



**MAKİNE ÖĞRENMESİ TEKNİKLERİ İLE DEPREM
TEHLİKE HARİTALARININ BELİRLENMESİ**

YÜKSEK LİSANS TEZİ

Ertuğrul DEMİRELLİ

Danışman

Prof. Dr. İbrahim TİRYAKİOĞLU

İkinci Danışman

Dr. Öğr. Üyesi Halil İbrahim SOLAK

HARİTA MÜHENDİSLİĞİ ANABİLİM DALI

Temmuz 2023

Bu tez çalışması 22.FEN.BİL.31 numaralı proje ile AKÜ BAPK tarafından desteklenmiştir.

AFYON KOCATEPE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

MAKİNE ÖĞRENMESİ TEKNİKLERİ İLE DEPREM
TEHLİKE HARİTALARININ BELİRLENMESİ

Ertuğrul DEMİRELLİ

Danışman

Prof. Dr. İbrahim TİRYAKİOĞLU

İkinci Danışman

Dr. Öğr. Üyesi Halil İbrahim SOLAK

HARİTA MÜHENDİSLİĞİ ANABİLİM DALI

Temmuz 2023

TEZ ONAY SAYFASI

Ertuğrul DEMİRELLİ tarafından hazırlanan “Makine Öğrenmesi Teknikleri ile Deprem Tehlike Haritalarının Belirlenmesi” adlı tez çalışması lisansüstü eğitim ve öğretim yönetmeliğinin ilgili maddeleri uyarınca 11 / 07 / 2023 tarihinde aşağıdaki jüri tarafından **oy birliği** ile Afyon Kocatepe Üniversitesi Fen Bilimleri Enstitüsü **Harita Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Danışman : Prof. Dr. İbrahim TİRYAKİOĞLU

İkinci Danışman : Dr. Öğr. Üyesi Halil İbrahim SOLAK

Başkan : Prof. Dr. Tamer BAYBURA
Afyon Kocatepe Üniversitesi, Mühendislik Fakültesi

Üye : Prof. Dr. İbrahim TİRYAKİOĞLU
Afyon Kocatepe Üniversitesi, Mühendislik Fakültesi

Üye : Doç. Dr. Süleyman Sefa BİLGİLİOĞLU
Aksaray Üniversitesi, Mühendislik Fakültesi

Afyon Kocatepe Üniversitesi
Fen Bilimleri Enstitüsü Yönetim Kurulu’nun
..... / / tarih ve
..... sayılı kararıyla onaylanmıştır.

.....
Prof. Dr. İbrahim EROL
Enstitü Müdürü

BİLİMSEL ETİK BİLDİRİM SAYFASI
Afyon Kocatepe Üniversitesi

Fen Bilimleri Enstitüsü, tez yazım kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez içindeki bütün bilgi ve belgeleri akademik kurallar çerçevesinde elde ettiğimi,
- Görsel, işitsel ve yazılı tüm bilgi ve sonuçları bilimsel ahlak kurallarına uygun olarak sunduğumu,
- Başkalarının eserlerinden yararlanılması durumunda ilgili eserlere bilimsel normlara uygun olarak atıfta bulunduğumu,
- Atıfta bulunduğum eserlerin tümünü kaynak olarak gösterdiğimi,
- Kullanılan verilerde herhangi bir tahrifat yapmadığımı,
- Ve bu tezin herhangi bir bölümünü bu üniversite veya başka bir üniversitede başka bir tez çalışması olarak sunmadığımı

beyan ederim.

11 / 07 / 2023

Ertuğrul DEMİRELLİ

ÖZET

Yüksek Lisans Tezi

MAKİNE ÖĞRENMESİ TEKNİKLERİ İLE DEPREM TEHLİKE HARİTALARININ BELİRLENMESİ

Ertuğrul DEMİRELLİ

Afyon Kocatepe Üniversitesi

Fen Bilimleri Enstitüsü

Harita Mühendisliği Anabilim Dalı

Danışman: Prof. Dr. İbrahim TİRYAKİOĞLU

İkinci Danışman: Dr. Öğr. Üyesi Halil İbrahim SOLAK

Ülkemiz taşıdığı coğrafi şartlar gereği doğal afetler, özellikle de deprem gerçeği ile sıklıkla yüzleşmektedir. Can ve mal kayıplarının büyük bölümünün depremlerde meydana geldiği ve 5 yılda bir bu coğrafyanın yıkıcı bir depremle sarsıldığı düşünülürse, deprem afeti önlem alınması gereken afetler bakımından ilk sırada gelmektedir. Depremler için alınabilecek önlemlerin belirlenmesi için depremlerin önceden tahmin edilebilmesi büyük önem arz etmektedir. Bu bağlamda son yıllarda makine öğrenmesi ile deprem tahmini çalışmaları hız kazanmıştır. Literatürde çeşitli yöntemler ile bu çalışmaların yapıldığı görülmektedir. Bu çalışmada ise deprem kataloğu ile jeolojik ve jeodezik verilerin birleştirildiği bir veri seti oluşturulmuştur. Sonrasında hem tüm depremleri içeren ham veri hem de fay bilgilerinin ve gerinimlerin eklendiği veri seti uygun şekilde eğitim ve test verisi olarak ayrılmıştır. Random Forest, Xgboost, Decision Tree ve K-nn regresyon algoritmaları kullanılarak eğitim seti ile modeller eğitilmiş, eğitilen modeller test verisi ile test edilmiştir. Elde edilen sonuçlar karşılaştırılarak değerlendirilmiştir. Karesel ortalama hata değerlerine göre en iyi sonuç 0.09 ile random forest ve xgboost algoritmalarında elde edilirken, en kötü sonuç 0.19 ile decision tree algoritmasında elde edilmiştir. Son olarak kullanılan tüm algoritmalar ile geleceğe yönelik deprem tahminleri yapılarak, bu tahminler deprem tehlike haritalarının üretilmesinde kullanılmıştır. Yapılan bu çalışmada kullanılan veri seti ile makine öğrenmesi ile deprem tahmini çalışmalarına farklı bir bakış açısı getirerek literatüre katkıda bulunulmuştur.

2023, x + 54 sayfa

Anahtar Kelimeler: Deprem, Deprem katalođu, Makine öğrenmesi, Regresyon, Deprem tehlike haritası



ABSTRACT

M.Sc. Thesis

DETERMINING EARTHQUAKE HAZARD MAPS WITH MACHINE LEARNING TECHNIQUES

Ertugrul DEMIRELLI

Afyon Kocatepe University

Graduate School of Natural and Applied Sciences

Department of Geomatics Engineering

Supervisor: Prof. İbrahim TİRYAKİOĞLU

Co-Supervisor: Asst. Prof. Halil İbrahim SOLAK

Due to its geographical conditions, our country frequently faces the reality of natural disasters, especially earthquakes. Considering that most of the loss of life and property is caused by earthquakes and this region is shaken by a devastating earthquake every five years, earthquake disaster comes first in terms of disasters that require precautions. It is of great importance to be able to predict earthquakes in order to determine the precautions that can be taken for earthquakes. In this context, earthquake prediction studies with machine learning have gained momentum in recent years. It is seen in the literature that these studies have been carried out by various methods. In this study, a data set was created in which earthquake catalogue, geological data and geodetic data were combined. Afterwards, both the raw data including all earthquakes and the data set to which fault information and strains are added, are appropriately separated as training and test data. By using Random Forest, Xgboost, Decision Tree and K-nn regression algorithms, the models were trained with the training set and the trained models were tested with the test data. Obtained results were evaluated and compared. According to the square mean error values, the best result was obtained in the random forest and xgboost algorithms with 0.09, while the worst result was obtained in the decision tree algorithm with 0.19. Finally, earthquake predictions for the future were made with all the algorithms used, and these predictions were used in the production of earthquake hazard maps. This study

contributed to the literature by bringing a different perspective to the data set used in earthquake prediction studies with machine learning.

2023, x + 54 pages

Keywords: Earthquake, Earthquake catalog, Machine learning, Regression, Earthquake hazard map

TEŞEKKÜR

Bu araştırmanın konusu, deneysel çalışmaların yönlendirilmesi, sonuçların değerlendirilmesi ve yazımı aşamasında yapmış olduğu büyük katkılarından dolayı tez danışmanlarım Prof. Dr. İbrahim TİRYAKİOĞLU ve Dr. Öğr. Üyesi Halil İbrahim SOLAK`a ve her konuda öneri ve eleştirileriyle yardımlarını gördüğüm hocalarıma ve arkadaşlarıma teşekkür ederim.

Bu tez çalışması AKÜ BAPK tarafından 22.FEN.BİL.31 numaralı proje kapsamında desteklenmiştir

Bu araştırma ve tüm eğitim hayatım boyunca maddi ve manevi desteklerinden dolayı aileme teşekkür ederim.

Ertuğrul DEMİRELLİ
Afyonkarahisar 2023

İÇİNDEKİLER DİZİNİ

	Sayfa
Ertuğrul DEMİRELLİ	II
ÖZET	i
ABSTRACT	iii
TEŞEKKÜR	v
İÇİNDEKİLER DİZİNİ.....	vi
KISALTMALAR DİZİNİ	vii
ŞEKİLLER DİZİNİ	viii
ÇİZELGELER DİZİNİ.....	x
1. GİRİŞ.....	1
2. LİTERATÜR BİLGİLERİ	4
3. DEPREMLER VE ÖZELLİKLERİ	6
3.1 Depremlerin Oluşumu.....	7
3.2 Deprem Büyüklüğünü Etkileyen Parametreler	12
3.3 Türkiye'nin Depremselliği.....	13
4. DEPREM TEHLİKE HARİTALARI.....	16
5. MAKİNE ÖĞRENMESİ.....	21
5.1 Regresyon Algoritmaları.....	23
5.1.1 Karar Ağaçları (Decision Tree).....	23
5.1.2 K En Yakın Komşu (KNN).....	25
5.1.3 Rastgele Orman Algoritması (Random Forest).....	26
5.1.4 Extreme Gradient Boosting Trees (XGBoost)	27
6. MATERYAL VE METOD	29
6.1 Veri	29
6.2 Veri Ön işleme	35
6.3 Algoritma Seçimi	38
6.4 Uygulama.....	38
6.5 Deprem Tehlike Haritalarının Üretilmesi	40
7. TARTIŞMA VE SONUÇ	44
8. KAYNAKLAR.....	46
ÖZGEÇMİŞ.....	54

KISALTMALAR DİZİNİ

Kısaltmalar

AFAD	Afet ve Acil Durum Yönetimi Başkanlığı
AI	Yapay zeka
CART	Classification and regression tree
CBDT	Cause based decision tree
CHAID	Chi-squared automatic interaction detection
DT	Decision tree
KNN	K-en yakın komşu
KRDAE	Kandilli Rasathanesi Deprem Araştırma Enstitüsü
LL	Sol yanal
ML	Machine Learning
MTA	Maden Tetkik ve Arama
N	Normal
R	Ters
RF	Random Forest
RL	Sağ yanal
SES	Sismik elektrik sinyalleri
XGBOOST	Extreme gradient boosting

ŞEKİLLER DİZİNİ

	Sayfa
Şekil 3.1 Yerkürenin katman yapısı (Tiryakioğlu, 2012).....	8
Şekil 3.2 Dünyanın dış kısmındaki katmanlar (Press ve Siever 1999).	9
Şekil 3.3 Dünya tektonik plakaları haritası	10
Şekil 3.4 Fayların kuvvet altında gelişmeleri (Pres ve Siever 1999, Başçiftçi 2020). ...	11
Şekil 3.5 Horst ve Graben Yapısı (Pres ve Siever 1999).	12
Şekil 3.6 Avrasya, Afrika ve Arap plakaları hareketleri (Okay 2000, Ergünay 2007). .	15
Şekil 4.1 1945 yılında ilk defa hazırlanmış deprem bölgeleri haritası (Özmen 2012)...	16
Şekil 4.2 1963 yılında yayınlanan deprem tehlike haritası.	17
Şekil 4.3 Olasılık yöntemi ile hazırlanmış 1996 yılı deprem tehlike haritası (Seyrek 2020).	19
Şekil 4.4 2019 tarihli deprem tehlike haritası (https://www.afad.gov.tr).	19
Şekil 4.5 Jeodezik verilere göre hazırlanmış deprem tehlike haritası (Aktuğ 2017).	20
Şekil 5.1 Algoritma hiyerarşi yapısı.....	22
Şekil 5.2 Karar ağacı (DT) algoritması (Özgür ve Erdoğan, 2020).	24
Şekil 5.3 K en yakın komşu algoritması.	26
Şekil 5.4 Rastgele orman (RF) algoritması işlem adımları (Peker vd. 2017).	27
Şekil 5.5 Gradient boosting trees (XGBoost) algoritması (Shehadeh vd. 2021).	28
Şekil 6.1 Türkiye’de aletsel dönemde meydana gelen $M \geq 3$ depremler (KRDAE) (kırmızı çizgi; aktif fay, siyah daire: M:3., mavi daire: M:4., turkuaz daire: M:5., mor daire: M:6., kırmızı daire: M:7)	29
Şekil 6.2 Ege ve Marmara bölgeleri aktif fay veri tabanı (Emre vd. 2016).	30
Şekil 6.3 Şekil 6.1’de yer alan fay haritasının devamı. İç Anadolu ve Güneydoğu Anadolu bölgesi diri fay haritası (Emre vd. 2016).	31
Şekil 6.4 Şekil 6.1’de yer alan fay haritasının devamı. Doğu Anadolu bölgesi diri fay haritası (Emre vd., 2016).	32
Şekil 6.5 Veri setinin özellikleri.....	33
Şekil 6.6 Çalışma bölgesi gerinim alanı (kırmızı oklar: sıkışma, mavi oklar: açılma, kırmızı çizgiler: diri fay, mavi kıvrımlı çizgiler: ana nehirler, siyah üçgenler: GNSS noktaları).	34

Şekil 6.7 1970 – 2022 yılları arasında çalışma bölgesinde meydana gelmiş depremler (İnt.Kyn.3).	36
Şekil 6.8 Random forest modeli ile üretilmiş deprem tehlike haritası.	41
Şekil 6.9 Xgboost modeli ile üretilmiş deprem tehlike haritası.	42
Şekil 6.10 Decision tree modeli ile üretilmiş deprem tehlike haritası.	42



ÇİZELGELER DİZİNİ

	Sayfa
Çizelge 3.1 20. yüzyılda Türkiyede meydana gelmiş önemli depremler.	13
Çizelge 3.2 Sanayi ve baraj gibi önemli tesisler ve nüfusun deprem bölgelerine göre dağılımları.....	14
Çizelge 6.1 Değişkenler ve veri setinin özellikleri.....	34
Çizelge 6.2 Deprem verileri ve öznitelikleri. (NN: Normal, RL: Sağ atımlı. Depremlerin oluş tarihleri jülyen gününe çevrilerek etiketlenmişti.)	37
Çizelge 6.3 Veri setinin istatistiki bilgileri.....	38
Çizelge 6.4 Algoritmalar ve hata değerleri.	39
Çizelge 6.5 Değişken ağırlıkları.....	40

1. GİRİŞ

İnsanlık kendisini keşfettiği günden bugüne kadar geçen süreçte doğal afetlerle mücadele etmiştir. Afetler insanlığa ve medeniyetlere büyük zararlar vermiştir. İnsanlığa sosyal ve kültürel açıdan buna ek olarak ekonomik olarak büyük zarar veren yüzü aşkın afet çeşidi vardır. Toplumların birikimlerini dakikalar hatta saniyeler içinde yok edebilen deprem bu afetlerden en tehlikelisi olarak kabul edilebilir (Gündoğdu vd. 2012). Deprem, yer kabuğunda, fay adı verilen kırıklarda biriken enerjinin ani boşalması ile açığa çıkan yer değiştirmenin sonucunda ortaya çıkan karmaşık elastik dalga hareketleri olarak tanımlanmaktadır. Yapılan bilimsel çalışmalar doğrultusunda depremin oluş nedenlerinin yanı sıra deprem kavramının nicel özellikleri de ortaya çıkarılmıştır. Günümüzde meydana gelmiş bir depremin büyüklüğü, enlem-boylam olarak merkezi, derinliği bilinebilmektedir (Gündoğdu 1986, Işık vd. 2012).

Dünya üzerindeki nüfusun artması ve endüstriyelleşmeden dolayı toplumlar daha geniş yerleşim alanlarına dağılmış ve bu yerleşim alanları artan bir ivme ile büyümüştür. Toplumların tektonik açıdan aktif veya aktif bölgelere yakın bölgelere yerleşmesi ciddi boyutlarda bir deprem tehlikesinin ortaya çıkmasına neden olmuştur. 1994 yılında Kaliforniya'da meydana gelen Northridge depremi ($M_w = 6.7$), 1995 yılında Japonya'da meydana gelmiş olan Kobe depremi ($M_w = 7.5$) ve Tayland'da meydana gelen Chi-Chi depremi ($M_w = 7.6$) ciddi sayıda can kayıplarına, ekonomide milyarlarca dolarlık kayıplara neden olmuş depremlerdir (Utkucu ve Alptekin 2001, Utkucu vd. 2011). Ülkemiz de coğrafi olarak yüksek, eğimli ve fay hatlarının yer aldığı bir lokasyonda yer almasından dolayı doğal afetler sıklıkla yaşanmaktadır (Genç, 2007). 2020 yılında meydana gelmiş olan Elazığ depremi ($M_w = 6.8$), Sisam Adası açıklarında meydana gelen Sisam depremi ($M_w = 6.9$) ve 2023 yılında Kahramanmaraş'ta meydana gelen depremler ($M_w = 7.7$, $M_w = 7.6$) son yıllarda ülkemizde meydana gelmiş, can kaybının yanında ekonomik kayıplara da neden olmuş depremlerdir. Ülkemiz afet yönetimi ve afetlere yönelik istatistiklerin verildiği (AFAD 2018) tarafından yapılan çalışmada, ülkemizde afet kaynaklı ölümlerin %60'ı depremler nedeniyle olmuştur. Ortalama olarak yılda 1000 vatandaşımız hayatını kaybetmekte, 2100 vatandaşımız yaralanmakta ve 7000 bina hasar görmektedir.

Deprem afetinin maddi ve manevi açıdan büyük kayıplar yaşatabildiği ülkemizde, afet yönetimi büyük önem arz etmektedir. Afet yönetimi ile deprem öncesi, deprem anı ve sonrasında alınacak önlemler belirlenerek, afette yaşanabilecek can kayıpları ve maddi kayıplar en aza indirilebilir. Deprem tehlike haritaları afet yönetiminde deprensellik açısından en tehlikeli bölgeleri göstermesi ile alınacak önlemler için önemli bir altlık oluşturmaktadır.

Son dönemde teknoloji alanında yaşanan hızlı gelişmeler ile birlikte yapay zekâ ve makine öğrenmesi birçok alanda kullanılmaya başlanmıştır. Literatürde makine öğrenmesinin sağlık sektöründe hastalık teşhisi ve tedavi yöntemleri, bankacılık sektöründe siber saldırıların tespitinde ve inşaat sektöründe depreme dayanıklı mimari tasarım gibi alanlarda kullanıldığı görülmektedir (Başer vd. 2021, Kaya ve Yıldız 2014, Bingöl vd. 2020). Ayrıca uzaktan algılama alanında uydu görüntüleri kullanılarak arazi üzerindeki değişimlerin makine öğrenmesi algoritmaları yardımıyla bulunması ve bitki örtüsünün belirlenmesi gibi farklı alanlarda kullanılmaktadır (Efe ve Algancı 2023, Tunca ve Köksal 2021). Bunların yanında deprem kestirimi alanında da makine öğrenmesi algoritmalarının kullanıldığı görülmüştür.

Gelecek bir tarihte meydana gelebilecek depremlerin tahmin edilmesi ile ilgili çalışmalar incelendiğinde farklı yöntemler ve veri setleri ile yapılan çalışmaların olduğu görülmüştür. Yunanistan bölgesi için (Moustra vd. 2011) tarafından, deprem öncesinde ortaya çıktığı düşünülen sismik elektrik sinyalleri kullanılarak deprem tahmini üzerine bir çalışma yapılmıştır. Bir diğer çalışma ise (Rouet-Leduc vd. 2017) tarafından rastgele orman (RF) algoritması kullanılarak laboratuvar ortamında yapılmıştır. Çalışmadaki amaç laboratuvar ortamında depremler oluşturarak fay bloklarının hareketi ile ortaya çıkan akustik sinyallerin elde edilmesi ve bu sinyaller ile deprem tahmini yapılmasıdır. Aynı şekilde (Lubbers vd. 2018) laboratuvar ortamında RF algoritmasını kullanarak verileri katalog haline getirmişler ve akustik sinyallerinin deprem büyüklüğüne etkisini gözlemlemişlerdir. Bir diğer çalışmada ise (Gitis ve Derendyaev 2019) makine öğrenmesi algoritmaları ve deprem kataloglarını kullanarak depremin zamansal ve mekânsal tahmini üzerine çalışmalar yapmışlardır.

Bu çalışmada makine öğrenmesi algoritmaları kullanılarak ileri bir tarihte meydana gelebilecek depremlere ait yaklaşık büyüklüklerin belirlenmesi ve elde edilen çıktı verisi ile deprem tehlike haritalarının üretilmesi amaçlanmıştır. Makine öğrenmesi ile tahmin süreci ilk aşamada veri ön işleme sonrasında tahmin modellerinin eğitimi ve son olarak da sonuçların doğruluklarının değerlendirilmesi olarak üç adımdan meydana gelmektedir. Süreç içinde kullanılan veriler tarihsel deprem katalogları, Türkiye’de yer alan diri fay bilgileri gibi jeolojik veriler ve jeodezik ölçmelerle elde edilmiş gerinimlerden oluşmaktadır. Katalog verileri deprem oluş tarihi, enlem, boylam, derinlik (KM), büyüklük (xM), jeolojik veriler fay uzunluğu ve depremin faya olan uzaklığı, jeodezik veriler ise gerinimlerden oluşmaktadır. Bu veriler kullanılarak ileri bir tarihte oluşabilecek deprem büyüklüğü tahmin edilmeye ve bunun için en iyi algoritma seçilmeye çalışılmıştır. Kullanılan tüm algoritmaların çıktıları ile deprem tehlike haritaları üretilmiş ve karşılaştırılmıştır.

2. LİTERATÜR BİLGİLERİ

Makine öğrenmesi algoritmaları ile deprem tahmini çalışmaları, makine öğrenmesi uygulamalarının popüler olması ve yaygınlaşması ile artmaktadır. Bu alanda çeşitli çalışmalar mevcut olmasına rağmen deprem katalogları, jeodezik veriler ve jeolojik verilerin bir arada kullanıldığı çalışmalar mevcut değildir. Aşağıda farklı veriler ve farklı yöntemler kullanılarak ele alınan çalışmalar açıklanmıştır.

Moustra vd. (2011) Yunanistan ölçeğinde yapay sinir ağlarının, farklı veri setleri ile deprem tahminindeki başarısını ele almışlardır. İki farklı olay üzerine bir çalışma yürütülmüştür. Bu çalışmalardan ilki bir sonraki gün meydana gelecek deprem büyüklüğü tahmini ve diğeri ise deprem öncesinde meydana gelen ve Sismik Elektrik Sinyalleri (SES) olarak adlandırılan sinyaller ile bu sinyalleri takip eden gündeki deprem büyüklüğünü tahmin etmektir. İlk çalışmada girdi olarak sadece depremler arası zaman serileri kullanılmış ve çıktı olarak da deprem büyüklüğüne ulaşılmıştır. Çalışmada elde edilen sonuç %80.55 olarak saptanmış olmasına rağmen büyüklüğü $M > 5.2$ olan sismik aktiviteler için bu oran %58.02 olarak bulunmuştur. İkinci adımda girdi verisi olarak SES kullanılmıştır. Bu aşama ikiye ayrılmıştır. İlk aşamada veri içinde yer alan eksik SES verisi tüm depremler için rastgele oluşturulmuş ve yaklaşan deprem büyüklüğünün tahminindeki doğruluk oranı %60'ın biraz üzerinde bulunmuştur. İkinci aşamada kayıp SES verisi yapay sinir ağları ile tekrardan oluşturulmuştur. Bu aşamada deprem tahmin doğruluğu %84.01 olarak bulunmuştur. SES ve SES ile deprem arasındaki zaman gecikmesi ile yapılan çalışmada doğruluk oranı ise %83.56 olarak hesaplanmıştır. Sonuçlar incelendiğinde yapay sinir ağları ile deprem tahmininde farklı girdiler ile farklı doğrulukta sonuçlar elde edildiği söylenebilir.

Leduc vd. (2017) laboratuvar ortamında elde edilen akustik veriler ve makine öğrenmesi ile deprem kestirimi yapmışlardır. Tahmin için akustik ses sinyallerinin fiziksel özellikleri kullanılmıştır. Çalışmada elde edilen sinyaller laboratuvar ortamında oluşturulan bir faydan elde edilmiştir. Fay bloklarının hareketlerinde meydana gelen akustik sinyallerin girdi olarak kullanılması deprem tahminini mümkün kılmaktadır. Çalışmada Random Forest (RF) algoritması kullanılmıştır. Yalnızca olayların periyodikliği ile yapılan çalışmada $0.3 R^2$ skoru elde edilmiştir. Bunun yanında Random

Forest algoritması kullanılarak, akustik sinyal verileri ile yapılan çalışmada 0.89 R^2 skoru elde edilmiştir.

Lubbers vd. (2018)'de fay bölgesinde sürekli olarak kaydedilen akustik veriler kullanılarak deprem tahmini için bir çalışma yapmıştır. Çalışmada kaydedilen veri ile bir katalog oluşturulmuş ve girdi olarak verilmiştir. Bu çalışmada da veriler laboratuvar ortamında oluşturulan depremlerden elde edilmiştir. Bu çalışmada amaç RF algoritmasını eldeki veri seti ile eğiterek makaslama gerilimi, depreme kadar geçen süre ve deprem zamanını tahmin etmektir. Deprem zamanı tahmini modelinin ($R^2 = 0.551$) makaslama gerilimi ve depreme kadar geçen süre tahmini algoritmalarına göre ($R^2 > 0.8$) daha başarısız olduğu görülmüştür. Buradan şu sonuç çıkartılabilir; geleceği tahmin etmek geçmiş ve bugünü tahmin etmekten daha zordur (Lubbers vd. 2018).

3. DEPREMLER VE ÖZELLİKLERİ

Yer kabuğunda ani şekilde ve beklenmedik bir zamanda meydana gelen kırılma ve bu kırılmaya bağlı olarak ortaya çıkan sismik dalgaların yer yüzünü sarsması olayına deprem (halk arasında Yer sarsıntısı, Zelzele) denmektedir (Aytekin 2012).

Teknoloji ve bilimin bugün geldiği noktada birçok doğa olayının karakteristik özellikleri ve meydana gelme periyotları modellenebilmektedir. Geline bu noktada teknolojik anlamda büyük gelişmeler katetmemize ve bilgi toplama, işleme alanında büyük adımlar atmamıza rağmen doğa olaylarının günlük yaşantımızı etkilemesine engel olunamamaktadır. Bunun yanında bazı afetler sonrasında büyük ölçekli can ve mal kayıpları ile yüz yüze gelinebilmektedir. Büyük ölçekli can ve mal kayıplarına neden olan doğal afetlerin başında ise deprem gelmektedir (Yavaşoğlu 2003, Başçıftı 2020).

Deprem, temelinde yer kabuğu hareketleri olarak bilinirler. Depremlerin meydana geleceği tarih, saat bilinemediğinden ve çoğu kez büyük ölçekli hasarlar verdiğinden dolayı toplumların en çok korktuğu doğal afet olma özelliği kazanmıştır. Depremler üç sınıfta toplanmışlardır. Bu üç sınıf “çökme”, “volkanik” ve “tektonik” olarak adlandırılmaktadır. Bu üç sınıftan çökme ve volkanik depremler sınıfına dahil olan depremler yerel depremlerdir (Sür 1993).

Yer kabuğunun yapı olarak kalker ve jips gibi eriyebilen kayalardan oluşmuş olduğu bölgelerde çökme depremler görülebilmektedir (Sür 1993). Zamanla birlikte yer içinde bulunan mağara tavanları incelererek çökmektedir. Bu çökme ile birlikte çökme depremler oluşur ve yerleşim bölgelerinde meydana gelmesi durumunda can ve mal kaybına yol açmaktadırlar.

Volkanik depremler genellikle aktif volkanların faaliyete geçmesine yakın bir dönemde meydana gelmektedir. Basit bir analiz ile volkanik aktivitenin habercisi olarak değerlendirilen volkanik depremler meydana geldiği aktif volkanın yakın çevresinde etkili olmaktadır (Sür 1993, Lahr vd. 1994, Roman ve Cashman 2006).

Son olarak tektonik depremler, yer kabuğunun genç ve hareketli bölgelerinde görülen bir

deprem türüdür. Farklı nedenler sonucunda yer kabuğundaki dengenin bozulması, yer kabuğundaki gerilme veya kırılma gibi nedenler ile potansiyel enerji kinetik enerjiye dönüşmektedir. Açığa çıkan kinetik enerji ile tektonik depremler oluşmakta ve büyük hasarlar meydana gelebilmektedir.


3.1 Depremlerin Oluşumu

İnsanoğlu geçmişten bugüne kadar geçen süreçte doğada meydana gelen olaylara ilgi duymuş ve imkanların yeterli olduğu ölçüde nedenleri üzerine çalışmalar yapmışlardır. Kutup bölgesinde meydana gelen hareketlenmeleri açıklayan küresel geometri teoremini kullanarak, litosferin hareketli yapısını açıklayan ilk bilim insanı İsviçreli bilim insanı Leonhard Euler olmuştur (Başçiftçi 2020). Litosfer tabakası tek bir parçadan oluşmayıp, birbirleri ile sürekli olarak fiziksel temas halinde olan levhalardan meydana gelmektedir. Yerkürenin manto katmanında ısınan malzemenin yükselmesi, soğuyan malzemenin alçalması ile oluşan konveksiyonel bir akım söz konusudur. Bu konveksiyonel hareket sonucunda levhaların birbirlerinden uzaklaşma, birbirleri ile çarpışma veya birbirlerine göre yanal hareketlerde bulunma gibi durumları ortaya çıkmaktadır. Depremler de bu hareketler sonucunda oluşmakta ve genellikle levha sınırlarında meydana gelmektedir (Erdoğan 2006, Yavaşoğlu 2009, Başçiftçi 2020).


Levha hareketleri sonucunda depremlerin yanı sıra dağların oluşumu veya volkanik aktiviteler gibi olaylara da neden olmaktadır. Bu doğa olaylarını inceleyen bilim insanları, bu tip doğal aktivitelerin nedenleri ve mekanizmalarını açıklamak adına çok sayıda teori ve kuram ortaya atmışlardır. Bunlardan en ünlüsü 1912 yılında Alfred Wegener tarafından ortaya konan Levha Tektoniği kuramı olarak Kabul edilmektedir (Wegener 2012, Tiryakioğlu 2012).

Litosfer tabakasındaki levhaların hareketi ve levha tektoniği kuramını daha net anlayabilmek için yerkürenin iyi bir şekilde anlaşılması önem taşımaktadır. Yerkürenin katmanlı bir yapı olduğu bilinmekte olup dıştan içe doğru sırasıyla kabuk, manto ve çekirdek katmanlarından oluşmaktadır. Yerkürenin iç katmanları da kendi içlerinde katmanlardan oluşmaktadırlar. Manto katmanı alt ve üst mantodan, çekirdek katmanı ise

iç ve dış çekirdek katmanlarından oluşmaktadır (Şekil 3.1). Yeryüzünün en dış katmanı olan yerkabuğu katmanı, karada 25-80 km, okyanus altlarında 5-8 km'lik kalınlık değerlerine sahiptir. 70-120 km kalınlık değerine sahip litosfer tabakasının en üst katmanını yerkabuğu katmanı oluşturmaktadır. Litosferin üstünde yerkabuğu bulunurken altında ise üst mantonun daha yumuşak ve akıcı olarak tanımlanan bölümü bulunmaktadır. Bu bölüme astenosfer olarak adlandırılmaktadır.




Şekil 3.1 Yerkürenin katman yapısı (Kibici 2005).



Şekil 3.2 Dünyanın dış kısmındaki katmanlar (Press ve Siever 1999).

Çekirdek ve litosfer arasındaki hacimce en büyük bölgeyi kaplayan katman manto katmanıdır. Manto katmanının üst kesimleri yüksek basınç ve sıcaklık etkisi ile plastiki bir özellik göstermektedir. Alt kısımlar ise fiziksel olarak sıvı halde bulunmaktadır. Litosfer; mantonun üstünde bulunmaktadır ve yeryüzüne kadar uzanmaktadır (Tiryakioğlu 2012). Litosfer hareketli parçalardan oluşmaktadır. Bu hareketli litosfer parçaları levha olarak isimlendirilmekte ve bu parçaların hareketini açıklayan teoriye ise Levha Tektoniği adı verilmektedir (Tüysüz 1999, Başçiftçi 2020).

Dünya üzerinde 7 büyük levha bulunmaktadır. Bu büyük levhaların yanı sıra çok sayıda da küçük olarak adlandırılan levhalar bulunmaktadır. Pasifik, Güney Amerika, Kuzey Amerika, Antartika, Avustralya ve Afrika levhaları büyük levhalar olup, Kokos, Antiler ve Nazka gibi levhalar da küçük levhalar olarak tanımlanmaktadır. Büyük levhalar aşağıda gösterilmiştir (Şekil 3.3).




Şekil 3.3 Dünya tektonik plakaları haritası (İnt.Kyn.1).

Depremler çökme, volkanik ve tektonik olarak üç sınıfta incelense de meydana gelen depremlerin büyük çoğunluğu tektonik kaynaklı depremler olarak gözlemlenmektedir. Kıta ve levha hareketlerinin nedeni tektonik olduğu kadar faylanmaların nedeni de tektoniktir. Tektonik depremlerin meydana gelmesinin temelinde diri fay aktivitelerinin payı vardır

Kayıtlara geçmiş olan ve bundan sonra meydana gelecek yıkıcı depremlerin hemen hemen tamamı faylarla ilişkili olmuştur ve de olacaktır. Bu nedenden dolayı depremleri anlamak ve bu depremlerde yaşanacak can ve mal kaybını düşürmek için fayları ve fay yapılarını iyi tanımamız gerekmektedir. Yeryüzündeki bir kırığın sağında ve solunda bulunan kayalar göz ile görülür bir düzeyde hareket etmişler ise bu kırık fay olarak adlandırılmaktadır. Blok hareket yönü ile fay düzlemi arasındaki ilişki dikkate alınarak faylar sınıflandırılmaktadır. Aralarındaki ilişkiye göre faylar üç sınıfa ayrılırlar. Bu üç sınıf yan atımlı (oblik), eğim atımlı ve doğrultu atımlı olarak adlandırılırlar (Sümer vd. 2018). Bu fay sınıfları gerilme, sıkışma veya makaslama kuvvetlerinin etkisi ile meydana gelirler ve etki eden kuvvete göre şekil alırlar (Tüysüz 1999, Başçiftçi 2020).

Eğim Atımlı Faylar: Hareket yönü, bu tip faylarda fay düzlemi boyunca yukarı ve aşağı gerçekleşmektedir. Tavan bloğunun taban bloğuna göre aşağı yönlü bir hareket yapması ile eğim atımlı normal faylanmadan bahsedilebilir. Bunun tam tersi bir durumda; tavan bloğu taban bloğuna göre yukarı yönlü bir hareket yapmış ise burada da eğim atımlı ters faylanmadan bahsedilir. Normal faylar bölgede genişlemeye neden olurken ters faylar bölgede kısalmaya neden olmaktadır. Ters fayların gelişiminde sıkışmalı tektonik rejim etkili olurken normal fayların gelişiminde gerilmeli tektonik rejim rol almaktadır (Sür 1993).


Doğrultu (yanal) Atımlı Faylar: Fayın iki tarafındaki blokların fay düzlemine göre yatay bir şekilde birbirlerine ters yönde hareket etmeleri sonucunda oluşur. Bloklardan herhangi biri durağan kabul edildiğinde diğer blok sağa hareket etmiş ise sağ yanal atımlı fay, eğer sola hareket etmiş ise sol yanal atımlı fay olarak adlandırılırlar. Bu tip faylar makaslama kuvvetleri etkisi altında gelişirler. Yanal atımlı faylar, eğim atımlı ters faylar ve eğim atımlı normal fayların etki altında oldukları kuvvetlerin etkisi ile nasıl meydana geldikleri adım adım Şekil 3.4’de gösterilmektedir (Sür 1993, Tüysüz 1999)



Şekil 3.4 Fayların kuvvet altında gelişmeleri (Pres ve Siever 1999, Başçiftçi 2020).

Yan Atımlı (verve) Faylar: Yan atımlı faylar doğrultu yönünde ve eğim yönünde birlikte

hareket eden faylardır. Bu faylarda tavan bloğu alçalmış ise oblik normal fay olarak adlandırılırlar. Bunun tersi olarak eğer tavan bloğu yükselmiş ise bu faylara da oblik ters fay denilmektedir. Ters faylarda eğim düşük açılı ise bindirme fayı, eğim yatay veya yataya yakın ise nap adı verilmektedir. Bu fay yapılarının atımı yüzlerce kilometreyi bulabilir. Ayrıca büyük dağ sınırlarının oluşum sürecinde meydana gelen sıkışmalı yapılardır. Normal fayların ardışık olarak gelişmesi durumunda horst-graben yapısını ortaya çıkarırlar. Yükselen fay bloklarına horst, alçalan fay bloklarına graben adı verilmektedir. Horstlar engebeli, dağlık ve yükseltili alanları oluştururken grabenler ise düzlük ve alçak alanları oluşturmaktadır (Tüysüz 1999).



Şekil 3.5 Horst ve Graben Yapısı (Pres ve Siever 1999).

3.2 Deprem Büyüklüğünü Etkileyen Parametreler

Bilindiği üzere bir bölgede yaşanabilecek tehlikelerin analizini yapabilmek için ilk önce tehlike kaynakları ve tehlikenin boyutunu etkileyebilecek etmenlerin bilinmesi gerekmektedir. Bu etmenlerin yapılarının, türlerinin ve geometrilerinin bilinmesi tehlike analizinin temelini oluşturmaktadır. Fay geometrisi ile deprem büyüklüğü, yüzey yırtılması ve atım miktarı arasında bir ilişki olduğu bilinmektedir (Sümer vd. 2018).

Depremlerin tam olarak ne zaman olacağını kestirmek güç olmakla birlikte geçmiş deprem verilerini kullanarak bölgedeki deprem tehlikesinin belirlenmesi mümkün

olabilmektedir. Fay geometrisinin yanında gelecekte meydana gelebilecek depremlerin tahmin edilmesinde ve bölgenin deprem riski analizinin yapılmasında, deprem parametreleri olarak adlandırılan, deprem gerçekleşme zamanı, odak derinliği ve deprem büyüklüğü değerleri kullanılmaktadır (Doğaner ve Çalık 2014).

3.3 Türkiye'nin Depremselliği

Afetler ülkemizin değişmez gerçeklerinden biridir. 1999'da ve 2023'de yaşamış olduğumuz depremler bize bu acı gerçeği bir kez daha hatırlatmıştır. Ülke olarak nüfus yoğunluğu yüksek şehirlerde yaşamakla beraber bu şehirler kurulurken güvenlik ve insan yaşamının geri planda bırakıldığı görülmektedir. Türkiye coğrafik konumu gereği yüksek ve eğimli bir bölgede bulunmakta olup fay hatları üzerinde bulunmaktadır. Bu nedenlerden dolayı ülkemiz doğal afetlerin ve depremlerin sıkça yaşandığı bir ülkedir. 1937-2007 yılları arasında afetler nedeniyle 100.000 insanımız hayatını kaybetmiş, 600.000 konut afetler nedeniyle hasar görmüştür. Bu konutlardan 500.000 kadarı çeşitli şekillerde depremlerden etkilenmiştir. Bu yıllar arasında toplanan verilere göre ortalama olarak 1000 vatandaşımız depremlerde hayatını kaybetmekte, 2100 vatandaşımız yaralanmakta ve 7000 konut hasar görmektedir. Doğal afetlerin verdiği hasarların %66'sı deprem kaynaklıdır. İstatistiksel olarak bakıldığında rakamlar göstermektedir ki deprem afeti ülkemiz için büyük bir risk taşımaktadır (Genç 2007).

Çizelge 3.1 1912-2023 yılları arasında Türkiye'de meydana gelmiş önemli depremler.

Tarih	Yer	Ölü	Yaralı	Ağır Hasarlı Ev
1912	Mürefte	216		5540
1930	Hakkari	2514		3000
1939	Erzincan	33000		116720
1942	Niksar-Erbaa	3000	6300	32000
1944	Bolu-Gerede	3959		20865
1946	Varto	839	349	1986
1966	Varto	2394	1489	20007
1970	Gediz	1086	1260	9452
1975	Lice	2385	3339	8149
1976	Van-Çaldıran	3840	497	9552

Çizelge 3.1 (Devam) 1912-2023 yılları arasında Türkiye’de meydana gelmiş önemli depremler.

Tarih	Yer	Ölü	Yaralı	Ağır Hasarlı Ev
1992	Erzincan	653	3850	6702
1995	Dinar	94	240	4909
1998	Ceyhan	150	1000	12000
1999	Kocaeli	17000	32000	50000
1999	Düzce	763		133496
2003	Bingöl	177		
2011	Van	604		
2020	Ege Denizi	117		
2023	Kahramanmaraş	50783		


Ülkemiz, dünya üzerindeki deprem açısından en aktif kuşaklardan olan, Akdeniz, Alp, Himalaya deprem kuşağı içinde yer almakta olmasına rağmen ülkede tesis edilen barajlar ve sanayi tesisleri gibi önemli yapıların büyük bölümü deprem açısından aktif ve deprem tehlikesi olan bölgelerde inşaa edilmiştir. Bunun yanında nüfusun büyük bölümü de deprem tehlikesi taşıyan bölgelerde yaşamaktadır.

Çizelge 3.2 Sanayi ve baraj gibi önemli tesisler ve nüfusun deprem bölgelerine göre dağılımları.

Deprem Bölgesi	Yüzey Alanı (%)	Nüfus (%)	Endüstri (%)	Barajlar (%)
1.Bölge	42	45	51	46
2.Bölge	24	26	25	23
3.Bölge	18	14	11	14
4.Bölge	12	13	11	11
5.Bölge	4	2	2	6
Toplam	100	100	100	100

Ülkemizin topraklarının %66’sı 1. ve 2. derece deprem bölgesinde, başka bir deyişle aktif fay bölgesinde yer almakta olup ülke nüfusunun %71’i de bu bölgelerde yaşamaktadır


(Ergünay 2007).



Şekil 3.6 Avrasya, Afrika ve Arap plakaları hareketleri (Okay 2000, Ergünay 2007).

4. DEPREM TEHLİKE HARİTALARI

1939 yılında meydana gelen Erzincan depremi ile başlayan ve sonrasında çok sayıda can ve mal kaybına neden olan depremlerin meydana gelmesi ile devam eden sürecin sonunda ülkemizde ilk defa 1945 yılında “Yersarsıntısı Bölgeleri Haritası” ismi ile deprem tehlike haritası hazırlanmıştır (Şekil 4.1). Tektonik alanında gerçekleşen bilimsel gelişmeler ışığında tektonik, sismotektonik ve deprem katalogları veri tabanlarının genişletilmesi sonucunda farklı yıllarda, 1945 yılında yayınlanan deprem tehlike haritasının güncellenmesi gereği doğmuştur. 1945 yılından sonra 1947, 1963, 1972, 1996 ve 2019 yıllarında farklı teknik ve yöntemler ile deprem tehlike haritaları üretilmiştir (Özmen 2012).



Şekil 4.1 1945 yılında ilk defa hazırlanmış deprem bölgeleri haritası (Özmen 2012).

Deprem tehlike haritalarının üretilmesinde 3 farklı yöntem karşımıza çıkmaktadır. Bu yöntemler; hasar verisi yöntemine göre, deterministik yöntemlere göre ve olasılık yöntemine göre olmak üzere sıralanabilir. 1945 ve 1947 yıllarında üretilen deprem tehlike

haritaları hasar verisi yöntemine göre hazırlanmıştır. Bu yöntemde geçmiş depremler ve meydana getirdikleri hasarlar dikkate alınır. 1945 yılında hazırlanan haritada ülkemiz;

- Büyük hasara uğramış bölgeler
- Tehlikeli yersarsıntısı bölgeleri
- Tehlikesiz bölgeler adı altında üç bölgeye ayrılmıştır.

1945 haritasının güncellenmesi gereği ile ilgili hazırlanan rapor ile 1947 yılında, ülkemizin ikinci resmi deprem tehlike haritası yayınlanmıştır (Pampal ve Özmen 2007).

Bu haritada Türkiye;

- Birinci derece deprem bölgesi
- İkinci derece deprem bölgesi
- Tehlikesiz bölgeler olarak üç bölgede incelenmiştir.



Şekil 4.2 1963 yılında yayınlanan deprem tehlike haritası (Özmen 2012).

1963 ve 1972 yıllarında yayınlanmış haritaların üretiminde deterministik yöntemler kullanılmıştır. Bu yöntem kullanılarak hazırlanan haritalarda, geçmişte yaşanan depremler ve bu depremlerin verdiği hasarlar, tektonik haritalar, eşşiddet haritaları ve son olarak deprem üzerine yapılan çalışmalardan faydalanılmıştır. Farklı şekillerde elde edilmiş verilerin birleştirilmesi ile hissedilen ve beklenen şiddet değerleri kullanılarak bu haritalar üretilmiştir (Özmen 2012). 1963 deprem tehlike haritasına göre ülkemiz (Şekil

4.2);


- Birinci derece deprem bölgesi,
- İkinci derece deprem bölgesi,
- Üçüncü derece deprem bölgesi,
- Tehlikesiz bölgeler olarak dört bölgede incelenmiştir.

1963 tarihli haritada bazı uyumsuzlukların tespit edilmesi ve tehlikesiz bölge olarak tanımlanan bazı bölgelerde yıkıcı depremlerin meydana gelmesi nedeniyle yeni deprem tehlikesi haritası yapımına başlanmış ve 1972 yılında yeni harita resmi olarak kullanıma sunulmuştur (Ergünay 1976). 1972 deprem tehlike haritasında ülkemiz;

- Birinci derece deprem bölgeleri,
- İkinci derece deprem bölgeleri,
- Üçüncü derece deprem bölgeleri,
- Dördüncü derece deprem bölgeleri,
- Tehlikesiz bölgeler olmak üzere 5 bölgeye ayrılmıştır.

1996 ve sonrasında hazırlanan deprem tehlike haritaları, dünyada gerçekleşen gelişmeler ışığında olasılık yöntemi kullanılarak hazırlanmıştır. Bu nedenle 1996 yılında yayınlanan deprem tehlike haritası yöntemsel olarak ilk 4 haritadan farklıdır ve olasılık yöntemi kullanılarak üretilmiş ilk harita olmasından dolayı oldukça önemlidir (Seyrek 2020). 50 yıl içinde %90 olasılıkla aşılmayacak yer ivmelerini göstermektedir. 1996 deprem tehlike haritası;

- Birinci derece deprem bölgesi $PGA \geq 0.4g$,
- İkinci derece deprem bölgesi $0.4g \geq PGA \geq 0.3g$,
- Üçüncü derece deprem bölgesi $0.3g \geq PGA \geq 0.2g$,
- Dördüncü derece deprem bölgesi $0.2g \geq PGA \geq 0.1g$,
- Beşinci derece deprem bölgesi $0.1g \geq PGA$ olarak beş bölgede incelenmiştir.




2019'da yürürlüğe giren son deprem tehlike haritasında 1996 yılında yayınlanan tehlike haritasından farklı olarak hesaplanan en büyük yer ivmesi değerlerine yer verilmiştir. Güncel haritada birinci derece, ikinci derece deprem bölgesi gibi ifadeler kullanılmamıştır. Bu şekilde deprem bölgesi kavramı son harita ile ortadan kalkmıştır.



Aktuğ (2017)'de deprem tehlike haritası üretmek için jeodezik veriler kullanılmıştır. Çalışmada deprem kataloglarının eksikliği ve deprem aktivitelerinin uzun yıllar alması

vurgulanmıştır. Aletsel dönemde henüz deprem üretmemiş olan ama aletsel dönem öncesi dönemde yıkıcı ölçüde deprem ürettiği bilinen bölgelerde deprem tehlikesi analizi yapılması ve bu bölgelerin deprem tehlikesine göre sınıflandırılmasında yanıltıcı sonuçlar ile karşılaşılabilir. Bu çalışmada jeodezik gerinim hızları ile deprem tekrarlama periyotları hesaplanmış ve elde edilen veriler ile deprem tehlike haritası üretilmiştir.




Şekil 4.5 Jeodezik verilere göre hazırlanmış deprem tehlike haritası (Aktuğ 2017).

5. MAKİNE ÖĞRENMESİ

Dünyanın dijitalleşmesi ve teknolojiadaki gelişme sayesinde nesnelerin internet, büyük veri, yapay zeka (AI) ve makine öğrenmesi (ML) gibi kavramlar hayatımıza girmiş bulunmaktadır. Bilgisayar teknolojisi hayatımıza girmeden önce defter ve kağıtlar ile tutulan verinin bugün aynı yöntemler ile tutulması kolay olmamakla beraber pek mümkün görünmemektedir. Eldeki bilgi her geçen gün katlanarak büyümektedir. Bu büyüme karşısında veri içerisinde gerekli olan veriyi bulmak ve işlemek karmaşık bir hale gelmiştir. Veri madenciliği ve makine öğrenmesi gibi kavramlar bu aşamada karşımıza çıkmaktadır. Veri madenciliği ve makine öğrenmesi ile büyük boyuttaki veri kümeleri içerisinde anlamlı ilişkiler çıkartılabilir ve bu ilişkiler analiz edilebilir (Savaş vd. 2012).

Veri yığınları içinden verinin birbiri ile olan ilişkileri çıkartılabilir. Bu ilişkiler yardımı ile gelecek ile ilgili tahminler yapılabilir. Geçmiş veriden geleceği tahmin etmek insanlık için önemli bir yetenektir. İnsanoğlu da tecrübeleri ve aldığı eğitim doğrultusunda çevresel veriyi işleyerek ileriye dönük tahminlerde bulunabilir. İnsanın geleceği tahmin ederken duygularını tam anlamıyla kenara koyamaması ve rasyonel bir şekilde hareket edememesi en büyük handikap olarak gözükmektedir. Bunun yanı sıra kapasitesini aşan büyük veri içerisinde bazı kritik parçalar hatalı kararlara neden olabilmektedir. İnsanların aksine makineler milyonlarca veriyi hızlıca tarayıp, bütün durum kombinasyonlarını değerlendirip kısa bir sürede rasyonel ve doğru kararlar verebilirler. İnsanın düşünme ve karar verme yeteneklerini modelleyebilmek makine öğrenmesinin başarısını artırmak için önem taşımaktadır (Ülker ve İnik 2017). Bundan yola çıkarak makine öğrenmesi kavramını, insan zekası ve düşünce yapısını taklit etmek amacıyla türetilen algoritmaların bir parçası veya bir problemin eldeki veriye uygun şekilde matematiksel olarak modellenmesi olarak tanımlanabilir (El Naqa ve Murphy 2015, Atalay ve Çelik 2017). İçinde bulundurdıkları çeşitlilik, hacim ve bu hacme bağlı hız sorunları nedeniyle büyük veri yapıları beraberinde bazı sorunlar getirmektedir. Makine öğrenmesi bu sorunların üstesinden gelmek için büyük veriyi uygun şekilde sınıflandırmaktadır (Suthaharan 2014, Tosunoğlu vd. 2021).



Şekil 5.1 Makine öğrenmesi hiyerarşi yapısı.

Makine öğrenmesinde, kullanımı verinin türüne göre değişen farklı algoritmalar mevcut olmakla birlikte bunların hiyerarşik durumları gösterilmiştir (Şekil 5.1). Makine öğrenmesi algoritmaları sınıflandırma, kümeleme ve tahmin özelliklerine sahiptirler. Denetimsiz, denetimli ve pekiştirmeli öğrenme, algoritmaların makinelerle öğretilmesinde kullanılan stratejilerdir. Denetimli öğrenme stratejisinde makineye girdi ve çıktı değerleri birlikte verilirken, denetimsiz öğrenmede ise makineye yalnızca girdi değeri verilir. Çok sayıda algoritma içinden hangisinin kullanılacağına, problemin çözümüyle uğraşan programcı tarafından karar verilmektedir. Çok sayıda algoritma içinden veri işlemedeki en başarılı algoritmayı seçmek de önem taşımaktadır. Algoritmaları işlevsel yönden sınıflandırmak, algoritma seçiminde fayda sağlayabilir (Ülker ve Civalek 2002, Tosunoğlu vd 2021).

Çalışmalarda en çok kullanılan ve en bilinen algoritmalar Bayes sınıflandırıcı, Karar ağaçları, K-en yakın komşu, Destek vektör makineleri, Lojistik regresyon ve Yapay sinir ağlarıdır. Günümüzde büyük veriyle hayatımızın birçok alanında (sağlık, bankacılık, lojistik vb.) karşılaşmaktayız. Elde edilen veri her sektör için o sektörün gelişiminde kullanılabilmektedir. Sağlık sektöründe insan kaynaklı hataları en aza indirmek,

sağlıkçılar için karar vermeyi kolaylaştırmak gibi amaçlarla makine öğrenmesi algoritmaları kullanılırken, büyük veri kümelerinin olduğu ekonomi alanında bu veriyi analiz etmek için makine öğrenmesi algoritmaları kullanılmaktadır (Karakoyun ve Hacıbeyoğlu 2014, Akay 2018). Ekonomiden sosyal medyaya, ticaretten iklim bilimine kadar büyük verinin elde edilebildiği her alanda makine öğrenmesi kullanılırken afet yönetimi ve deprem üzerine de makine öğrenmesinin kullanılması kaçınılmazdır.

5.1 Regresyon Algoritmaları

Regresyon modelleri, ilgili bağımlı değişken ve diğer bağımsız değişkenler arasındaki ilişkiyi belirler. Belirlenen bu ilişkinin gününe göre tahminler ortaya koyar. Regresyon, kestirim yapan istatistiksel bir ölçümdür denilebilir. Regresyon modelleri kısaca, x değişkenlerinden bir denklem oluşturarak y değişkenini matematiksel olarak tanımlama prensibine dayalı olarak çalışmaktadır. Oluşturulan bu denklem ile x bağımsız değişkenlerinin yeni değerleri ile y bağımlı değişkenini tahmin edilir.

5.1.1 Karar Ağaçları (Decision Tree)


Karar ağaçları (DT) algoritması, bağımlı değişkenlerin sayısal değerlerinin kestirimini yapan ağaç tabanlı bir yapıdır. İşlem sırasında kullanılan veri topluluğu her defasında yapraklar, dallar ve karar düğümlerinden oluşan alt kümelerle bölünür. Öznitelikler düğümler tarafından temsil edilmektedir. Yapraklar ve düğümler ile düğümler arasındaki temsil etmek için ise dallar kullanılmaktadır. Karar ağaçlarının oluşturulmasının temelinde verilere sorulan sorular ile bir karar kurallarının bulunmasıdır. Karar ağaçlarındaki en önemli aşama ağaç yapısındaki dallanmanın hangi kurala veya özneliğe göre şekilleneceğinin belirlenmesidir (Kavzoğlu vd. 2012). Karar ağaçları regresyon algoritmasının işleyişi aşağıda verilmiştir.

İlk önce bir karar ağacı oluşturmak amacıyla geleneksel bir karar ağacı algoritması kullanılır. Bu karar ağacı, her daldan aşağı inen örneklerin sınıf değerlerindeki altküme içi varyasyonunu en aza indiren bir bölme kriteri kullanır. Bölme yolu ile tahmin için kullanılmak üzere bir dizi kural üretilmektedir. Yaygın olarak kullanılan ağaç yöntemleri

ki-kare otomatik etkileşim tespiti (CHAID), sınıflandırma ve regresyon ağaçları (CART), C4.5 ve C5.0'dır (Tso ve Yau 2007). Beklenen hata azaltmayı maksimuma çıkartan öznitelik, ağaç içerisinde kök düğüm olarak belirlenir. Standart sapma azalması (SSA) aşağıda verilen formül ile hesaplanır.

$$SSA = ss(T) - \sum_i \frac{|T_i|}{|T|} \times ss(T_i) \quad (5.1)$$

Daha sonra, karar ağacı yapraktan geriye doğru budanır. Son olarak, budanmış ağacın yapraklarında bitişik doğrusal modeller arasında kaçınılmaz olarak oluşacak olan keskin süreksizlikleri telafi etmek için bir düzeltme prosedürü kullanılır (Wang ve Yao 2013, Rathore ve Kumar 2016).



Şekil 5.2 Karar ağacı (DT) algoritması (Özgür ve Erdoğan 2020).

Karar ağaçları algoritmasının en büyük avantajlarından birisi, ürettiği modelin yorumlanabilir kurallara sahip olması veya mantıksal ifadeleri temsil edebilmesidir. Algoritma ile karmaşık olmayan hesaplamalar ile tahmin ve sınıflandırma yapılabilir. Karar ağaçları sürekli veya kategorik değişkenler için kullanılabilir (Perner vd. 2001, Tso ve Yau 2007).

5.1.2 K En Yakın Komşu (KNN)

K en yakın komşu algoritması regresyon ve sınıflandırma problemlerinde kullanılan en temel denetimli öğrenme algoritmalarından biridir. Algoritma örnek tabanlı öğrenme esasına göre tahminler yapmaktadır. Bu tip örnek tabanlı olan öğrenme algoritmalarında, eğitim setinde yer alan veriler kullanılarak öğrenme işlemi gerçekleştirilir (Taşcı ve Onan 2016). Algoritma tahmini istenen örneğin en yakın komşuları ile olan ilişkisine bağlı olarak tahminde bulunmaktadır. En yakın komşular en küçük öklid mesafesi baz alınarak bulunur (Altunkaynak vd. 2020). Öklid mesafesinin hesaplanması ise denklem (5.2)'de gösterilmiştir.


$$\text{Öklid fonksiyonu} = \sqrt{\sum_{i=1}^k (x_i - y_i)^2} \quad (5.2)$$

En yakın komşuları belirlemek için kullanılabilecek diğer fonksiyonlar Manhattan fonksiyonu ve Minkowski fonksiyonu sırası ile denklem (5.3) ve denklem (5.4)'de gösterilmişlerdir.

$$\text{Manhattan fonksiyonu} = \sum_{i=1}^k |x_i - y_i| \quad (5.3)$$

$$\text{Minkowski fonksiyonu} = \left(\sum_{i=1}^k (|x_i - y_i|)^q \right)^{\frac{1}{q}} \quad (5.4)$$

K en yakın komşu algoritması tembel bir algoritma olarak tanımlanır. Bunun nedeni, algoritmanın eğitim verisini öğrenmek yerine ezberlemesidir. Algoritma tahmin yaparken ezberlediği tüm veri içerisinde K sayıda en yakın komşuları arar.




Şekil 5.3 K en yakın komşu algoritması.

KNN algoritmasının belli avantajlarının yanında dezavantajları da mevcuttur. Algoritmanın başarısı K parametresinin seçimine bağlı olarak değişmektedir. K parametresinin küçük belirlenmesi durumunda, gürültü içeren veriye karşı başarılı sonuçlar elde edilebilir. Bunun tersi bir durumda, K parametresinin büyük seçilmesi, alakasız veriler sonuçları olumsuz yönde etkileyecektir (Kemalbay ve Alkış 2020).

5.1.3 Rastgele Orman Algoritması (Random Forest)

Rastgele orman tekniği çok sayıda karar ağacının performansını birleştirerek tahmin veya sınıflandırma yapmaktadır (Rodriguez-Galiano vd. 2015). Üretilen ağaç sayısının fazla olması nedeniyle model performansının da yüksek olması beklenmektedir. Bu algoritma kategorik, sürekli veya ikisini birden barındıran veri setlerinde kullanılabildiği gibi aynı zamanda küçül veya büyük yoğunluktaki veri setlerinde de rahatlıkla kullanılmaktadır (Akman vd. 2011, Korkmaz vd. 2018). Fakat rastgele orman algoritmasının veri seti büyüklüğü ve türüne bağlı olarak her durumda yüksek performansı garanti etmediği bilinmektedir. Rastgele orman algoritması diğer algoritmalarla göre doğruluk açısından


daha tatmin edici olmakla beraber algoritmadaki ağaç yapısının görülememesi dezavantaj olarak görülmektedir (Akın ve Terzi 2020).



Şekil 5.4 Rastgele orman (RF) algoritması işlem adımları (Peker vd. 2017).

5.1.4 Extreme Gradient Boosting Trees (XGBoost)

XGBoost algoritması 2016 yılında tahmin algoritmalarına alternatif olarak geliştirilmiştir. Algoritma gradyan arttırma ve karar ağacı temelli çalışmaktadır. Yarışmalarda gösterdiği başarı ile dikkatleri üzerine çekmiş olan XGBoost algoritması sınıflandırma ve regresyon problemlerinde başarı ile kullanılmaktadır. Öğrenme aşamasında ağaçları oluştururken CART algoritmasını kullanan XGBoost algoritması, kaynak kullanımına dikkat etmesi, hesaplama hızı ve model performansına odaklanması gibi konularda kullanıcıya avantajlar sunmaktadır (Verma vd. 2018, Morde 2019, Brownlee 2016, Kurt vd. 2020).




Şekil 5.5 Gradient boosting trees (XGBoost) algoritması (Shehadeh vd. 2021).

Tüm veri türlerinde hızlı ve doğru şekilde işleme yeteneğini, sebebe dayalı karar ağacı (Cause Based Decision Tree – CDBT) ve gradient boosting machine (GBM) bir algoritmada birleştirip ağaç güçlendirme özelliğini geliştirerek kazanmıştır. XGBoost çok sayıda öznitelik barındıran veri kümelerini işlemek için kullanıma uygundur (Chen ve Guestrin 2016).

6. MATERİYAL VE METOD

6.1 Veri


Çalışma kapsamında veri seti oluşturabilmek için öncelikle Kandilli Rasathanesi ve Deprem Araştırma Enstitüsü'nün (KRDAE) deprem kataloğunda yer alan depremler filtrelenmiştir. KRDAE kataloğunda 1900 – 2021 yılları arasında ülkemizde meydana gelen depremlere ait, büyüklükleri üç ve sekiz arasında değişen, ~350000 kayıt yer almaktadır. Katalog depremleri harita üzerinde gösterilmiştir (Şekil 6.1). Bu depremlerden yaklaşık 10500'ü Batı Anadolu'dadır (37.90 – 40.10 enlemleri ve 26.16 – 30.46 boylamları arası). Bu bölge hem yoğun deprem aktivitesi hem de karmaşık tektonik yapısı nedeniyle çalışma bölgesi olarak seçilmiş ve bu depremler veri setine dahil edilmiştir. Veri setinde bulunan depremler ülkemizde meydana gelmiş ve komşu ülkelerde meydana gelerek ülkemizde hissedilen depremlerden oluşmaktadır. Deprem kataloğunda bulunan her bir veri için deprem oluş tarihi, depremin enlem ve boylam değerleri, derinliği ve deprem büyüklüğü öznitelik bilgileri bulunmaktadır.




Şekil 6.1 Türkiye’de aletsel dönemde meydana gelen $M \geq 3$ depremler (KRDAE) (kırmızı çizgi; aktif fay, siyah daire: M:3., mavi daire: M:4., turkuaz daire: M:5., mor daire: M:6., kırmızı daire: M:7)

Depremin en önemli faktörü olan faylara ait veriler ise MTA'nın (Maden Tetkik ve Arama) diri fay haritaları ve ek olarak (Emre vd. 2016)'den elde edilmiştir. Fay uzunluğunun deprem büyüklüğünü önemli ölçüde etkilemesi nedeniyle her bir faya ait

uzunluklar, o fay kırıkları arasındaki mesafeler toplanarak km cinsinden elde edilmiştir. Ayrıca her fay için bir id atanmıştır. Bunlara ek olarak fayların tipleri de (RL: Sağ yanal, N: Normal Fay, LL: Sol yanal, R: Ters vb.) (Emre vd. 2016)’den alınmıştır.




Şekil 6.2 Ege ve Marmara bölgeleri aktif fay veri tabanı (Emre vd. 2016).



Şekil 6.4 Şekil 6.1’de yer alan fay haritasının devamı. Doğu Anadolu bölgesi diri fay haritası (Emre vd. 2016).


Makine öğrenmesi uygulamalarında modelin başarısını arttırmak için sistemi etkileyen girdi verilerinin iyi tanımlanması gerekmektedir. Bu amaçla günümüzde GPS/GNSS verilerinden elde edilen jeodezik gerinimler deprem tehlike analizi çalışmalarında etkin olarak Aktuğ (2017)’de de görüldüğü gibi kullanılmaktadır. Gerinim bir cisim üzerinde o ana kadar meydana gelen güncel deformasyon hakkında bilgi vermektedir. Tektonik olarak değerlendirildiğinde bu durum levhalar veya daha küçük bloklar üzerinde meydana gelen stres birikimine karşılık gelir. Gerinimler fayın depremsellliği ve kinematığı ile ilgili bilgi veren en önemli parametrelerdir. Bir bölgede gerinim hızlarının büyüklüğü oradaki sismik tehlikeyi ifade etmektedir. (Solak 2015, Aktuğ 2017, Araszkiewicz 2016).



Şekil 6.5 Veri setinin özellikleri.

Makine Öğrenmesi için gerçekleştirilecek uygulamaya çalışma bölgesindeki faylara ait bilgiler ile bölgeye ait gerinimlerin de dahil edilmesinin modelin başarısını arttıracığı değerlendirilmiştir. Bu amaçla hem modelin başarısını arttırmak hem de gerinimlerin etkisini görmek için ikinci bir veri seti oluşturulmuştur. Bu nedenle (Solak 2020) tarafından yapılmış olan çalışmada İzmir-Balıkesir bölgesi için verilmiş hız alanları kullanılarak, Geodsuit programı ile bölgenin 0.1° grid aralığında jeodezik gerinimleri Shen vd. (2015)'de açıklanan modele göre hesaplanmıştır. Elde edilen gerinimler Şekil 2'de gösterilmiştir. Yoğun ağ tasarımı (111 nokta), yüksek hız doğruluğu (max. 1.5 mm/yıl) ve buna bağlı olarak Türkiye geneline kıyasla doğruluğu yüksek gerinim değerleri elde edileceğinden dolayı bu bölge ikinci veri seti için çalışma alanı olarak

seçilmiştir.



Şekil 6.6 Çalışma bölgesi gerinim alanı (kırmızı oklar: sıkışma, mavi oklar: açılma, kırmızı çizgiler: diri fay, mavi kıvrımlı çizgiler: ana nehirler, siyah üçgenler: GNSS noktaları).

Çizelge 6.1 Değişkenler ve veri setinin özellikleri.

Değişken İsmi	Değişken Tipi	Değer	Detay
Oluş Tarihi	Girdi	Etiket	
Enlem	Girdi	Ondalık	Depremin merkez üssü
Boylam	Girdi	Ondalık	
Der (km)	Girdi	Ondalık	Depremin derinliği

Çizelge 6.1 (Devamı) Değişkenler ve veri setinin özellikleri.


Değişken İsmi	Değişken Tipi	Değer	Detay
Fay Tipi	Girdi	Etiket	Depreme neden olan fayın türü
Faya Uzaklık (km)	Girdi	Ondalık	Depreme neden olan faya uzaklık
Fay Uzunluğu (km)	Girdi	Ondalık	Depreme neden olan fayın uzunluğu
Gerinim (ns/yıl)	Girdi	Ondalık	Depremi merkez üssündeki gerinim
xM	Çıktı	Ondalık	Depremi büyüklüğü

6.2 Veri Önleme

Veri setleri genellikle sonuçları etkileyebilecek hatalı veriler içermektedir ve bu hatalı veriler gürültü olarak tanımlanmaktadırlar. Veri içerisinde gürültü ne kadar çoksa sonuçların güvenilirliği de o kadar tartışmalı olacaktır (Oğuzlar 2003). Bu çalışmada 1900 – 1970 yılları arasında meydana gelmiş küçük ölçekli depremlerin teknik yetersizliklerden dolayı katalogta yer almadığı görülmüştür. Veri içerisinde yer alan bu boşluğun sonuçlara olumsuz etkilerini önlemek için 70 yıllık bu bölüm veri setinden çıkartılmış ve çalışmada 1970 yılı sonrası depremler kullanılmıştır. Meydana gelmiş depremler Türkiye sınırları içerisinde, denizde ve ülkemizin komşularında meydana gelmiş depremleri içermesine rağmen kullanılan fay verileri ülke sınırı içindeki karasal fayları içermektedir. Bu nedenle deprem ve depreme neden olan fay eşleştirmelerinde deniz depremleri ve komşu ülkelerde meydana gelen depremlerin fay-deprem eşleştirmelerinden kaynaklanacak hataları elemine etmek için deniz ve ülke sınırı dışında meydana gelmiş depremler de veri seti içinden çıkartılmıştır. Depremlerden sonra meydana gelen artçı depremlerin yarattığı gürültüyü önlemek için artçı depremler veri setinden ayıklanmıştır. Artçı depremlerin ayıklanmasında; M:4 ve üzeri olan depremler için depremin oluş tarihinden itibaren 1 hafta sonrasında ve 5 km yakınında meydana gelmiş depremler, M:5 ve üzeri olan depremler için depremin oluş tarihinden itibaren 2 ay sonrasında ve 15 km yakınında meydana gelmiş depremler, M:6 ve üzeri olan depremler için depremin oluş tarihinden itibaren 3 ay sonrasında ve 20 km yakınında

meydana gelmiş depremler ve M:7 ve üzeri olan depremler için depremin oluş tarihinden itibaren 6 ay sonrasında ve 20 km yakınında meydana gelmiş depremler artçı depremler olarak kabul edilmiştir.

Şekil 6.10'da çalışma bölgesinde 1970 – 2022 yılları arasında meydana gelmiş depremler gösterilmiştir. Depremler AFAD deprem kataloglarından elde edilmiştir. Bölgede xM:6 ve xM:7 büyüklüklerini geçen bir deprem olmadığı Şekil 6.10'da da görülmektedir. Katalogda yer alan ve nedeni patlama, volkanik veya bilinmeyen sarsıntılar filtrelenmiştir. Veri ön işleme adımları bu bölgedeki depremler üzerinde tamamlanmış ve çalışma sonuçları bölgedeki depremler kullanılarak tamamlanmıştır.



Şekil 6.7 1970 – 2022 yılları arasında çalışma bölgesinde meydana gelmiş depremler (İnt.Kyn.3).

37.90 – 40.10 enlemleri ve 26.16 – 30.46 boylamları arasında elde edilmiş olan gerinimler bu enlem ve boylam aralıklarında meydana gelmiş ~10500 depreme eklenmiştir. Veri setinin bir bölümü (Çizelge 6.2) ve veri setine ilişkin istatistiki bilgileri aşağıda gösterilmiştir (Çizelge 6.3). Gerinimler eklenirken ters mesafe ağırlıklı enterpolasyon yöntemi kullanılmış ve her depremin içinde bulunduğu gridin köşe noktaları kullanılarak deprem merkez üssü koordinatlarındaki gerinimler hesaplanmıştır. Ters mesafe ağırlıklı enterpolasyon yöntemi kullanılarak depremin merkez üssündeki gerinim değerinin en doğru şekilde hesaplanması amaçlanmıştır.

Çizelge 6.2 Deprem verileri ve öznitelikleri. (NN: Normal, RL: Sağ atımlı. Depremlerin oluş tarihleri jülyen gününe çevrilerek etiketlenmiştir.)

Olus Tarihi (Julian Günü)	Tarih (gg.aa.yy)	Enlem °	Boylam °	Der(km)	xM	Fay Tipi	Faya Uzakhk(km)	Fay Uzunluk(km)	Gerini m (ns/yıl)
2442450.5	07.02.1975	38.75	28.35	5	4.1	RL	441	56	68.54
2442455.5	12.02.1975	39.14	29	15	4.2	RL	368.8	56	64.29
2442562.5	19.02.1975	39.12	27.68	10	4	NN	514.9	56	107.75
2442562.5	19.02.1975	38.75	27.6	9	4.2	RL	524.1	56	82.49
.									.
.									.
.									.
2459566.5	18.12.2021	39.0075	27.8813	8.9	3.3	RL	492.5	56	74.83
2459570.5	22.12.2021	39.8318	29.1303	4.8	3.2	RL	10.52	29	247.17
2459578.5	30.12.2021	39.2802	28.2493	7.3	3.3	RL	452.6	56	64.49

Ters mesafe ağırlıklı enterpolasyon yöntemde dayanak noktaları ile gerinim değeri belirlenecek noktanın aralarındaki mesafenin tersi ağırlıklandırılarak ilgili noktanın gerinim değeri denklem (6.1)'de verilen eşitliğe göre hesaplanmıştır.

$$g_e = \sum_{i=1}^n S_i * G_i / \sum_{i=1}^n S_i \quad (6.1)$$

Eşitlikte hesaplanan g değeri depremin meydana geldiği noktadaki gerinim değerini, G değeri ise dayanak noktalarındaki gerinim değerini ifade etmektedir. Denklemde verilen S değeri ağırlık değerleri, n değeri ise dayanak noktalarının sayısı için kullanılmaktadır. Ağırlık değerlerinin hesaplanması için kullanılan formül denklem (6.2)'de gösterilmiştir.

$$S_i = 1/d_i, i = 1,2,3,4 \dots \quad (6.2)$$

Ağırlıkların hesaplanmasında kullanılan d değeri dayanak noktası ve gerinim değeri hesaplanan nokta arasındaki mesafeyi belirtmektedir. Denklem (6.2)'de yer alan d değeri yani noktalar arasındaki mesafe hesaplanırken python/geopy kütüphanesinden yararlanılmıştır.

Çizelge 6.3 Veri setinin istatistiki bilgileri.

	count	mean	std	min	25%	50%	75%	max
Oluş tarihi (Julyen günü)	10364	2451168.47	4446.79	2442427.5	2448197.75	2451344.5	2454884.5	2459578.5
Enlem (°)	10364	38.94	0.56	37.9	38.47	39.07	39.32	40.1
Boylam (°)	10364	28.21	1.04	26.16	27.5	27.99	29.06	30.45
Der(km)	10364	7.17	5.32	0.0	4.2	6.6	10.0	30.0
xM	10364	3.26	0.32	3.0	3.0	3.2	3.4	6.0
Faya Uzaklık (km)	10364	345.57	214.01	0.33	211.4	377.7	512.5	675.4
Fay Uzunluk (km)	10364	53.07	12.51	9.0	56.0	56.0	56.0	90.0
Gerinim (ns/yıl)	10364	76.4	46.44	12.2	49.48	71.48	91.15	389.33

6.3 Algoritma Seçimi

Deprem gerçekleşme olayının lineer olarak tanımlanması mümkün olmamasından dolayı lineer çözüm sunan ML algoritmaları tercih edilmemiştir. Bunun yerine daha komplike modelleme çalışmalarında yüksek doğrulukta sonuçlar sunan K-Nearest Neighbourhood (KNN), Decision Tree (DT), Random Forest (RF) ve Gradient Boosting Trees (XGBoost) regresyon algoritmaları tercih edilmiştir.

6.4 Uygulama

Oluşturulan veri setleri ile ML algoritmalarını test etmek için SciKit-Learn kütüphanesi kullanılmıştır. Bu kütüphane Python programlama dili ile yazılmış olup çok sayıda regresyon ve sınıflandırma algoritmalarını içeren bir makine öğrenmesi kütüphanesidir. Python kütüphaneleri olan NumPy ve Matplotlib kütüphaneleri üzerine inşa edilmiştir (Buitinck vd. 2013). Model başarısını artırmak için GridSearchCV ile belirlenen algoritma hiper-parametrelerinin tüm kombinasyonları denenmiş ve en ideal değerler kullanılmıştır. K-en yakın komşu algoritması için en ideal k komşu sayısı değeri belirlenirken, karar ağacı, rastgele orman ve ekstrem gradyan arttırımı algoritmaları için ise max_depth, min_samples_leaf gibi parametrelerin en ideali kullanılmıştır.

Her iki veri seti de %70 eğitim verisi ve %30 test verisi olmak üzere ikiye bölünmüştür.

Öncelikle deprem verileri ve fay bilgilerinden oluşan birinci veri seti, sonrasında ise deprem verileri, fay bilgileri ve gerinimlerden oluşan ikinci veri seti eğitim verisi ile eğitilmiş, sonrasında ise test verileri ile test edilmiştir. Elde edilen sonuçlar yorumlama ve karşılaştırma kolaylığı açısından Çizelge 6.4'te sunulmuştur.

Çizelge 6.4 Algoritmalar ve hata değerleri.

Algoritmalar	1. veri seti (Deprem verileri ve fay bilgileri)		2. veri seti (Gerinimler ve fay bilgileri eklenmiş)	
	MSE	RMSE	MSE	RMSE
K en yakın komşu	0.11	0.33	0.11	0.33
Karar ağaçları	0.19	0.43	0.16	0.40
Rastgele orman	0.14	0.37	0.09	0.30
XGBoost	0.14	0.37	0.09	0.30

Çizelge 6.4'te incelendiğinde deprem verileri ve fay bilgilerini içeren birinci veri seti için en iyi sonucu sırasıyla RMSE:0.33 ve MSE:0.11 değerlerine sahip olan K en yakın komşu algoritması vermiştir. Rastgele orman, XGBoost ve karar ağaçları algoritmaları için bu değerler ise sırasıyla MSE: 0.14-0.14-0.19 ve RMSE: 0.37-0.37-0.43'dür.

Çizelge 6.4 incelendiğinde günümüzde deprem tehlike analizinde aktif olarak kullanılan fay bilgileri ile gerinimlerin birlikte modele girdi olarak verildiği 2. veri setinde MSE değerlerinin 0.09-0.16, RMSE değerlerinin ise 0.30-0.40 arasında değiştiği görülmektedir. Buna göre en iyi sonucu Rastgele orman ve XGBoost algoritmaları vermiştir (RMSE:0.30 ve MSE:0.09). K en yakın komşu ve Karar ağaçları algoritmaları ise sırasıyla MSE: 0.11 – RMSE: 0.33 ve MSE: 0.16 – RMSE: 0.40 değerlerine sahiptir. Tüm sonuçlar birlikte değerlendirildiğinde Rastgele orman ve XGBoost algoritmalarının

ikinci veri setinde en iyi sonuçları verdiği, K en yakın komşu algoritmasının ise birinci veri setinde en iyi değeri verdiği görülmektedir. Ancak burada daha da önemli olan, depremi tanımlayan parametrelerden oluşan girdi sayısı arttıkça sistemin öğrenme becerisinin artmış, hata payının azalmış olmasıdır. Bu durum deprem tekrarlama periyodu, faylara ait tarihsel dönemdeki deprem kayıtları, yüzey kırıkları vb. bilgiler ile daha yüksek doğrulukta sonuç elde edilebileceğini göstermektedir.

Makine öğrenmesi algoritmalarında her bir girdinin sonuca etkisini görmek için algoritmanın sağladığı bir ağırlığa göre (0 ile 1 arasında) ağırlıklandırılarak gerçekleştirilmektedir (Kuzey 2012).


Çizelge 6.5 Değişken ağırlıkları.

Girdiler	1. Veri Seti (Deprem ve Fay Bilgileri)	2. Veri Seti (Fay Bilgileri ve Gerinimler)
	Ağırlıklar	Ağırlıklar
Tarih	0.28	0.25
Enlem	0.18	0.16
Boylam	0.22	0.12
Derinlik	0.13	0.15
Fay Tipi	0.01	0.01
Faya	0.16	0.13
Uzaklık		
Fay	0.03	0.01
Uzunluk		
Gerinim	-	0.17


6.5 Deprem Tehlike Haritalarının Üretilmesi

37.90 – 40.10 enlemleri ve 26.16 – 30.46 boylamları arasında kalan bölge 0.1° gridlere ayrılmıştır. Elde edilen noktalar faylar ile eşleştirilmiştir. Her nokta için en yakın olduğu faya olan uzaklığı, eşleştiği fayın uzunluğu ve fay türü belirlenmiştir. Elde edilen veri ve eğitilmiş modeller kullanılarak her algoritma özelinde tekrar deprem büyüklüğü tahmininde bulunulmuş ve deprem tehlike haritaları üretilmiştir. Tahmin için girdi olarak her noktanın eşleştirilen fay bilgileri, eğitim için kullanılan verideki derinlik ortalaması


olan 7,17 km, tarih olarak 2496469.5 (01.01.2023) tarihi kullanılmıştır. Harita üzerinde kırmızı ile gösterilen bölgeler risk seviyesinin yüksek olduğu, mavi ile gösterilen bölgeler risk seviyesinin düşük olduğu yerleri temsil etmektedir.



Şekil 6.8 Random forest modeli ile üretilmiş deprem tehlike haritası.



Şekil 6.9 Xgboost modeli ile üretilmiş deprem tehlike haritası.



Şekil 6.10 Decision tree modeli ile üretilmiş deprem tehlike haritası.

Haritalar incelendiğinde Rastgele orman ve Xgboost algoritmaları ile yüz yıl sonrası için yapılan tahminler ile üretilen haritalarda Batı Ege ve İç Ege bölgelerinde deprem tehlikesinin olduğu görülmektedir. Karar ağaçları ile yüz yıl sonrası için yapılan tahminlerde ise Güney Marmara ile Güney Ege bölgelerinde deprem tehlikesinin olduğu görülmüştür. Bu bölgelerde büyüklüğü 5 ve üzeri depremler olabileceği görülmektedir.



7. TARTIŞMA VE SONUÇ

Bu çalışmada deprem kataloglarında yer alan veriler, faylara ait bilgiler ve güncel jeodezik gerinimler kullanılarak deprem kestirimi yapılması amaçlanmıştır. Bu nedenle KRDAE deprem kataloğunun (1900-2021) kendisi ve bu katalogdan, artçı depremler çıkartılarak, depremler ile faylar ilişkilendirilerek ve fay bilgilerinin yanına gerinimler eklenerek elde edilen veri seti olmak üzere iki adet veri seti elde edilmiştir. Elde edilen bu iki veri seti üzerinde aynı algoritmalar kullanılmıştır. Dört farklı algoritma ile yapılan testlerde, model performansını belirlemek için MSE ve RMSE değerleri baz alınmıştır. Modelin eğitim ve test aşamalarında, veri setinin %30'u test verisi %70'i eğitim verisi olarak kullanılmıştır. Sıfıra en yakın değerlerin en iyi performansı verdiği göz önünde bulundurulursa, en başarılı algoritmaların ikinci veri setinde rastgele orman (RF) ve gradient boosting trees (XGBoost) algoritmalarının, birinci veri setinde ise k en yakın komşu algoritmasının olduğu görülmektedir. En düşük performansı sergileyen algoritmanın ise her iki veri setinde karar ağaçları (DT) algoritması olduğu görülmüştür. Depremler ve fay bilgilerinin yer aldığı veri seti ile yapılan çalışmada en düşük 0.11 bulunan karesel ortalama hata (MSE) değerinin, gerinimler ve fay bilgilerinin eklendiği veri seti ile 0.09 karesel ortalama hata değerine kadar düştüğü görülmüştür. Gerinim değerleri ve fay bilgilerinin eklenmesi ile rastgele orman ve XGBoost algoritmalarının sonuçlarında gözle görülür bir iyileşme görülmektedir.

Literatürde (Lubbers vd. 2018) tarafından tamamlanan çalışmada elde edilen akustik sinyaller veri setinin büyütülmesi ve (Moustra vd. 2011) tarafından yapılan çalışmalarda kullanılan sismik elektrik sinyalleri verisindeki eksik kısımların tamamlanarak girdi sayısının artırılması gibi müdahaleler ile sonuç doğrulukları artırılmaktadır. Bunun yanında (Leduc vd. 2017) çalışmasında belirtildiği gibi jeodezik verilere ek olarak akustik sinyaller ile laboratuvar ortamında elde edilen veriler Dünya ölçeğinde genişletilerek çalışma doğruluğu artırılabilir. Son olarak (Gitis ve Derendyaev 2019) tarafından tamamlanan çalışmada da değinildiği gibi bu sonuçlar deprem tahmini problemi üzerine yapılan çalışmalara katkıda bulunabilir. Bu çalışmalardan yola çıkarak ileride yapılacak çalışmalarda paleosismolojik verilerin eklenmesi, gerinimlerin tüm ülke ölçeğinde çalışılarak veriye eklenmesi veya veri seti içerisine farklı parametrelerin eklenmesi ile

başarı oranının yükseltilebileceği değerlendirilmektedir. Kullanılan algoritmalarından farklı algoritmalar ile tahmin doğrulukları yükseltilebilir ve tehlike haritalarının üretilmesinde bu algoritmalar da kullanılabilir.



8. KAYNAKLAR

- Afet ve Acil Durum Yönetimi Başkanlığı (AFAD), 2018, Türkiye’de Afet Yönetimi ve Doğa Kaynaklı Afet İstatistikleri.
- Akay E Ç, 2018, Ekonometride Yeni Bir Ufuk: Büyük Veri ve Makine Öğrenmesi, Sosyal Bilimler Araştırma Dergisi, 7, 41-53.
- Akın P, Terzi Y, 2020, Dengesiz Veri Setli Sağkalım Verilerinde Cox Regresyon ve Rastgele Orman Yöntemlerin Karşılaştırılması, Veri Bilimi, 3, 21-25.
- Akman M, Genç Y, Ankaralı H, 2011, Random Forests Yöntemi ve Sağlık Alanında Bir Uygulama/Random Forests Methods and an Application in Health Science, Türkiye Klinikleri Biyoistatistik, 3, 36-48.
- Aktuğ B, 2017, Jeodezik Deprem Tehlike Haritası, TMMOB Harita ve Kadastro Mühendisleri Odası, Türkiye Harita Bilimsel ve Teknik Kurultayı, 3-6 Mayıs 2017, Ankara.
- Altunkaynak A, Başakın E E, Kartal E, 2020, Dalgacık K-en Yakın Komşuluk Yöntemi ile Hava Kirliliği Tahmini, Uludağ Üniversitesi Mühendislik Fakültesi Dergisi, 25, 1547-1556.
- Araszkiewicz A, Figurski M, Jarosiński M, 2016, Erroneous GNSS Strain Rate Patterns and Their Application to Investigate The Tectonic Credibility of GNSS Velocities, Acta Geophysica, 64, 1412-1429.
- Aytekin O, 2012, 2011 Van Depreminin Yöresindeki Kültür Varlıklarına Olan Etkisi Üzerine Bir Değerlendirme, Batman Üniversitesi Yaşam Bilimleri Dergisi, 1, 1081-1090.
- Atalay M, Çelik E, 2017, Büyük Veri Analizinde Yapay Zekâ ve Makine Öğrenmesi Uygulamaları-Artificial Intelligence and Machine Learning Applications in Big Data Analysis, Mehmet Akif Ersoy Üniversitesi Sosyal Bilimler Enstitüsü Dergisi, 9, 155-172.
- Başçiftçi F, 2020, Tektonik Hareketlerin Jeodezik Yöntemlerle İzlenmesi, Mimarlık Bilimlerinde Güncel Araştırmalar, 34.

- Başer B Ö, Yangın M, Sarıdaş E S, 2021, Makine Öğrenmesi Teknikleriyle Diyabet Hastalığının Sınıflandırılması, Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi, 25, 112-120.
- Bingol K, Akan A E, Örmecioğlu H T, Er A, 2020, Artificial Intelligence Applications in Earthquake Resistant Architectural Design: Determination of Irregular Structural Systems With Deep Learning and ImageAI Method, Journal of the Faculty of Engineering and Architecture of Gazi University, 35, 2197-2209.
- Buitinck L, Louppe G, Blondel M, Pedregosa F, Mueller A vd., 2013, API Design for Machine Learning Software: Experiences from The Scikit-learn Project, arXiv preprint arXiv:1309.0238.
- Chen T, Guestrin C, 2016, Xgboost: A Scalable Tree Boosting System, In proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining, 785-794.
- Efe E, Algancı U, 2023, Çok zamanlı Sentinel 2 uydu görüntüleri ve makine öğrenmesi tabanlı algoritmalar ile arazi örtüsü değişiminin belirlenmesi. Geomatik, 8, 27-34.
- El Naqa I, Murphy M J, 2015, What is machine learning?, Springer International Publishing, 3-11.
- Emre Ö, Duman T Y, Özalp S, Şaroğlu F, Olgun Ş, Elmacı H, Çan T, 2018, Active Fault Database of Turkey, Bulletin of Earthquake Engineering, 16, 3229-3275.
- Erdoğan S, 2006, Burdur Fethiye Fay Zonu Tektonik Hareketlerinin GPS ile Belirlenmesi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Doktora Tezi, İstanbul.
- Ergünay O, 1976, Earthquake Zoning Map of Turkey, UNESCO Proc. Sem. Seism. Zoning Map, 1, 359-370.
- Ergünay O, 2007, Türkiye'nin Afet Profili, TMMOB Afet Sempozyumu Bildiriler Kitabı, 5, 1-14.
- Doğaner A, Çalık S, 2014, Elazığ ve çevresindeki sismik aktivitelerin deprem parametreleri ilişkisinin incelenmesi, Fırat Üniv. Fen Bilimleri Dergisi, 26, 73-77.

- Genç F N, 2007, Türkiye’de Doğal Afetler ve Doğal Afetlerde Risk Yönetimi, Stratejik Araştırmalar Dergisi, 9, 201-226.
- Gitis V G, Derendyaev A B, 2019, Machine Learning Methods for Seismic Hazards Forecast, Geosciences, 9, 308.
- Gündoğdu O, 1986, Türkiye Depremlerinin Kaynak Parametreleri ve Aralarındaki İlişkiler, İstanbul Üniversitesi Mühendislik Fakültesi, Doktora tezi, 122s, İstanbul.
- Gündoğdu O, Işık Ö, Koç S, 2012, Marmara ve Çevresinde Deprem Tehlikesi, Okmeydanı Tıp Dergisi, 28, 71-81.
- Işık Ö, Aydınlioğlu H. M, Koç S, Gündoğdu O, Korkmaz G, Ay A, 2012, Afet Yönetimi ve Afet Odaklı Sağlık Hizmetleri, Okmeydanı Tıp Dergisi, 28, 82-123.
- Karakoyun M, Hacıbeyoğlu M, 2014, Biyomedikal Veri Kümeleri İle Makine Öğrenmesi Sınıflandırma Algoritmalarının İstatistiksel Olarak Karşılaştırılması, Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen ve Mühendislik Dergisi, 16, 30-42.
- Kavzoğlu T, Şahin E K, Çölkesen İ, 2012, Heyelan Duyarlılığının İncelenmesinde Regresyon Ağaçlarının Kullanımı: Trabzon örneği, Harita Dergisi, 147, 21-33.
- Kaya Ç, Yıldız O, 2014, Makine Öğrenmesi Teknikleriyle Saldırı Tespiti: Karşılaştırmalı Analiz, Marmara University Journal of Science, 26.
- Kemalbay G, Alkış B N, 2020, Borsa Endeks Hareket Yönünün Çoklu Lojistik Regresyon ve K-en Yakın Komşu Algoritması ile Tahmini, Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi, 27, 556-569.
- Korkmaz D, Çelik H E, Kapar M, 2018, Sınıflandırma ve Regresyon Ağaçları ile Rastgele Orman Algoritması Kullanarak Botnet Tespiti: Van Yüzüncü Yıl Üniversitesi Örneği, Yüzüncü Yıl Üniversitesi Fen Bilimleri Enstitüsü Dergisi, 23, 297-307.
- Kurt A, Buldu B, Cedimoğlu İ H, 2020, Xgboost ve Rastgele Orman Algoritmalarının Ağ Tabanlı Saldırı Tespitine Yönelik Performanslarının Karşılaştırılması.
- Kuzey C, 2012, Veri Madenciliğinde Destek Vektör Makinaları ve Karar Ağaçları Yöntemlerini Kullanarak Bilgi Çalışanlarının Kurum Performansı Üzerine Etkisinin Ölçülmesi ve Bir Uygulama. Yayımlanmamış Doktora Tezi, İstanbul

Üniversitesi Sosyal Bilimler Enstitüsü, 341s, İstanbul.

- Lahr J C, Chouet B A, Stephens C D, Power J A, Page R A, 1994, Earthquake Classification, Location, and Error Analysis in a Volcanic Environment: Implications for The Magmatic System of The 1989–1990 Eruptions at Redoubt Volcano, Alaska, *Journal of Volcanology and Geothermal Research*, 62, 137-151.
- Lubbers N, Bolton D C, Mohd-Yusof J, Marone C, Barros K, Johnson P A, 2018, Earthquake Catalog-Based Machine Learning Identification of Laboratory Fault States and The Effects of Magnitude of Completeness, *Geophysical Research Letters*, 45, 13-269.
- 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, 15032-15039.
- Oğuzlar A, 2003, Veri Ön İşleme, *Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 21, 67-76.
- Okay A I, 2000, Marmara Denizindeki Aktif Fay Geometrisi Nasıl Araştırılmalı, *Cumhuriyet Bilim Teknik Dergisi*, 683, 17-18. İstanbul.
- Özgür E G, Erdoğan B D, 2020, Bilgisayar Uyarlamalı Test (BUT) Uygulamalarında Regresyon Ağacı Yaklaşımı: Regresyon Karar Ağaçları ile Psikometrik Model Kullanan Standart BUT Algoritmasının Yapay Bir Veri Üzerinde Değerlendirilmesi, *Ankara Sağlık Bilimleri Dergisi*, 9, 161-167.
- Özmen B, 2012, Türkiye Deprem Bölgeleri Haritalarının Tarihsel Gelişimi, *Türkiye Jeoloji Bülteni*, 55.
- Pampal S, Özmen B, 2007, Türkiye'nin Deprem Gerçeği Deprem Bölgeleri Haritaları ve Yönetmeliklerinin Tarihsel Gelişimi, 1028, Ankara.
- Peker M, Özkaraca O, Kesimal B, 2017, Enerji Tasarruflu Bina Tasarımı İçin Isıtma ve Soğutma Yüklerini Regresyon Tabanlı Makine Öğrenmesi Algoritmaları ile Modelleme, *Bilişim Teknolojileri Dergisi*, 10, 443-449.
- Perner P, Zscherpel U, Jacobsen C, 2001, A Comparison Between Neural Networks and Decision Trees Based on Data From Industrial Radiographic Testing, *Pattern*

- Recognition Letters, 22, 47-54.
- Press F and Siever R, 1999, Understanding Earth, W. H. Freeman and Company.
- Rathore S S, Kumar S, 2016, A Decision Tree Regression Based Approach for The Number of Software Faults Prediction, ACM SIGSOFT Software Engineering Notes, 41, 1-6.
- Rodriguez-Galiano V, Sanchez-Castillo M, Chica-Olmo M, Chica-Rivas M J O G R, 2015, Machine Learning Predictive Models for Mineral Prospectivity: An Evaluation of Neural Networks, Random Forest, Regression Trees and Support Vector Machines, Ore Geology Reviews, 71, 804-818.
- Roman D C, Cashman K V, 2006, The Origin of Volcano-Tectonic Earthquake Swarms, Geology, 34, 457-460.
- Rouet-Leduc B, Hulbert C, Lubbers N, Barros K, Humphreys C J, Johnson P A, 2017, Machine Learning Predicts Laboratory Earthquakes, Geophysical Research Letters, 44, 9276-9282.
- Savaş S, Topaloğlu N, Yılmaz M, 2012, Veri Madenciliği ve Türkiye'deki Uygulama Örnekleri, İstanbul Ticaret Üniversitesi Fen Bilimleri Dergisi, 11, 1-23.
- Seyrek E, 2020, Yeni Türkiye Sismik Tehlike Haritasının Ege Bölgesi için Değerlendirilmesi, Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi, 9, 414-423.
- Shehadeh A, Alshboul O, Al Mamlook R E, Hamedat O, 2021, Machine Learning Models for Predicting The Residual Value of Heavy Construction Equipment: An Evaluation of Modified Decision Tree, LightGBM, and XGBoost Regression, Automation in Construction, 129, 103827.
- Shen Z K, Wang M, Zeng Y, Wang F, 2015, Optimal Interpolation of Spatially Discretized Geodetic Data, Bulletin of the Seismological Society of America, 105, 2117-2127.
- Solak H İ, 2015, GNSS Hızları ile Güneybatı Anadolu'daki Gerinim Alanlarının Zamansal Değişimi, Afyon Kocatepe Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek lisans tezi, 95s, Afyonkarahisar.

- Solak H İ, 2020, İzmir-Balıkesir Transfer Zonu ve Çevresindeki Güncel Deformasyonların GNSS Yöntemi ile İncelenmesi, Afyon Kocatepe Üniversitesi, Fen Bilimleri Enstitüsü, Doktora Tezi, 163s, Afyonkarahisar.
- Suthaharan S, 2014, Big Data Classification: Problems and Challenges in Network Intrusion Prediction with Machine Learning, ACM Sigmetrics Performance Evaluation Review, 41, 70-73.
- Sümer Ö, Karagöz O, Akın A, 2018, Fay Parametreleri ve Deprem Büyüklüğü Arasındaki İlişkiler İçin Yeni Bir Program: Faultstat, Afyon Kocatepe Üniversitesi Fen Ve Mühendislik Bilimleri Dergisi, 18, 1089-1101.
- Sür Ö, 1993, Türkiye'nin Deprem Bölgeleri, Türkiye Coğrafyası Araştırma ve Uygulama Merkezi Dergisi, 2, 53-68.
- Taşcı E, Onan A, 2016, K-en Yakın Komşu Algoritması Parametrelerinin Sınıflandırma Performansı Üzerine Etkisinin İncelenmesi, Akademik Bilişim, 1, 4-18.
- Tiryakioğlu İ, 2012, GNSS Ölçüleri ile Güneybatı Anadolu' daki Blok Hareketleri ve Gerilim Alanlarının Belirlenmesi, Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Doktora Tezi, 173s, İstanbul.
- Tosunoğlu E, Yılmaz R, Özeren E, Sağlam Z, 2021, Eğitimde Makine Öğrenmesi: Araştırmalardaki Güncel Eğilimler Üzerine İnceleme, Ahmet Keleşoğlu Eğitim Fakültesi Dergisi, 3, 178-199.
- Tso G K, Yau K K, 2007, Predicting Electricity Energy Consumption: A Comparison of Regression Analysis, Decision Tree and Neural Networks, Energy, 32, 1761-1768.
- Tunca E, Köksal E, 2021, Sentinel 2 Uydu Görüntülerinden Bitki Türlerinin Makine Öğrenmesi ile Belirlenmesi. ÇOMÜ Ziraat Fakültesi Dergisi, 9, 189-200.
- Tüysüz O, 1999, Yeryuvarının İç Yapısı, Depremler ve Türkiye, Ders Notları, Avrasya Yer Bilimleri Enstitüsü, İstanbul.
- Utkucu M, Alptekin Ö, 2001, Real-Time (Gerçek-Zaman) Sismolojisi, Dünyadaki Gelişimi ve Türkiye'de Uygulanabilirliği, İstanbul Üniversitesi Mühendislik Fakültesi Yerbilimleri Dergisi, 14, 139-152.

- Utkucu M, Budakoğlu E, Durmuş H, 2011, Marmara Bölgesinde (KB Türkiye) Depremsellik ve Deprem Tehlikesi Üzerine Bir Tartışma. *Yerbilimleri*, 32, 141-168.
- Ülker E, İnık Ö, 2017, Deep Learning and Deep Learning Models Used in Image Analysis, *Gaziosmanpaşa Journal of Scientific Research*, 6, 85-104.
- Ülker M, Civalek O, 2002, Yapay Sinir Ağları ile Eksenel Yüklü Kolonların Burkulma Analizi, *Turkish Journal of Engineering and Environmental Sciences*, 26, 117-125.
- Verma P, Anwar S, Khan S, Mane S B, 2018, Network Intrusion Detection Using Clustering and Gradient Boosting, In 2018 9th International conference on computing, communication and networking technologies (ICCCNT), 1-7. IEEE.
- Wang S, Yao X, 2013, Using Class Imbalance Learning for Software Defect Prediction, *IEEE Transactions on Reliability*, 62, 434-443.
- Yavaşoğlu H, 2003, Kuzey Anadolu Fayının Orta Bölümünün Kinematığının 2001 ve 2002 GPS Ölçmeleri ile Belirlenmesi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 76s, İstanbul
- Yavaşoğlu H, 2009, Kuzey Anadolu Fayının Orta Anadolu Bölümündeki Güncel Tektonik Aktivitenin Jeodezik Yöntemler Ve Elastik Yarı Uzay Modelleme İle Belirlenmesi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Doktora Tezi, 205s, İstanbul.

İnternet Kaynakları

- 1- <http://opentextbc.ca/geology/chapter/1-5-fundamentals-of-plate-tectonics/>, 05.10.2022
- 2- <http://tdth.afad.gov.tr/TDTH/main.xhtml/>, 10.02.2021
- 3- <https://depem.afad.gov.tr/event-catalog/>, 10.02.2021
- 4- <http://towardsdatascience.com/https-medium-com-vishalmorde-xgboost-algorithm-long-she-may-rein-edd9f99be63d/>, 16.03.2023
- 5- <http://machinelearningmastery.com/gentle-introduction-xgboost-applied-machine-learning/>, 15.03.2023