgasının amplitüdü ölçülür ve nomogramda işaretlenir. İlk iki işaret doğrusal olarak birleştirilir. Depremin büyüklüğü (magnitud) bu iki işareti birleştiren doğrunun magnitud ölçeği ile kesiştiği noktadır. Bu yöntem ile Düzce iline ait 1990-2022 arasında yaşanmış  $M \geq 3$  olan deprem büyüklükleri hesaplanmıştır. 1990 yılına ait 1 yıllık veri seti Çizelge 4'de verilmiştir. Deprem veri kümesinin büyüklüğüne göre adetini gösteren 32 yıllık histogram dağılımı Şekil 29'da verilmiştir.

Çizelge 4. Düzce İli 1990 İle 2022 Arası Depremler ( $M \geq 3$ )

Tarih	Ay	Gün	Saat	Enlem	Boylam	Derinlik	Büyüklik
1990	02	09	18:20:00.00	41.0000	31.9000	10	3,71
1990	02	14	12:17:01.40	40.7400	29.1000	7	3,01
1990	04	11	08:02:08.00	40.7000	29.9000	7	3,01
1990	05	06	22:09:13.60	40.7200	29.7000	13	3,11
1990	05	07	10:36:02.70	40.5800	30.2000	5	3,51
1990	06	07	23:28:30.00	40.7400	29.2000	10	3,31
1990	06	08	01:47:56.00	40.5400	30.1400	3	3,91
1990	06	18	19:27:08.00	40.5100	30.5000	5	3,31
1990	07	21	17:56:49.00	40.7000	30.3000	22	3,11
1990	08	22	13:02:34.00	41.0000	29.9000	3	3,11
1990	09	01	17:27:37.00	40.7000	30.0000	8	3,01
1990	09	29	00:02:17.00	40.7000	29.8000	12	3,01
1990	10	03	01:51:29.00	40.6900	30.0000	5	3,01
1990	10	05	10:16:45.00	40.7000	30.0000	7	3,01
1990	10	08	05:50:14.00	40.7000	30.2000	4	3,11
1990	10	19	05:28:11.00	40.6800	30.0000	7	3,01
1990	11	04	08:07:49.70	40.7800	30.0300	9	3,11
1990	11	11	22:06:00.10	40.6000	31.7400	14	3,21



Şekil 29. Deprem Büyüklük Dağılımı

Veri seti içine depremin zaman, lokasyon ve derinlik bilgileri eklenmiştir. Sismik veriler, Kandilli Rasathanesi Deprem Araştırma Enstitüsü tarafından sağlanmıştır.

## B. B-Değeri ve D-Değeri Hesaplama

Deprem b değeri ve deprem d değeri, bir deprem bölgesinde meydana gelen depremlerin şiddetinin ölçümü için kullanılan iki farklı parametredir. Deprem b



değeri, bir deprem bölgesinde meydana gelen depremlerin, bir ölçüm periyoduna göre ortalama şiddetini gösterir. Deprem d değeri ise, bir deprem bölgesinde meydana gelen depremlerin toplam şiddetini göstermektedir (Ceylan, 2008).

Deprem b değeri ve deprem d değeri arasındaki fark, deprem bölgesinde meydana gelen depremlerin sayısı ile depremlerin toplam şiddeti arasındaki farktır. Eğer deprem bölgesinde meydana gelen depremlerin sayısı fazla ise, deprem b değeri yüksek olurken deprem d değeri düşük olabilmektedir. Bu durumda, deprem bölgesinde sık sık meydana gelen düşük şiddette depremler olmuştur. Eğer deprem bölgesinde meydana gelen depremlerin toplam şiddeti fazla ise, deprem d değeri yüksek olurken deprem b değeri düşük olabilmektedir (Öztürk, 2012: 1-23). Bu durumda, deprem bölgesinde nadir olmakla birlikte yüksek şiddette depremler olmaktadır.

Deprem b değeri, bir deprem bölgesinde meydana gelen depremlerin şiddetinin ölçümü için kullanılan bir parametredir. Deprem b değeri formül kullanarak hesaplanmıştır (Öztürk, 2017).

$$b = \log_{10} (N + C) \quad (\text{denklem 6})$$

Burada, N, deprem bölgesinde meydana gelen depremlerin sayısıdır ve C, bir sabit değerdir. Deprem b değerinin yüksek olması, deprem bölgesinde sık sık meydana gelen yüksek şiddette depremlerin olması anlamına gelmektedir. Deprem b değerinin düşük olması ise, deprem bölgesinde nadir ve düşük şiddette depremlerin olması anlamına gelmektedir.

Deprem b değerini hesaplamak için öncelikle, deprem bölgesinde meydana gelen depremlerin sayısı (N) belirlenmiştir. Daha sonra, sabit değer (C) eklenerek, formül ile deprem b değerini hesaplanmıştır. Hesaplanan b değerleri veri seti olarak eklenmiştir.

Deprem d değeri hesaplamak için formül kullanılmıştır (Polat, Goek ve Yilmaz, 2008: 593–614).

$$d = \log_{10} (D + C) \quad (\text{denklem 7})$$

Burada, D, deprem bölgesinde meydana gelen depremlerin toplam şiddetidir ve C, bir sabit değerdir. Deprem d değerinin yüksek olması, deprem bölgesinde meydana gelen depremlerin genel olarak yüksek şiddette olduğunu gösterir.

Deprem  $d$  deęerinin dūřuk olması ise, deprem bōlgesinde meydana gelen depremlerin genel olarak dūřuk řiddette olduęunu gōsterir.

Deprem  $d$  deęerini hesaplamak iin öncelikle, deprem bōlgesinde meydana gelen depremlerin toplam řiddeti ( $D$ ) hesaplanmıřtır. Daha sonra, sabit deęer ( $C$ ) eklenerek ve formöl kullanarak deprem  $d$  deęeri hesaplanmıřtır. Hesaplanan  $d$  deęerleri veri seti olarak eklenmiřtir.

### **C. RNN (Recurrent Neural Network)**

RNN, bir yapay zeka (AI) yöntemidir. RNN, girdi verilerinin sırasını ve zamanı dikkate alan bir yapay sinir aęıdır. RNN, girdi verilerinin sırasını ve zamanı dikkate alarak, veriler arasındaki iliřkiyi tahmin etme konusunda ok iyi bir performans gōstermektedir. Bu özellięi nedeniyle, RNN ok sık makine öęrenimi (machine learning) uygulamalarında kullanılmaktadır ve doęru ıktıyı üretir (Sherstinsky, 2020). RNN alıřma algoritması, ařaęıdaki adımları ierir:

-Girdi verileri, girdi katmanına girilir.

-Girdi verileri, gizli katmanlarda iřlenir ve aęırlık deęerleri (weights) öęrenilir.

-Gizli katmanlar, verileri iřler ve ıktı verisi üretir.

-ıktı verisi, ıktı katmanına gōnderilir.

-ıktı verisi üretilir.

RNN'ler, verileri iřlerken izelge 5'de ifade edilen formüller kullanılır (Gao ve Glowacka, 2016: 350-365).

Çizelge 5. RNN Formülleri

Formüller	Açıklama
$h_t=f(h_{t-1},X_t)$	$h_t$ : Şu anki h değeri $h_{t-1}$ : Bir önceki h değeri $x_t$ : Şu anki girdi vektörü
$h_t=\tanh(W_{hh}h_{t-1} + W_{xh}X_t)$	W: Ağırlık h: Gizli katman $W_{hh}$ : Bir önceki gizli katmanın ağırlığı $W_{hx}$ : Şu anki gizli katmanın ağırlığı tanh: Aktivasyon fonksiyonu
$y_t= W_{hy}h_t$	$W_{hy}$ : Çıktı katmanının ağırlık değeri $y_t$ : Çıktı

Kaynak: (medium.com, 2022)

Bir deprem tahmini modeli oluşturmak için, geçmiş depremlerin ve diğer verileri girdi olarak kullanarak, RNN modeli gelecekteki depremleri tahmin etmeye çalışmaktadır. Bu veriler, depremlerin büyüklüğü, yerleri, zamanı, derinliği, b ve d değeri, Ay'ın dünyaya mesafesi özelliklerini içermektedir. RNN modeli, bu sıralı verileri işleyerek, gelecekte olası depremlerin ne zaman, nerede ve olma olasılığını tahmin edecektir. RNN modelini eğitmek ve tahminlerini test etmek için 32 yıllık veri seti kullanılmıştır.

## VII. SONUÇLAR VE DEĞERLENDİRİLMESİ

Deprem, çok eski yıllardan günümüze kadar farklı büyüklüklerle gerçekleşmiş ve gerçekleşmeye devam etmektedir. Deprem oluşumundan bu yana depremin tahmin edilmesine yönelik, birçok araştırmacı tarafından farklı metotlar denenerek çalışmalar yapılmıştır. Yapılan çalışmalarda, sadece deprem büyüklüğü verileri ile doğru bir tahmine ulaşılamadığı anlaşılmıştır. Tahmine yönelik, birçok veri seti ve farklı yaklaşımlar kullanılmıştır. Çalışmaların sonuçlarına bakıldığında %100 oranında tahmin üreten ve bu oranın sürekliliğini sağlayan bir çalışmaya rastlanmamıştır. Bu tez çalışması kapsamında, kullanılan sismik veriler (deprem büyüklüğü, enlem ve boylam bilgisi, derinliği ve lokasyonu), Kandilli Rasathanesi Deprem Araştırma Enstitüsü tarafından sağlanmıştır.

Çalışmada, veri setlerinin değerlendirilmesi için Zaman Serisi Analizi, Rassal Orman (Random Forest), Regresyon Analizi, SMOreg algoritması, Çok Katmanlı Algılayıcı (Multi-Layer Perceptron – MLP) modelleri kullanılmıştır. Veri seti olarak, sismik verilerin haricinde depremin oluşumunu etkileyebilecek veri setleri olduğu bilinen; Ay'ın Dünyaya Uzaklığı, depremin b ve d değeri verileri modele dahil edilmiştir. Tezin bu aşamasında, sismik verileri değerlendirmek için tahmin çalışmalarında sıkça kullanılan ve literatürde sıkça başarılı sonuçlar alındığı belirtilen tahmin oranları kullanılmıştır. Modeller içinde kullanılan veri setlerinin analiz aşamaları, Python programlama dili kullanılarak gerçekleştirilmiştir. Ayrıca WEKA üzerinden tahmin algoritması kullanılarak sonuç değerlendirilmesi yapılmıştır.

Modelin kurulması aşamasında ise öncelikle Zaman Serisi Analizi, Rassal Orman (Random Forest), Regresyon Analizi, Çok Katmanlı Algılayıcı (Multi-Layer Perceptron – MLP) modelleri için kütüphaneleri indirilmiştir. Veri setleri üzerinden `sklearn.model_selection()` kütüphanesinde yer alan `train_test_split()` fonksiyonuna erişim sağlanarak model validasyonu gerçekleştirilmiştir. Modele göre kullanılacak en uygun eğitim ve test verileri oluşturulmuştur. Eğitim ve test

için kullanılacak verilerinin, fonksiyon kullanılarak belirlenmesinin esas nedeni fonksiyonun veri setini analiz ederek en uygun şekilde bölmeleridir. Eğitim verileri, x\_train ve y\_train olarak oluşturulan test setleri kullanılarak analiz edilmiştir. Yapı olarak veri setleri iki farklı veri seti olarak gözükmesine rağmen veri setleri bağımlı ve bağımsız değişkenleri ifade etmesine göre ayrılmıştır. Eğitim ve test verisi olarak işlenen veriler lin.fit(x\_train, y\_train) komutu ile fit işlemi gerçekleşmiş ve lin\_predict() komutu ile veri seti tahmin etme işlemi başlatılmıştır. Kullanılan modele göre doğruluk oranları hesaplatılmıştır. Modele bağlı sonuçlar, Çizelge 6'da gösterilmiştir. Elde edilen oranlara göre en iyi tahmin modelinin Regresyon analizi ve Rassal Orman yöntemi olduğu görülmüştür.

Çizelge 6. Model Değerlendirmesi


Yöntem	Sonuc	Oran(%)
Random Forest	0, 8865897501923641	88
Regression	0, 8971708595884971	89
Multi-Layer Perceptron	0, 8257259173610263	82
SMOreg Algorithm	0, 7389372701836973	73

Analiz sonuçları değerlendirildiğinde deprem gibi statik olmayan veri yapısına sahip değerlerin tahmini oldukça zordur. Yapılmış olan çalışmalarda olduğu gibi bu tez çalışmasında da öngörülen tahmine %100 ulaşamadığı belirlenmiştir. Yapılan çalışmanın, bilimsel olarak literatüre en önemli katkılarında biri, deprem gibi statik olmayan ve sürekli değişkenlik gösteren parametrelerin ve bu parametreleri etkileyecek farklı veri setleri kullanılarak değişiminin belirlenmesidir. Bu tez çalışmasının, Farklı bir il üzerinde ve farklı veri setleri dahil edilerek incelemesi yapılan sismik araştırmalarda etkin bir yapı oluşturmak için faydalı olacağı ön görülmektedir.

## VIII. SONUÇLAR VE TARTIŞMALAR


Bu bölüm, Düzce iline ait 1990-2022 yılları arasındaki deprem olma olasılığı ve büyüklük tahminine ilişkin bulguları içerir.

İlk çalışma, Düzce ili için 2022’da Kasım ve Aralık ayı içinde yer alan depremler için gerçekleştirilmiştir. Belirtilen zaman aralığı içinde büyüklüğü 1.0 ile 6.1 arasında toplam 756 adet deprem gerçekleşmiştir. Meydana gelen depremler arasından büyüklüğü 3.0 ve üzerinde olan deprem sayısı Şekil 30’da ifade edildiği gibi 16 adettir.



Şekil 30. Düzce Kasım ve Aralık Deprem Dağılımı

RNN yöntemine bağlı kalarak, deprem büyüklüğü, derinlik, lokasyon, zaman, Ay’ın dünyaya uzaklığı, b-değeri ve d-değeri, eğitim - test aşamasında kullanılmıştır. Tahmin aşaması, Düzce ilinde Kasım ve Aralık aylarında yaşanmış büyüklüğü 3 ve üzerinde olan depremler üzerinde yapılmıştır. Gerçek veriler ile tahmin edilen büyüklük ve olasılık değerleri karşılaştırılmıştır. Tahmin edilen deprem büyüklükleri Şekil 31’de gösterilmiştir.



Şekil 31. Tahmin Edilen Deprem Büyüklük Dağılımı

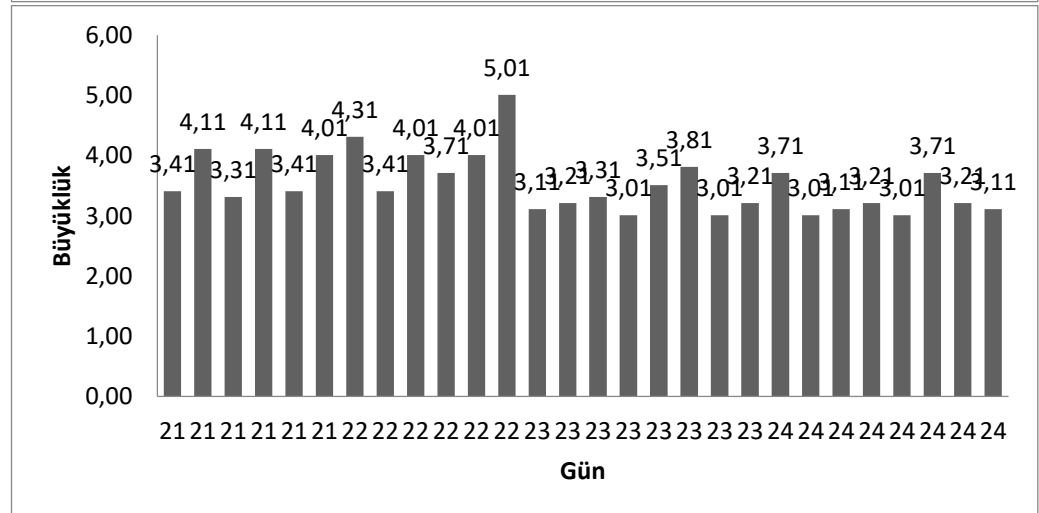
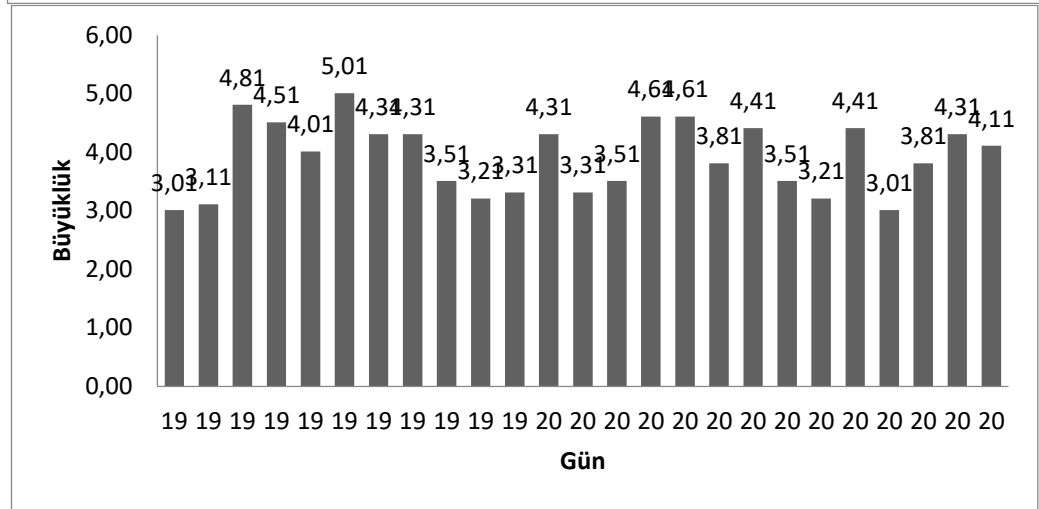
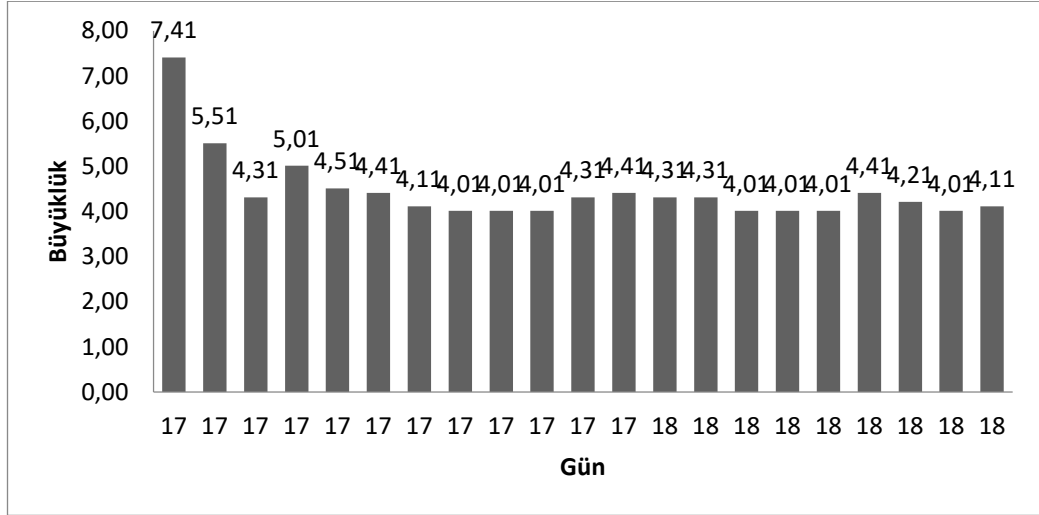
Ulaşılan sonuçlar incelendiğinde, gerçek veriler ile tahmin edilen veriler arasında, en yüksek olasılık %75.3 ve en düşük olasılık %58.9 ile deprem olabileceği öngörülmektedir. Gerçekleşen deprem büyüklüğü ile tahmin edilen deprem büyüklükleri karşılaştırıldığında maksimum %0.5 ve minimum %0.4 oranında yanılma oranı ile gerçek deprem büyüklükleri tahmin edilmiştir. Gerçek büyüklük verileri ile olasılık ve tahmin büyüklükleri Çizelge 7’de verilmiştir.

Çizelge 7. Tahmin ve Gerçek Deprem Verileri


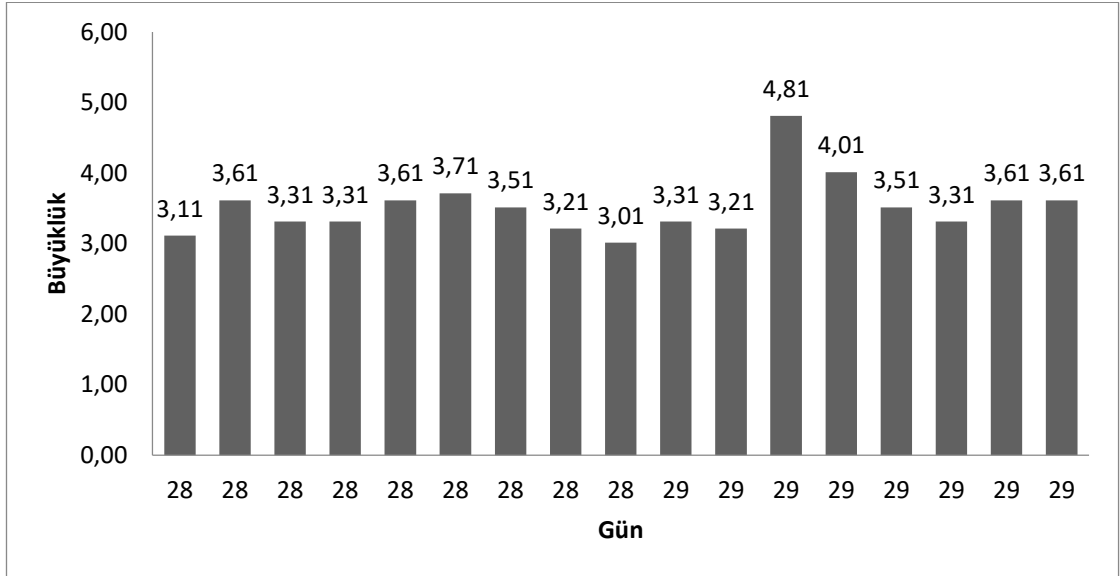

Tarih	Büyüklük ( $M \geq 3$ )	Derinlik (km)	Olasılık (%)	Tahmin (M)
23.11.2022	6,1	8,3	73	5,6
23.11.2022	4,4	5	75,3	4
23.11.2022	3,8	5,3	73,2	3,1
24.11.2022	3,2	3,8	60,7	2,7
25.11.2022	3,5	5	65,4	3,1
25.11.2022	3,4	5	60,2	2,9
25.11.2022	3	6,5	63,4	2,6
27.11.2022	4,5	17,5	73,2	4
2.12.2022	3,6	9,9	74,1	3,1
2.12.2022	3,6	5,1	72,2	3,1
2.12.2022	3,3	8,3	73,4	2,8
3.12.2022	4,2	10,6	69,2	3,7
3.12.2022	3,6	14,1	71,3	3,1
4.12.2022	3,5	6,3	58,9	3
8.12.2022	3	5,4	63,4	2,5
12.12.2022	3	4,5	66,9	2,6

İkinci çalışma, Düzce ilinde 1999 yılında yaşanan ve büyük yıkımlar ile sonuçlanan 19 Ağustos depremi için gerçekleştirilmiştir. Yaşanan depremin

öncesini ve sonrasını değerlendirmek amacıyla Temmuz, Ağustos ve Eylül ayları üzerinde tahmin çalışması gerçekleştirilmiştir. Belirtilen zaman aralığı içinde büyüklüğü 3.0 ve üzerinde olan toplam 295 adet deprem gerçekleşmiştir. Yaşanan depremler arasında, 141 adet Ağustos ayı içinde meydana gelmiştir. Ağustos ayında meydana gelen depremlerin gün bazlı dağılımı Şekil 32’de verilmiştir.








Şekil 32. Düzce 1999 Yılı -Ağustos Ayı Deprem Dağılımı

Tahmin aşaması, RNN yöntemi kullanılarak Düzce ilinde, 1999 yılında Ağustos ayında yaşanmış büyüklüğü 3 ve üzerinde olan depremler üzerinde yapılmıştır. Gerçek veriler ile tahmin edilen büyüklük ve olasılık değerleri karşılaştırılmıştır. Tahmin edilen deprem büyüklükleri Şekil 33’de gösterilmiştir.



Şekil 33. Tahmin Edilen Büyüklük Verileri

Ulaşılan sonuçlar incelendiğinde, gerçek veriler ile tahmin edilen veriler arasında, en yüksek olasılık %74.3 ve en düşük olasılık %68.3 ile deprem olabileceği öngörülmektedir. Ağustos ayı boyunca günlük ortalama minimum 6, maksimum 14 adet deprem gerçekleştirilmiştir. Günlük yaşanan ortalama deprem büyüklüğü Çizelge 8’de verilmiştir. Bir gün içinde gerçekleşen deprem büyüklüğü ile tahmin edilen deprem büyüklüğü karşılaştırıldığında maksimum %0.6 ve minimum %0.1 oranında yanılma oranı ile gerçek deprem büyüklükleri tahmin edilmiştir. Gerçek büyüklük verileri ile olasılık ve tahmin büyüklükleri Çizelge 8’de verilmiştir.

Çizelge 8. Gerçek ve Tahmin Edilen Büyüklük Verileri

Tarih			Der. (km)	Büyüklük (M>=3)	İlama Büyü (M>=3)	Olasılık (%)	Tahmin (M)
1999	8	17	18	7,41			
1999	8	17	15	5,51			
1999	8	17	5	4,31			
1999	8	17	16	5,01			
1999	8	17	16	4,51			
1999	8	17	17	4,41			
1999	8	17	10	4,11	4,7	74,3	6,8
1999	8	17	11	4,01			
1999	8	17	6	4,01			
1999	8	17	13	4,01			
1999	8	17	16	4,31			
1999	8	17	16	4,41			
1999	8	18	14	4,31			
1999	8	18	5	4,31			
1999	8	18	5	4,01			
1999	8	18	9	4,01			
1999	8	18	8	4,01	4,2	74	4,6
1999	8	18	11	4,41			
1999	8	18	9	4,21			
1999	8	18	1	4,01			
1999	8	18	24	4,11			
1999	8	19	10	3,01			
1999	8	19	3	3,11			
1999	8	19	6	4,81			
1999	8	19	12	4,51			
1999	8	19	14	4,01			
1999	8	19	11	5,01	3,9	72,2	3,4
1999	8	19	12	4,31			
1999	8	19	1	4,31			
1999	8	19	9	3,51			
1999	8	19	28	3,21			
1999	8	19	7	3,31			
1999	8	20	11	4,31			
1999	8	20	5	3,31			
1999	8	20	14	3,51			
1999	8	20	8	4,61			
1999	8	20	17	4,61			
1999	8	20	12	3,81			
1999	8	20	7	4,41			
1999	8	20	5	3,51	3,9	70,4	3,4
1999	8	20	9	3,21			
1999	8	20	16	4,41			
1999	8	20	21	3,01			
1999	8	20	8	3,81			
1999	8	20	9	4,31			
1999	8	20	1	4,11			

Çizelge 2. (Devamı) Gerçek ve Tahmin Edilen Büyüklük Verileri

	Tarih	Der. (km)	Büyüklük (M>=3)	ılama Büyü (M>=3)	Olasılık (%)	Tahmin (M)
1999	8	21	8	3,41		
1999	8	21	8	4,11		
1999	8	21	7	3,31	3,7	71,5
1999	8	21	1	4,11		3,2
1999	8	21	1	3,41		
1999	8	21	23	4,01		
1999	8	22	10	4,31		
1999	8	22	9	3,41		
1999	8	22	9	4,01	4,1	73
1999	8	22	5	3,71		3,6
1999	8	22	1	4,01		
1999	8	22	5	5,01		
1999	8	23	1	3,11		
1999	8	23	6	3,21		
1999	8	23	4	3,31		
1999	8	23	11	3,01	3,3	69,4
1999	8	23	23	3,51		3,4
1999	8	23	5	3,81		
1999	8	23	7	3,01		
1999	8	23	4	3,21		
1999	8	24	5	3,71		
1999	8	24	9	3,01		
1999	8	24	8	3,11		
1999	8	24	6	3,21	3,3	69,6
1999	8	24	7	3,01		2,9
1999	8	24	16	3,71		
1999	8	24	1	3,21		
1999	8	24	1	3,11		
1999	8	25	1	3,11		
1999	8	25	1	3,51		
1999	8	25	14	3,51		
1999	8	25	12	3,81		
1999	8	25	7	3,31	3,4	70,1
1999	8	25	14	3,21		2,8
1999	8	25	13	3,71		
1999	8	25	5	3,11		
1999	8	25	5	3,31		
1999	8	26	9	3,11		
1999	8	26	2	3,11		
1999	8	26	1	3,61		
1999	8	26	7	3,01		
1999	8	26	5	3,21	3,5	68,9
1999	8	26	6	3,71		3
1999	8	26	3	4,11		
1999	8	26	5	3,61		
1999	8	26	5	3,61		
1999	8	26	5	3,51		
1999	8	27	9	3,31		
1999	8	27	15	3,01		
1999	8	27	16	3,11		
1999	8	27	7	3,51	3,3	71,1
1999	8	27	10	3,81		3
1999	8	27	10	3,21		
1999	8	27	5	3,11		
1999	8	27	10	3,11		

Çizelge 3. (Devamı) Gerçek ve Tahmin Edilen Büyüklük Verileri

	Tarih	Der. (km)	Büyüklük (M>=3)	ılama Büyü (M>=3)	Olasılık (%)	Tahmin (M)
1999	8	28	7	3,11		
1999	8	28	5	3,61		
1999	8	28	5	3,31		
1999	8	28	22	3,31		
1999	8	28	9	3,61	3,4	68,3
1999	8	28	5	3,71		3,2
1999	8	28	9	3,51		
1999	8	28	9	3,21		
1999	8	28	9	3,01		
1999	8	29	5	3,31		
1999	8	29	5	3,21		
1999	8	29	7	4,81		
1999	8	29	16	4,01	3,7	70,3
1999	8	29	5	3,51		3,4
1999	8	29	12	3,31		
1999	8	29	4	3,61		
1999	8	29	7	3,61		
1999	8	30	9	3,31		
1999	8	30	4	4,01		
1999	8	30	5	3,21		
1999	8	30	8	3,21		
1999	8	30	1	3,01		
1999	8	30	5	3,11	3,3	69,8
1999	8	30	5	3,01		2,9
1999	8	30	8	3,51		
1999	8	30	10	3,11		
1999	8	30	5	3,21		
1999	8	30	13	3,11		
1999	8	30	4	3,31		
1999	8	31	17	5,21		
1999	8	31	10	4,61		
1999	8	31	4	3,01		
1999	8	31	20	3,21		
1999	8	31	1	3,01		
1999	8	31	5	3,11	3,5	70,3
1999	8	31	7	3,11		3
1999	8	31	19	4,11		
1999	8	31	10	3,31		
1999	8	31	7	3,11		
1999	8	31	14	3,21		

Bu arařtırmada, 1990-2022 yılları arasında Türkiye Marmara Bölgesinde yer alan coğrafi konumu, 40° 49' 59" Kuzey ile 31° 10' 0" Doğu gps koordinatlarına sahip Düzce ili üzerinde RNN yöntemini kullanarak deprem tahmini ve tahmin edilme oranları incelenmiştir. Veri seti olarak, deprem büyüklüğü, derinlik, Ay'ın dünyaya uzaklığı, b değeri ve d değeri kullanılmıştır. Yapılan çalışmalarda farklı yöntemler kullanılmasına rağmen sismik veriler, düzensiz veri yapısına sahip olduğu için %100 oranla tahmin edilmesinin zor olduğu görülmektedir. Yapılan çalışmada, araştırma bulgularına göre hazırlanan

veri seti ve kullanılan yöntem ile tahmin edilen büyüklük değerleri, gerçek deprem büyüklüğüne yakın değerler olduğu tespit edilmiştir. Çalışmanın, gelecek tahmin çalışmalarına faydalı olacağı ön görülmektedir.

## **IX. KAYNAKÇA**

### **KİTAPLAR**

ALPAYDIN, E. (2004). **Introduction to machine learning** (adaptive computation and machine learning series). The MIT Press Cambridge.

ALPAYDIN, E., 2014. **Introduction to Machine Learning 3rd ed.**, MIT Press.

ÖZTEMEL, E. (2003). **Yapay sinir ağları**. PapatyaYayincilik, Istanbul.

### **MAKALELER**

ADELI, H., & PANAKKAT, A. (2009). A probabilistic neural network for earthquake magnitude prediction. **Neural networks**, 22(7), 1018-1024.

AKILLI, A., & HÜLYA, A. T. I. L. (2014). Süt sığırcılığında yapay zeka teknolojisi: Bulanık mantık ve yapay sinir ağları. **Hayvansal Üretim**, 55(1), 39-45.

AL-BAGHDADI, J. A., MOZAHIM HAMDOON, R., & JANAN YOSIEF, F. (2020). Prediction the Locations of Future Earthquakes in Eastern Part of Iraq Using GIS Techniques. **MS&E**, 745(1), 012134.

AL BANNA, M. H., GHOSH, T., AL NAHIAN, M. J., TAHER, K. A., KAISER, M. S., MAHMUD, M., ... & ANDERSSON, K. (2021). Attention-based bi-directional long-short term memory network for earthquake prediction. **IEEE Access**, 9, 56589-56603.

ALI, J., KHAN, R., AHMAD, N., & MAQSOOD, I. (2012). Random forests and decision trees. **International Journal of Computer Science Issues (IJCSI)**, 9(5), 272.

ALVES, E. I. (2006). Earthquake forecasting using neural networks: results and future work. **Nonlinear Dynamics**, 44(1), 341-349.

- ARISOY, E., SETHY, A., RAMABHADHAN, B., & CHEN, S. (2015, April). Bidirectional recurrent neural network language models for automatic speech recognition. In 2015 IEEE International Conference on Acoustics, **Speech and Signal Processing (ICASSP)** (pp. 5421-5425). IEEE..
- ASIM, K. M., İDRİS, A., IQBAL, T., & MARTÍNEZ-ÁLVAREZ, F. (2018). Seismic indicators based earthquake predictor system using Genetic Programming and AdaBoost classification. **Soil Dynamics and Earthquake Engineering**, 111, 1-7.
- ASIM, K. M., MOUSTAFA, S. S., NIAZ, I. A., ELAWADI, E. A., IQBAL, T., & MARTÍNEZ-ÁLVAREZ, F. (2020). Seismicity analysis and machine learning models for short-term low magnitude seismic activity predictions in Cyprus. **Soil Dynamics and Earthquake Engineering**, 130, 105932.
- ATASEVEN, B. (2013). Yapay sinir ağları ile öngörü modellemesi.
- AZAM, F., SHARIF, M., YASMIN, M., & MOHSIN, S. (2014). Artificial intelligence based techniques for earthquake prediction: a review. **Sci Int**, 26(4), 1495-1502.
- BAI, T., & TAHMASEBI, P. (2022). Attention-based LSTM-FCN for earthquake detection and location. **Geophysical Journal International**, 228(3), 1568-1576.
- BAYRAK, E. A., & KIRCI, P. (2019). Intelligent Big Data Analytics in Health. In Early Detection of Neurological Disorders Using Machine Learning Systems (pp. 252-291). **IGI Global**.
- BIBI, I., AKHUNZADA, A., MALIK, J., IQBAL, J., MUSADDIQ, A., & KIM, S. (2020). A dynamic DL-driven architecture to combat sophisticated Android malware. **IEEE Access**, 8, 129600-129612
- BINGOL, K., ASLI, E. R., ORMECIOGLU, H. T., & ARZU, E. R. (2020). Depreme dayanıklı mimari tasarımda yapay zeka uygulamaları: Derin öğrenme ve görüntü işleme yöntemi ile düzensiz taşıyıcı sistem tespiti.



**Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi**, 35(4), 2197-2210.

BRYKOV, M. N., PETRYSHYNETS, I., PRUNCU, C. I., EFREMENKO, V. G., PIMENOV, D. Y., GIASIN, K., ... & WOJCIECHOWSKI, S. (2020). Machine learning modelling and feature engineering in seismology experiment. **Sensors**, 20(15), 4228.

BURAK, K. O. C. A., & KEMAL, A. D. E. M. (2022). Bilişim Teknolojileri Öğretmenlerinin Blok Tabanlı Kodlama Araçlarına İlişkin Öz Yeterlik İnançlarının Evrimsel Sinir Ağı ile Sınıflandırılması. **Avrupa Bilim ve Teknoloji Dergisi**, (36), 50-54.

CHUNG, J., GULCEHRE, C., CHO, K., & BENGIO, Y. (2014). Empirical evaluation of gated recurrent neural networks on sequence modeling. **arXiv preprint arXiv:1412.3555**.

ÇAM, H., & DUMAN, O. (2016). YAPAY SİNİR AĞI YÖNTEMİYLE DEPREM TAHMİNİ: TÜRKİYE BATI ANADOLU FAY HATTI UYGULAMASI. Gümüşhane University Electronic Journal of the Institute of Social Science/**Gümüşhane Üniversitesi Sosyal Bilimler Enstitüsü Elektronik Dergisi**, 7(17).

ÇELİK, E., ATALAY, M., & BAYER, H. (2014, April). Earthquake prediction using seismic bumps with artificial neural networks and support vector machines. In 2014 22nd Signal Processing and Communications Applications Conference (SIU) (pp. 730-733). **IEEE**.

DESCHAMPS, A., IANNACCONE, G., & SCARPA, R. (1984). The umbrian earthquake (Italy) of 19 september 1979. **Ann. Geophys**, 2(1), 29-36.

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.

ERGEZER, H., DIKMEN, M., & ÖZDEMİR, E. (2003). Yapay sinir ağları ve tanıma sistemleri. **PİVOLKA**, 2(6), 14-17.

- FAOUZI, J., & JANATI, H. (2020). pyts: A Python Package for Time Series Classification. **Journal of Machine Learning Research**, 21(46), 1-6.
- FLORIOS, K., CONTOPOULOS, I., TATSIS, G., CHRISTOFILAKIS, V., CHRONOPOULOS, S., REPAPIS, C., & TRITAKIS, V. (2021). Possible earthquake forecasting in a narrow space-time-magnitude window. **Earth Science Informatics**, 14(1), 349-364.
- GARCIA, J., 2014. Machine Learning and Cognitive Systems: The Next Evolution of Enterprise Intelligence (Part I). **WIRED Magazine**.
- GAO, Y., & GLOWACKA, D. Deep gate recurrent neural network. In Proceedings of the Asian Conference on Machine Learning, Hamilton, New Zealand, 16–18 November 2016; pp. 350–365.
- GAO, Y., & GLOWACKA, D. (2016, November). Deep gate recurrent neural network. In Asian conference on machine learning (pp. 350-365). **PMLR**.
- GENTILI, S., & DI GIOVAMBATTISTA, R. (2022). Forecasting strong subsequent earthquakes in California clusters by machine learning. **Physics of the Earth and Planetary Interiors**, 327, 106879.
- GIMSA, A. (2020). Development of the Distance Earth-Moon. **International Journal of Scientific Research and Management**, 8(03).
- GIMSA, A. Development of the Distance Earth-Moon. **Int. J. Sci. Res. Manag.** 2020, 8, 10–13.
- GRAVES, A., LIWICKI, M., FERNÁNDEZ, S., BERTOLAMI, R., BUNKE, H., & SCHMIDHUBER, J. (2008). A novel connectionist system for unconstrained handwriting recognition. **IEEE transactions on pattern analysis and machine intelligence**, 31(5), 855-868.
- GRAVES, A., & SCHMIDHUBER, J. (2005). Framewise phoneme classification with bidirectional LSTM and other neural network architectures. **Neural networks**, 18(5-6), 602-610.
- GÜLTEPE, Y. (2019). Makine Öğrenmesi Algoritmaları ile Hava Kirliliği Tahmini Üzerine Karşılaştırmalı Bir Değerlendirme. **Avrupa Bilim ve Teknoloji Dergisi**, (16), 8-15.

- GÜVEN, Z. B., & BİLGİN, T. T. (2014). Zaman Serileri Madenciliği Kullanılarak Nüfus Artışı Tahmin Uygulaması. **Acad Inform**, 5-7.
- HÄRDLE, W., LUTKEPOHL, H., & CHEN, R. (1997). A review of nonparametric time series analysis. **International statistical review**, 65(1), 49-72.
- HUANG, J. P., WANG, X. A., ZHAO, Y., XIN, C., & XIANG, H. (2018). Large earthquake magnitude prediction in Taiwan based on deep learning neural network. **Neural Network World**, 28(2), 149-160.
- ISHIBASHI, K. (2004). Status of historical seismology in Japan. **Annals of Geophysics**, 47(2-3).
- JENA, R., NAIK, S. P., PRADHAN, B., BEYDOUN, G., PARK, H. J., & ALAMRI, A. (2021). Earthquake vulnerability assessment for the Indian subcontinent using the Long Short-Term Memory model (LSTM). **International Journal of Disaster Risk Reduction**, 66, 102642.
- KASAP, R., & GÜRLEN, Ü. (2003). Deprem magnitüdüleri için tekrarlanma yıllarının elde edilmesi: Marmara Bölgesi örneği.
- KARA, Ş. E., & ŞAMLI, R. (2021). Yazılım Projelerinin Maliyet Tahmini için WEKA'da Makine Öğrenmesi Algoritmalarının Karşılaştırmalı Analizi. **Avrupa Bilim ve Teknoloji Dergisi**, (23), 415-426.
- KARAKUŞ, U. (2014). DEPREMİ YAŞAMIŞ VE YAŞAMAMIŞ ÖĞRENCİLERİN DEPREM ALGILARININ, METAFOR ANALİZİ İLE İNCELENMESİ. **Doğu Coğrafya Dergisi**, 18(29), 97-116.
- KHAN, I., CHOI, S., & KWON, Y. W. (2020). Earthquake detection in a static and dynamic environment using supervised machine learning and a novel feature extraction method. **Sensors**, 20(3), 800.
- KOLLAM, M., & JOSHI, A. (2020, August). Earthquake Forecasting by Parallel Support Vector Regression Using CUDA. In 2020 International Conference on Computing, Electronics & Communications Engineering (iCCECE) (pp. 150-155). **IEEE**.

- KONONENKO, I., 2001. Machine learning for medical diagnosis: history, state of the art and perspective. **Artificial Intelligence in Medicine**, 23(1), pp.89–109.
- KÖLE, M. M. (2016). Çankırı ili için deprem olasılık tahmini. **Çankırı Karatekin Üniversitesi Sosyal Bilimler Enstitüsü Dergisi**, 7(1), 455-470.
- KRISCHER, L., MEGIES, T., BARSCH, R., BEYREUTHER, M., LECOCQ, T., CAUDRON, C., & WASSERMANN, J. (2015). ObsPy: A bridge for seismology into the scientific Python ecosystem. **Computational Science & Discovery**, 8(1), 014003.
- LI, L., SHI, Y., & CHENG, S. (2022). Exploration of long short-term memory neural network in intermediate earthquake forecast: a case study in Sichuan-Yunnan region. **Chinese Journal of Geophysics**, 65(1), 12-25.
- 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.
- MAZANOĞLU, E. Ç. K. (2017). Uşak ili çevresindeki depremlerin yapay sinir ağları ile modellenmesi. **Journal of Science and Engineering**, 19(56).
- MURWANTARA, I. M., YUGOPUSPİTO, P., & HERMAWAN, R. (2020). Comparison of machine learning performance for earthquake prediction in Indonesia using 30 years historical data. **TELKOMNIKA (Telecommunication Computing Electronics and Control)**, 18(3), 1331-1342.
- MYLES, A. J., FEUDALE, R. N., LIU, Y., WOODY, N. A., & BROWN, S. D. (2004). An introduction to decision tree modeling. **Journal of Chemometrics: A Journal of the Chemometrics Society**, 18(6), 275-285.

- NEZ, J. L. M. N., & LANTADA, A. S. D. Artificial Intelligence Aided Engineering Education: State of the Art, Potentials and Challenges,2020.
- NUTTLI, O. (1961). The effect of the Earth's surface on the S wave particle motion. **Bulletin of the Seismological Society of America**, 51(2), 237-246.
- OBERMEYER, Z. & EMANUEL, E.J., 2016. Predicting the Future — Big Data, Machine Learning, and Clinical Medicine. **New England Journal of Medicine**, 375(13), pp.1216–1219.
- OSTERTAGOVÁ, E. (2012). Modelling using polynomial regression. **Procedia Engineering**, 48, 500-506.
- ÖZDOĞAN, S. (1993). Türkiye'nin deprem bölgeleri. **Türkiye Coğrafyası Araştırma ve Uygulama Merkezi Dergisi**, 2, 53-68.
- ÖZEKES, S. (2003). Veri madenciliği modelleri ve uygulama alanları.
- ÖZMEN, B. (2012). Türkiye deprem bölgeleri haritalarının tarihsel gelişimi. **Türkiye Jeoloji Bülteni**, 55(1).
- ÖZMEN, B. (2013). Ankara için Deprem Olasılığı Tahminleri. **Yerbilimleri**, 34(1), 141-168.
- ÖZMEN, B. (2011). Kastamonu ve yakın çevresi için deprem olasılığı tahminleri. **Türkiye Jeoloji Bülteni**, 54(3), 109-122.
- ÖZTÜRK, S. (2015). Depremselliğin fraktal boyutu ve beklenen güçlü depremlerin orta vadede bölgesel olarak tahmini üzerine bir modelleme: Doğu Anadolu Bölgesi, Türkiye. **Gümüşhane Üniversitesi Fen Bilimleri Dergisi**, 5(1), 1-23.
- ÖZTÜRK, E., & TOPRAK, B. (2016). Düzce İli Karaçörtlen Köy Yolu Hattı Heyelan Riskinin İnklinometre Çalışmalarıyla Araştırılması. **Düzce Üniversitesi Bilim ve Teknoloji Dergisi**, 4(3), 902-910.
- ÖZTÜRK, S. (2017) ELAZIĞ DEPREMLERİ İÇİN GUTENBERG-RICHTER b-DEĞERİ VE FRAKTAL BOYUT Dc-DEĞERİNİN İSTATİSTİKSEL

**BİR ANALİZİ. 4. Uluslararası Deprem Mühendisliği ve Sismoloji Konferansı.**

- PAL, M. (2005). Random forest classifier for remote sensing classification. **International journal of remote sensing**, 26(1), 217-222.
- 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.
- PARZEN, E. (1961). An approach to time series analysis. **The Annals of Mathematical Statistics**, 32(4), 951-989.
- POLAT, O., GOEK, E., & YILMAZ, D. (2008). Earthquake hazard of the Aegean extension region (West Turkey). **Turkish Journal of Earth Sciences**, 17(3), 593-614.
- PURNOMO, M. R. A. (2020). A Bayesian Reasoning for Earthquake Prediction Based on IoT System. **JPhCS**, 1471(1), 012022.
- PRIYAM, A., ABHIJEETA, G. R., RATHEE, A., & SRIVASTAVA, S. (2013). Comparative analysis of decision tree classification algorithms. **International Journal of current engineering and technology**, 3(2), 334-337.
- SARKAR, S., ROY, A., KUMAR, S., & DAS, B. (2021). Seismic Intensity Estimation Using Multilayer Perceptron for Onsite Earthquake Early Warning. **IEEE Sensors Journal**, 22(3), 2553-2563.
- SCHONLAU, M., & ZOU, R. Y. (2020). The random forest algorithm for statistical learning. **The Stata Journal**, 20(1), 3-29.
- SCHUSTER, M., & PALIWAL, K. K. (1997). Bidirectional recurrent neural networks. **IEEE transactions on Signal Processing**, 45(11), 2673-2681.
- SEBATLI-SAĞLAM, A., & ÇAVDUR, F. (2022). Yapay sinir ağı ile deprem şiddeti tahmini: Farklı ağ tasarımlarının ve eğitim algoritmalarının incelenmesi. **Journal of the Faculty of Engineering & Architecture of Gazi University**, 37(4).

- SENYÜCEL, M. (2008). Motor erken uyarı sistemi.
- SELVIN, S., VINAYAKUMAR, R., GOPALAKRISHNAN, E. A., MENON, V. K., & SOMAN, K. P. (2017, September). Stock price prediction using LSTM, RNN and CNN-sliding window model. **In 2017 international conference on advances in computing, communications and informatics (icacci)** (pp. 1643-1647). IEEE.
- SHERSTINSKY, A. (2020). Fundamentals of recurrent neural network (RNN) and long short-term memory (LSTM) network. **Physica D: Nonlinear Phenomena**, 404, 132306.
- SPROAT, R., & JAITLY, N. (2017). An RNN Model of Text Normalization. **In INTERSPEECH** (pp. 754-758).
- STAUDEMAYER, R. C., & MORRIS, E. R. (2019). Understanding LSTM--a tutorial into long short-term memory recurrent neural networks. **arXiv preprint arXiv:1909.09586**.
- SZEPESVÁRI, C. (2010). Algorithms for reinforcement learning. **Synthesis lectures on artificial intelligence and machine learning**, 4(1), 1-103.
- ŞENTÜRK, E., SAQIB, M., & ADİL, M. A. (2022). A Multi-Network based Hybrid LSTM model for ionospheric anomaly detection: A case study of the Mw 7.8 Nepal earthquake. **Advances in Space Research**.
- TAREEN, A. D. K., NADEEM, M. S. A., KEARFOTT, K. J., ABBAS, K., KHAWAJA, M. A., & RAFIQUE, M. (2019). Descriptive analysis and earthquake prediction using boxplot interpretation of soil radon time series data. **Applied radiation and isotopes**, 154, 108861.
- UYANIK, G. K., & GÜLER, N. (2013). A study on multiple linear regression analysis. **Procedia-Social and Behavioral Sciences**, 106, 234-240.
- WANG, F., & TAX, D. M. (2016). Survey on the attention based RNN model and its applications in computer vision. **arXiv preprint arXiv:1601.06823**.

- WANG K.L., CHEN Q.F., SUN S.H., WANG A.D.: Predicting the 1975 haicheng earthquake. **Bulletin of the Seismological Society of America**, 2006, 96(3), pp. 757-795.
- WU, Y. M., & ZHAO, L. (2006). Magnitude estimation using the first three seconds P-wave amplitude in earthquake early warning. **Geophysical research letters**, 33(16).
- WU, Y.M.; ZHAO, L. Magnitude estimation using the first three seconds P-wave amplitude in earthquake early warning. **Geophys. Res. Lett.** 2006, 33, L16312.
- XIAO, W. T., CHANG, L. J., & LIU, W. M. (2018, May). Semantic segmentation of colorectal polyps with DeepLab and LSTM networks. **In 2018 IEEE International Conference on Consumer Electronics-Taiwan (ICCE-TW)** (pp. 1-2). IEEE.
- VAN DER ELST, N. J., & SHAW, B. E. (2015). Larger aftershocks happen farther away: **Nonseparability of magnitude and spatial distributions of aftershocks**. **Geophysical Research Letters**, 42(14), 5771-5778.
- VEDALDI, A., & LENC, K. (2015, October). Matconvnet: Convolutional neural networks for matlab. **In Proceedings of the 23rd ACM international conference on Multimedia** (pp. 689-692).
- YAMASAKI, E. (2012). What we can learn from Japan's early earthquake warning system. **Momentum**, 1(1), 2.
- YILMAZ, D. G. Guangming Köyü ve diğerler örnekler: Afet sonrası Çin kırsalında yapılaşma. **Kent Akademisi**, 12(2), 241-256.
- YILMAZ, O., & MİSLİ, Ç. (2016). Aristarchus Yöntemi ile Ay ve Güneş. **Fizik Dünyası Dergisi**, 1(3).
- YİĞİTER, Ş. Y., SARI, S. S., & BAŞAKIN, E. E. (2017). Hisse senedi kapanış fiyatlarının yapay sinir ağları ve bulanık mantık çıkarım sistemleri ile tahmin edilmesi, **dergipark**.
- ZAKARIA, H. L., & ZAMLI, K. Z. (2017). Elitism based migrating birds optimization algorithm for combinatorial interaction testing.



**International Journal of Software Engineering and Technology**,  
3(1).

ZHOU, Z.-H., 2009. Ensemble Learning. In Encyclopedia of Biometrics. Boston,  
**MA:Springer US**, pp. 270–273.

ZHU, X., & GOLDBERG, A. B. (2009). Introduction to semi-supervised  
learning. **Synthesis lectures on artificial intelligence and machine  
learning**, 3(1), 1-130.

#### **ELEKTRONİK KAYNAKLAR**

AKU, “DEPREMLERİN OLUŞUMU VE TÜRLERİ”, AFYON KOCATEPE  
ÜNİVERSİTESİ Deprem Uygulama ve Araştırma Merkezi,  
<https://deprem.aku.edu.tr/depremlerin-olusumu-ve-tURLeri>, (Erişim  
Tarihi: 08.09.2021)

ELİÇALIŞKAN, M. “Coğrafya dünyası”, <http://www.cografya.gen.tr>, (Erişim  
Tarihi: 31.11.2021).

URL-1 “Jeolojik Yapı”, <<http://www.duzce.gov.tr/jeolojik-yapi>>, (Erişim  
Tarihi: 17 Mayıs 2022)

URL-2 “Deprem”, <[https://www.mta.gov.tr/v3.0/sayfalar/bilgi-merkezi/deprem/  
pdf/](https://www.mta.gov.tr/v3.0/sayfalar/bilgi-merkezi/deprem/pdf/)>, (Erişim Tarihi: 17 Mayıs 2022)

URL-3 “Sismik Ağ Haritası”, <[http://www.koeri.boun.edu.tr/sismo/2/sismik-  
ag/sismik-ag-haritalari/sismik-ag-haritalari-2/genisbantistasyonlar/](http://www.koeri.boun.edu.tr/sismo/2/sismik-ag/sismik-ag-haritalari/sismik-ag-haritalari-2/genisbantistasyonlar/)>,  
(Erişim Tarihi: 18 Mayıs 2022)

URL-4 “İstasyonlar”,  
<[http://www.koeri.boun.edu.tr/sismo/istasyonlar/BB\\_istasyonlar.htm](http://www.koeri.boun.edu.tr/sismo/istasyonlar/BB_istasyonlar.htm)>  
, (Erişim Tarihi: 31 Aralık 2022)

URL-5 “Recurrent Neural Network Maths”,  
<[https://medium.com/@vidishajitani25/recurrent-neural-network-  
maths-69214e4d69e1](https://medium.com/@vidishajitani25/recurrent-neural-network-maths-69214e4d69e1)>, (Erişim Tarihi: 03 Mart 2022)

URL-6 “Bidirectional Recurrent Neural Networks”, <  
[https://deepai.org/machine-learning-glossary-and-terms/bidirectional-  
recurrent-neural-networks](https://deepai.org/machine-learning-glossary-and-terms/bidirectional-recurrent-neural-networks)>, (Erişim Tarihi: 17 Temmuz 2022)

URL-7 “Recurrent Neural Network Nedir”,

< <https://medium.com/@hamzaerguder/recurrent-neural-network-nedir-bdd3d0839120>>, (Eriřim Tarihi: 17 Temmuz 2022)

URL-8 “Moon Distance”,

<<https://www.timeanddate.com/astronomy/moon/distance.html>>, (Eriřim Tarihi: 07 Ocak 2022)

## **TEZLER**

BALKASOĐLU, ř. (2018). Bölgesel deprem tahmini için tekrarlı yapay sinir ađı modelinin geliştirilmesi (Master's thesis, Fen Bilimleri Enstitüsü).

CEYLAN, S. (2008). Marmara depremlerinin kaotik özellikleri ve fraktal analizi (Doctoral dissertation, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul, 90).

INALEGWU, O. C. (2015). Predicting Time Lag Between Primary And Secondary Waves For Earthquakes Using Artificial Neural Network (ANN) (Doctoral dissertation, Eastern Mediterranean University (EMU)-Dođu Akdeniz Üniversitesi (DAÜ)).

KOÇAK, H. Y., & MENĐİ, A. T. D. Bir Doğal Afet Olarak Depreme Hazırlıklı Olma Bilinci Ve Katılım: Abd, Japonya Ve Türkiye (Doctoral Dissertation, Ankara Üniversitesi Sosyal Bilimler Enstitüsü Kamu Yönetimi Ve Siyaset Bilimi (Kent Ve Çevre Bilimleri) Ana Bilim Dalı).

KUTLUGÜN, M. A. (2017). Gözetimli makine öğrenmesi yoluyla türe göre metinden ses sentezleme (Master's thesis, İstanbul Sabahattin Zaim Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliđi Anabilim Dalı).

ÖZERDEM, M. S. (2003), Sismik anomalilerin yapay sinir ađları yöntemi ile tanınması ve sınıflandırılması, İstanbul Teknik Üniversitesi, İstanbul.

UYSAL, A. E. (2009). Yapay zekanın Temelleri Ve Bir Yapay Sinir ađı uygulaması (Doctoral dissertation, Marmara Üniversitesi (Turkey)).

## **ĐĐĐER KAYNAKLAR**

- MIKOLOV, T., KARAFIÁT, M., BURGET, L., CERNOCKÝ, J., & KHUDANPUR, S. (2010, September). Recurrent neural network based language model. In Interspeech (Vol. 2, No. 3, pp. 1045-1048).
- NORIEGA, L. (2005). Multilayer perceptron tutorial. School of Computing. Staffordshire University.
- RIEDMILLER, M., & LERNEN, A. (2014). Multi layer perceptron. Machine Learning Lab Special Lecture, University of Freiburg, 7-24.
- SYKES, A. O. (1993). An introduction to regression analysis.
- TRANMER, M., & ELLIOT, M. (2008). Multiple linear regression. The Cathie Marsh Centre for Census and Survey Research (CCSR), 5(5), 1-5.

## ÖZGEÇMİŞ

**Ad-Soyad: Turgut PURA**

### ÖĞRENİM DURUMU:

**Lisans:** 2009, İstanbul Kültür Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği

**Yüksek Lisans :** 2016, İstanbul Aydın Üniversitesi, Bilgisayar Mühendisliği Anabilim Dalı, Bilgisayar Mühendisliği (Tezli)

### MESLEKİ DENEYİM VE ÖDÜLLER:

### TEZDEN TÜRETİLEN YAYINLAR, SUNUMLAR VE PATENTLER:

Pura, T., Güneş, P., Güneş, A., Hameed, A.A., 2023. Earthquake Prediction for the Marmara Region of Düzce Province Using Artificial Intelligence, *Applied Science*, 2076-3417.

### DİĞER YAYINLAR, SUNUMLAR VE PATENTLER

HORASAN, A., PURA, T. & SÖNMEZ, F. (2021). YENİ NESİL VERİ GÜVENLİĞİ BAĞLAMINDA DAĞITIK SİSTEMLER ÜZERİNDE

BLOCKCHAIN KULLANIMI VE BITCOIN UYGULAMASI. Tasarım Mimarlık ve Mühendislik Dergisi, 1(2), 110-118.

PURA, T., & GÜNEŞ, A., (2016). Web Tabanlı Eğitimin Nitelik ve Nicelik Bakımından İncelenmesi ve Bir Ders Arşiv Sistemi Yazılım Önerisi. İstanbul Aydın Üniversitesi Dergisi Anadolu Bil Meslek Yüksekokulu, (42).

PURA, T, & AYDOĞAN, Ş., (2020). Bilgi Güvenliğinde En Çok Tercih Edilen Uygulamaların Belirlenmesi. UGEBAK 2019 ve IV. ELMIS 2019, 112-121.

ASLAN, K. & PURA, T., (2015). Web Tabanlı Eğitimin Verimliliğinin Araştırılması. Eğitim ve Öğretim Araştırmaları Dergisi 4 (4), 1-7.