



**T.C.
BURSA TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

**UZUN KISA SÜRELİ BELLEK (LSTM) KULLANARAK İSTANBUL VE
CİVARI İÇİN DEPREM EĞİLİMİ TAHMİNİ**

YÜKSEK LİSANS TEZİ

Yasin KARAKUŞ

Bilgisayar Mühendisliği Anabilim Dalı

Bilgisayar Mühendisliği Tezli Yüksek Lisans Programı

EKİM 2024

**T.C.
BURSA TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

**UZUN KISA SÜRELİ BELLEK (LSTM) KULLANARAK İSTANBUL VE
CİVARI İÇİN DEPREM EĞİLİMİ TAHMİNİ**

YÜKSEK LİSANS TEZİ

Yasin KARAKUŞ

(22435004005)

ORCID: 0000-0002-4534-0151

**Bilgisayar Mühendisliği Anabilim Dalı
Bilgisayar Mühendisliği Tezli Yüksek Lisans Programı**

Danışman: Doç. Dr. Volkan ALTUNTAŞ

ORCID: 0000-0003-3144-8724

EKİM 2024

BTÜ, Lisansüstü Eğitim Enstitüsü'nün 22435004005 numaralı Yüksek Lisans Öğrencisi Yasin KARAKUŞ, ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı "UZUN KISA SÜRELİ BELLEK (LSTM) KULLANARAK İSTANBUL VE CİVARI İÇİN DEPREM EĞİLİMİ TAHMİNİ" başlıklı tezini aşağıda imzaları olan jüri önünde başarı ile sunmuştur.

Tez Danışmanı : **Doç. Dr. Volkan ALTUNTAŞ**
Bursa Teknik Üniversitesi

Jüri Üyeleri : **Doç. Dr. Erdem YAVUZ**
Bursa Teknik Üniversitesi

Dr. Öğr. Üyesi İrfan KÖSESOY
Kocaeli Üniversitesi

Teslim Tarihi :
Savunma Tarihi : **07 Ekim 2024**



20.04.2016 tarihli Resmi Gazete’de yayımlanan Lisansüstü Eğitim ve Öğretim Yönetmeliğinin 9/2 ve 22/2 maddeleri gereğince; Bu Lisansüstü teze, Bursa Teknik Üniversitesi’nin aboneliği olduğu intihal yazılım programı kullanılarak Lisansüstü Eğitim Enstitüsü’nün belirlemiş olduğu ölçütlere uygun rapor alınmıştır.

İNTİHAL BEYANI

Bu tezde görsel, işitsel ve yazılı biçimde sunulan tüm bilgi ve sonuçların akademik ve etik kurallara uyularak tarafımdan elde edildiğini, tez içinde yer alan ancak bu çalışmaya özgü olmayan tüm sonuç ve bilgileri tezde kaynak göstererek belgelediğimi, aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiğimi beyan ederim.

Öğrencinin Adı Soyadı: Yasin KARAKUŞ

İmzası:

Y. KARAKUŞ



*Başta Kadim Milletimiz Olmak Üzere Arakan, Doğu Türkistan ve Filistin
Halklarına*

ÖNSÖZ

Tüm yardım ve desteklerinden dolayı başta danışman hocam Doç. Dr. Volkan ALTUNTAŞ olmak üzere tüm eğitmenlerimize, milletimizin bekası ve iyiliğini kendisine dert edinenlere ve son olarak hayatımın her anında benimle birlikte olan, maddi ve manevi desteklerini esirgemeyen aileme minnetle saygı, sevgi ve şükranlarımı sunarım.

Ekim 2024

Yasin KARAKUŞ
(Araştırma Görevlisi)

İÇİNDEKİLER

Sayfa

ÖNSÖZ.....	vii
İÇİNDEKİLER	viii
KISALTMALAR	xi
SEMBOLLER	xii
ÇİZELGE LİSTESİ.....	xiii
ŞEKİL LİSTESİ.....	xiv
1. GİRİŞ	1
1.1 Tezin Amacı	1
1.2 Tezin İçeriği	1
2. DOĞAL AFETLER	2
2.1 Tanımı	2
2.2 Çeşitleri	2
2.3 Görülme Sıklığı ve Olası Etkileri.....	3
3. DEPREM	4
3.1 Temel Kavramlar.....	4
3.1.1 Fay.....	4
3.1.2 Deprem.....	4
3.1.3 Öncü deprem	4
3.1.4 Artçı deprem	5
3.1.5 Ana şok	5
3.1.6 Derinlik	5
3.1.7 Odak noktası	5
3.1.8 Merkez üssü	5
3.1.9 Sismoloji	5
3.1.10 Sismograf	5
3.1.11 Sismisite	5
3.1.12 Büyüklük ve şiddet.....	6
3.1.12.1 Büyüklük türleri	6
3.1.13 Tsunami.....	7
3.2 Depremın Olası Etkileri.....	7
3.2.1 Depremlerin sağlık ve sağlık sistemi üzerindeki etkileri	8
3.2.2 Depremin ekonomi üzerindeki etkileri	8
3.2.3 Depremin çevre üzerindeki etkileri	8
3.2.4 Depremin eğitim sistemi üzerindeki etkileri	8
3.2.5 Depremin turizm üzerindeki etkileri	9
3.3 Meydana Gelen Depremlerin Bilançosu	9
3.3.1 Dünya genelinde meydana depremlerin bilançosu	9
3.3.2 Türkiye’de meydana gelen depremlerin bilançosu	9
4. DEPREM TAHMİN ÇALIŞMALARI.....	11
4.1 Deprem Tahmini Nasıl Olmalıdır?.....	11

4.2 Deprem Tahmini Süreci	11
4.2.1 Veri setleri	12
4.2.2 Veri ön işleme	13
4.2.2.1 Veri temizleme	13
4.2.2.2 Veri birleştirme	13
4.2.2.3 Veri dönüştürme	13
4.2.2.4 Veri indirgeme	13
4.2.3 Özellik seçimi	14
4.2.3.1 Filtreleme yöntemleri	14
4.2.3.2 Sarmalayıcı yöntemler	14
4.2.3.3 Gömülü yöntemler	14
4.2.4 Model seçimi	14
4.2.5 Eğitim ve geçerleme	15
4.2.6 Model değerlendirme	15
4.2.6.1 Sınıflandırma problemlerinde model değerlendirme	15
4.2.6.2 Regresyon problemlerinde model değerlendirme	17
4.3 Örnek Çalışmaların İncelenmesi	19
4.3.1 Tek algoritma kullanan çalışmaların incelenmesi	19
4.3.2 Hibrit ya da topluluk algoritmaları kullanan çalışmaların incelenmesi	20
4.3.3 Ülkemiz özelinde gerçekleştirilen deprem tahmin çalışmaları	21
5. İSTANBUL VE CİVARI İÇİN DEPREM EĞİLİMİ TAHMİNİ	23
5.1 İstanbul	23
5.1.1 Genel tarihi	23
5.1.2 Coğrafi konumu	23
5.1.3 Ekolojik yapısı	23
5.1.4 Turizm	24
5.1.5 Ekonomi	24
5.1.6 Nüfus yapısı	24
5.1.7 Sismoloji	24
5.1.8 Yapı stoğu	26
5.2 Materyal ve Metot	26
5.2.1 Veri seti	26
5.2.2 Veri ön işleme	28
5.2.2.1 Eksik veri tespiti	28
5.2.2.2 Veri normalizasyonu	28
5.2.2.3 Veri bölütleme	28
5.2.3 Model inşası	29
5.2.3.1 Uzun kısa süreli bellek	29
5.2.3.2 Evrimsel sinir ağları	30
5.2.4 Model değerlendirme	33
6. SONUÇLAR	34
6.1 Parametre Seçimi	34
6.1.1 Akvitasyon fonksiyonu seçimi	34
6.1.2 Sönümlenme değeri seçimi	36
6.1.3 İterasyon sayısı seçimi	36
6.1.4 Test oranı seçimi	37
6.2 Performans Ölçümü	38
6.3 Bingöl - Karlıova Civarı İçin Deprem Eğilimi Tahmini	42
7. DEĞERLENDİRME VE ÖNERİLER	46
7.1 Öneriler	47

KAYNAKLAR	49
ÖZGEÇMİŞ.....	54



KISALTMALAR

ANFIS	: Uyarlanabilir Nöro-Bulanık Çıkarım Sistemi
ANN	: Yapay Sinir Ağları
ARIMA	: Otoregresif Bütünleşik Hareketli Ortalama
BiLSTM	: Çift Yönlü Uzun Kısa Süreli Bellek
CNN	: Evrimsel Sinir Ağları
CRED	: Afet Araştırma ve Epidemiyoloji Merkezi
ELM	: Aşırı Öğrenme Makinesi
EM-DAT	: Acil Durum Olayları Veri Tabanı
FFNN	: İleri Beslemeli Sinir Ağı
FPA	: Çiçek Tozlaşma Algoritması
Km	: Kilometre
kNN	: k-en Yakın Komşular
LS-SVM	: En Küçük Kareler Destek Vektör Makinesi
LSTM	: Uzun Kısa Süreli Bellek
MAE	: Ortalama Mutlak Hata
MAPE	: Ortalama Mutlak Yüzde Hatası
MLPNN	: Çok Katmanlı Algılayıcı Sinir Ağı
MSE	: Ortalama Hata Karesi
RBFNN	: Radyal Tabanlı Fonksiyon Sinir Ağı
RF	: Rastgele Orman
RMSE	: Kök Ortalama Kare Hatası
RNN	: Yinelemeli Sinir Ağı
SMA	: Basit Hareketli Ortalama
SRNN	: Yapısal Tekrarlayan Sinir Ağı
SSA	: Tekil Spektrum Analizi
SVM	: Destek Vektör Makinesi
TÜİK	: Türkiye İstatistik Kurumu
USGS	: Amerika Birleşik Devletleri Jeoloji Araştırmaları Kurumu
Yy	: Yüzyıl

SEMBOLLER

FN	: Yanlıř negatif
FP	: Yanlıř pozitif
n	: Gzlem sayısı
TN	: Gerek negatif
TP	: Gerek pozitif
x	: Veri seti ierisindeki herhangi bir deęer
Xmax	: Veri seti ierisindeki en byk deęer
Xmin	: Veri seti ierisindeki en dřk deęer
Xscaled	: 0-1 aralıęına leklenmiř deęer
y_i	: i. gzlemin gerek deęeri
ŷ_i	: i. gzlemin tahmin edilen deęeri

ÇİZELGE LİSTESİ

Sayfa

Çizelge 3.1 : Büyüklük ve şiddet dönüşüm tablosu.....	6
Çizelge 3.2 : Dünya genelinde meydana gelen depremlerin bilançosu.	9
Çizelge 3.3 : Türkiye’de meydana gelen depremlerin bilançosu.	10
Çizelge 4.1 : Ülkeler ve deprem verilerini yayınlayan kuruluşlar.....	12
Çizelge 5.1 : Beklenen İstanbul depremiyle alakalı olabilecek olan depremler.....	25
Çizelge 5.2 : Deprem veri setine ait detaylı bilgi	27
Çizelge 5.3 : Deprem veri setine ait istatistikler.....	28
Çizelge 6.1 : LSTM modelinde aktivasyon fonksiyonu seçimi için yapılan testlerin sonuçları.....	35
Çizelge 6.2 : CNN modelinde aktivasyon fonksiyonu seçimi için yapılan testlerin sonuçları	35
Çizelge 6.3 : Sönümlenme değeri seçimi için yapılan testlerin sonuçları.	36
Çizelge 6.4 : LSTM modelinde iterasyon sayısı seçimi için yapılan testlerin sonuçları	37
Çizelge 6.5 : CNN modelinde iterasyon sayısı seçimi için yapılan testlerin sonuçları	37
Çizelge 6.6 : LSTM modelinde test oranı seçimi için yapılan testlerin sonuçları.....	38
Çizelge 6.7 : CNN modelinde test oranı seçimi için yapılan testlerin sonuçları.....	38
Çizelge 6.8 : İstanbul ve civarında son 25 yılın deprem verileri kullanılarak yapılan performans ölçümü.	39
Çizelge 6.9 : İstanbul ve civarında son 10 yılın deprem verileri kullanılarak yapılan performans ölçümü.	39
Çizelge 6.10 : İstanbul ve civarında son 5 yılın deprem verileri kullanılarak yapılan performans ölçümü.....	40
Çizelge 6.11 : İstanbul ve civarında son 1 yılın deprem verileri kullanılarak yapılan performans ölçümü.....	40
Çizelge 6.12 : İstanbul ve civarında zaman aralığı ve tahmin edilen özelliğe göre en düşük hata skoru elde eden modeller.....	41
Çizelge 6.13 : Bingöl - Karlıova civarında son 25 yılın deprem verileri kullanılarak yapılan performans ölçümü.	42
Çizelge 6.14 : Bingöl - Karlıova civarında son 10 yılın deprem verileri kullanılarak yapılan performans ölçümü.	43
Çizelge 6.15 : Bingöl - Karlıova civarında son 5 yılın deprem verileri kullanılarak yapılan performans ölçümü.	43
Çizelge 6.16 : Bingöl - Karlıova civarında son 1 yılın deprem verileri kullanılarak yapılan performans ölçümü	44
Çizelge 6.17 : Bingöl - Karlıova civarında zaman aralığı ve tahmin edilen özelliğe göre en düşük hata skoru elde eden modeller.....	44

ŞEKİL LİSTESİ

	<u>Sayfa</u>
Şekil 2.1 : CRED'e göre doğal afet çeşitleri.	2
Şekil 2.2 : Dünya genelinde en yaygın görülen doğal afetler(2000 – 2019)	3
Şekil 2.3 : Doğal afetlerin 1980-1999 ve 2000-2019 yılları arasındaki etkileri	3
Şekil 4.1 : Deprem tahmini çalışmalarının sınıflandırılması	11
Şekil 4.2 : Deprem tahmin süreci	12
Şekil 4.3 : Karışıklık matrisi	16
Şekil 5.1 : Ülkemizde bulunan fay hatları	25
Şekil 5.2 : Deprem veri setindeki özelliklere ait değerlerin zamansal gösterimi	27
Şekil 5.3 : LSTM akış diyagramı	31
Şekil 5.4 : CNN akış diyagramı	32

UZUN KISA SÜRELİ BELLEK (LSTM) KULLARAK İSTANBUL VE CİVARI İÇİN DEPREM EĞİLİMİ TAHMİNİ

ÖZET

Doğal afetler, genellikle insanların kontrolü dışında gerçekleşen ve gerçekleşmesi neticesinde başta can ve mal kayıpları olmakla birlikte ekonomik, çevresel, sağlıksal ve daha nice kayıplara yol açan olaylardır. Bu doğal afetlerden birisi olan depremler ile ülkemiz tarihinde sıkça karşılaşılmaktadır. Birçok ülke, kurum ve kişi tarafından depremlerin yıkıcı etkilerini en aza indirmek için çalışmalar yapılmaktadır. Bu çalışmalardan birisi de depremi gerçekleşmeden önceden yeri, zamanı ve büyüklüğüyle tahmin edebilen deprem tahmin çalışmalarıdır.

Depremi önceden tahmin edilebilmesi can ve mal kaybını büyük oranda azaltma potansiyeline sahip olduğu için hayati öneme sahip ve depremlerin sürekli yaşanıyor olmalarıyla birlikte popülerliğini hiç kaybetmeyen bir konudur. Aynı zamanda depremlerin oluşumunun çok yüksek karmaşıklıkta süreçleri içermesi ve analiz edilmesi zor olan çok sayıda faktöre bağlı olmasından dolayı oldukça zor bir konudur. Deprem tahmini üzerine mevcut çalışmalar, kullanılan metodolojilere göre matematiksel analiz, öncüllerin araştırılması, geleneksel makine öğrenmesi ve derin öğrenme olmak üzere dört farklı başlık altında incelenebilmektedir. Öncüller olarak isimlendirilen verilerin kullanıldığı çalışmalar her depremden önce meydana gelmediği için bu verileri kullanan algoritmaları genelleştirmek ve standart hale getirmek oldukça zordur. Matematiksel analiz yöntemleri kısıtlı verilerle çalışmaları ve düşük başarı sonuçları elde ettikleri için pek tercih edilmemektedirler. Geleneksel makine öğrenmesi deprem tahmininde kullanılan önemli yöntemlerden birisidir. Derin öğrenme yöntemleri, karmaşık problemleri çözmedeki başarısı nedeniyle deprem tahmininde son zamanlardaki en popüler yöntemlerdir. Uluslararası mecralarda deprem tahmini çalışmaları gerçekleştirildiği gibi ülkemizde de çeşitli yöntemler kullanılarak deprem tahmini çalışmaları gerçekleştirilmiştir. Kahramanmaraş'ta meydana gelen depremlerle birlikte yaşamış olduğumuz can ve mal kayıplarının ardından gözler jeologların uzun zamandır üzerinde durduğu ve yapı stoğunun büyük bir çoğunluğunun eskiye dayandığı İstanbul'a çevrilmiştir. Ne yazık ki beklenen İstanbul depremi için İstanbul ve civarına yönelik yeterli sayıda deprem tahmini çalışması yapılmamıştır.

Beklenen İstanbul depremi için bir deprem tahmin çalışması yapmak, deprem tahmini konusunda bir kaynak oluşturmak ve bu konuda çalışmalar yapmaya teşvik etmek amacıyla bu çalışmada İstanbul ve civarı için uzun kısa süreli bellek (LSTM) ve evrişimsel sinir ağları (CNN) kullanarak deprem tahmini çalışması yapılmıştır. Bu çalışmadan önce deprem ve deprem tahmin çalışmalarına dair genel bilgiler verilmiştir. Daha sonra deprem tahmini kısmı veri toplama, veri ön işleme, veri bölütleme, model eğitimi ve modellerin değerlendirilmesi aşamalarından oluşmaktadır. Veri toplama aşamasında İstanbul ve civarına ait son 25 yılın tarihsel deprem verileri AFAD'dan temin edilmiştir. Veri ön işleme aşamasında eksik veri tespiti ve veri normalizasyonu gerçekleştirilmiştir. Veri Bölütleme aşamasında veri

seti eğitim ve test olmak üzere 2 kısma ayrılmıştır. Model eğitimi aşamasında LSTM ve CNN kullanılarak deprem tahmini modeli oluşturulmuştur. Deprem tahmin modeli girdi olarak deprem büyüklüğü, enlem, boylam ve derinlik verilerini ayrı ayrı ya da hep birlikte kullanarak deprem büyüklüğü, enlem, boylam ve derinlik tahminleri yapmaktadır. Model değerlendirme aşamasında deprem tahmin modeli ile birlikte parametreler, tarihsel veriler ve veri seti özellikleri ortalama mutlak hata, ortalama hata karesi ve ortalama mutlak yüzde hatası metrikleri kullanılarak test edilmiştir. Ek olarak eğitilen modeller, modellerin geçerliliğini ölçmek amacıyla bir diğer deprem beklenen yerler arasında olan Bingöl – Karlıova civarı için de test edilmiştir.

Testler sonucunda İstanbul ve civarı için kabul edilebilir başarı oranına sahip bir deprem tahmin çalışması gerçekleştirilmiştir. Bununla birlikte bu problem özelinde LSTM ve CNN modellerin ne kadar başarılı oldukları, hangi zaman aralığına ait verilerin kullanımının daha başarılı sonuçlar üretebileceği, özelliklerin öğrenmeye olan katkısı ve hangi parametrelerin daha kullanışlı olduğuna yönelik bilgiler edinilmiştir.

Anahtar kelimeler: Deprem tahmini, Derin öğrenme, LSTM, CNN, İstanbul.

EARTHQUAKE PREDICTION FOR ISTANBUL AND ITS NEIGHBOURHOOD USING LONG SHORT TERM MEMORY (LSTM)

SUMMARY

Natural disasters are events that generally occur beyond the control of human beings and as a result of their realisation, they cause economic, environmental, health and many other losses, especially loss of life and property. We frequently encounter earthquakes, one of these natural disasters, in the history of our country. Many countries, institutions and individuals are working to minimise the destructive effects of earthquakes. One of these studies is earthquake prediction studies that can predict the earthquake with its location, time and magnitude before it occurs.

Predicting the earthquake in advance is of vital importance because it has the potential to greatly reduce the loss of life and property, and it is a subject that has never lost its popularity with the continuous occurrence of earthquakes. At the same time, it is a very challenging topic because the occurrence of earthquakes involves processes of very high complexity and depends on many factors that are difficult to analyse. Existing studies on earthquake prediction can be analysed under four different headings according to the methodologies used: mathematical analysis, antecedent search, traditional machine learning and deep learning. Since the studies using data called precursors do not occur before every earthquake, it is very difficult to generalise and standardise the algorithms using these data. Mathematical analysis methods are not preferred because they work with limited data and achieve low success results. Traditional machine learning is one of the important methods used in earthquake prediction. Deep learning methods are the most popular methods in earthquake prediction due to their success in solving complex problems. As earthquake prediction studies have been carried out internationally, earthquake prediction studies have also been carried out in our country using various methods. After the loss of life and property we have experienced with the earthquakes in Kahramanmaraş, the eyes have turned to Istanbul, which geologists have been focusing on for a long time and where most of the building stock is based on old buildings. Unfortunately, a sufficient number of earthquake prediction studies have not been carried out for Istanbul and its vicinity for the expected Istanbul earthquake.

In order to make an earthquake prediction study for the expected Istanbul earthquake, to create a resource on earthquake prediction and to encourage studies on this subject, an earthquake prediction study using long short-term memory (LSTM) and convolutional neural networks (CNN) was carried out in this study for Istanbul and its vicinity. Before this study, general information about earthquake and earthquake prediction studies is given. Then, the earthquake prediction part consists of data collection, data preprocessing, data segmentation, model training and model evaluation. In the data collection phase, historical earthquake data of Istanbul and its neighbourhood for the last 25 years were obtained from AFAD. In the data preprocessing stage, missing data detection and data normalisation were performed. In

the data segmentation stage, the data set was divided into 2 parts as training and test. In the model training phase, an earthquake prediction model was created using LSTM and CNN. The earthquake prediction model uses earthquake magnitude, latitude, longitude and depth data separately or together to predict earthquake magnitude, latitude, longitude and depth. In the model evaluation phase, the parameters, historical data and dataset characteristics along with the earthquake prediction model were tested using the mean absolute error, mean squared error and mean absolute percentage error metrics. In addition, the trained models were also tested for the vicinity of Bingöl - Karlıova, which is among the other expected earthquake locations, in order to measure the validity of the models.

As a result of the tests, an earthquake prediction study with an acceptable success rate for Istanbul and its neighbourhood was carried out. In addition, information has been obtained on how successful LSTM and CNN models are for this problem, which time interval data can produce more successful results, the contribution of features to learning and which parameters are more useful.

Keywords: Earthquake prediction, Deep learning, LSTM, CNN, Istanbul.

1. GİRİŞ

1.1 Tezin Amacı

Bu tezin amacı depremlerin oluşumunu anlayarak depremlerin meydana getirdiği can kayıpları, sağlık problemleri, ekonomik zararlar ve çevresel tahribatlar gibi zararların önüne geçmek için derin öğrenme yöntemlerinden LSTM ve CNN ile birlikte çözümler üretmeye çalışmaktır. Tezin bir diğer amacı ise ülkemizin bir deprem ülkesi olmasına rağmen deprem tahmini konusunda yeterli çalışmanın yapılmamış olması dolayısıyla deprem tahmini çalışmalarını teşvik etmek ve bu süreçte yardım alınabilecek bir kaynak oluşturmaktır. Araştırma bölgesi olarak ülkemizde İstanbul ve civarının seçilmesi ise İstanbul'un birçok konuda Türkiye'nin en önemli şehri olmasından ve deprembilimcilerin yakın tarihte deprem beklenen şehirler arasında İstanbul'u göstermesinden kaynaklıdır. Depremlere ait zaman serisi veriler kullanılarak, geçmişte meydana gelen depremlerin gelecekte meydana gelen depremleri ne oranda ifade edebildiği araştırılmıştır. Bu çalışmada CNN'nin tek ve LSTM'nin farklı varyantları kullanılarak ilgili derin öğrenme yönteminin bu konudaki başarısı incelenmiştir.

1.2 Tezin İçeriği

Bu tezde doğal afetlere ve doğal afetlerden biri olan depreme dair temel bilgiler verilmiştir. Daha sonra makine öğrenmesi yöntemleriyle deprem tahmini çalışmalarının nasıl olması gerektiğine, deprem tahmini çalışmalarının hangi süreçlerden meydana geldiğine ve örnek deprem tahmini çalışmalarının incelenmesine yer verilmiştir. Bununla birlikte İstanbul ve civarında meydana gelen depremlere ait verileri ve CNN ve LSTM derin öğrenme yönteminin çeşitli varyantlarını kullanarak deprem eğilimi tahminine yönelik bir çalışma gerçekleştirilmiştir. Bu çalışmanın ardından geliştirilen modelin geçerliliğini ölçmek için bir diğer deprem beklenen bölgeler arasında gösterilen Bingöl - Karlıova civarı için de modeller test edilmiştir. Tüm sonuçlar çalışma içerisinde karşılaştırılmış ve yorumlanmıştır.







2. DOĞAL AFETLER

2.1 Tanımı

Doğal afetler, genellikle insanların kontrolü dışında vuku bulan, gerçekleşme konumuna, şiddetine ve benzeri parametrelere bağlı olarak neden olduğu hasarların değişiklik gösterdiği tehlike addeden olaylardır. Bu olayların neticesinde ulusal ya da uluslararası boyutlarda can ve uzuv kayıpları, maddi kayıplar ve çevresel kayıpların yaşanması olağandır. Şahıslar ve ülkeler önleyebilecekleri kadarıyla doğal afetlerin kayıplarını önlemek adına bilinçlendirme çalışmaları, acil durum tatbikat ve hazırlıkları, yardım çalışmaları, sivil savunma gibi önlemler alır.

2.2 Çeşitleri

Afet Araştırma ve Epidemiyoloji Merkezi (CRED) tarafından yapılan sınıflandırmada doğa kaynaklı afetler 6 farklı başlık altında sınıflandırılmıştır. Bu sınıflar; jeofiziksel, hidrolojik, meteorolojik, klimatolojik, biyolojik ve dünya dışı olarak karşımıza çıkmaktadır [1]. Şekil 2.1’de bu sınıflandırma görülmektedir.

					
Jeofiziksel	Hidrolojik	Meteorolojik	Klimatolojik	Biyolojik	Dünya Dışı
Deprem	Sel	Fırtına	Kuraklık	Hayvan Kazası	Etki
Kütle Hareketi (Kuru)	Heyelan	Ekstrem Sıcaklık	Buzul Gölü Patlaması	Salgın	Uzay Havası
Volkanik Aktivite	Dalga Etkisi	Sis	Tahrip Edici Kırsal Yangın	Böcek İstilas	

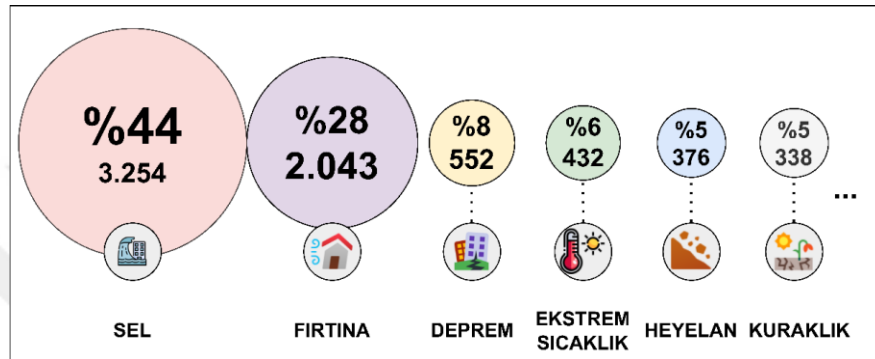
Şekil 2.1 : CRED’e göre doğal afet çeşitleri [1].

Ülkeler buldukları koşullar nedeniyle bazı doğal afetleri hiç yaşamıyorken ya da daha az yaşıyorken, diğer doğal afetler ile daha sık karşılaşabilmektedir. Bu da her ülkede farklı doğal afetlerin farklı önem derecesine sahip olmasına neden olmaktadır. Ülkemizde deprem, sel, çığ, yangın gibi doğal afetlerle sıkça karşılaşılabilirken tsunami, kasırga gibi doğal afetler oldukça nadir görülmektedir.

2.3 Görülme Sıklığı ve Olası Etkileri

CRED'in acil durumlar veri tabanında (EM-DAT) [2] 2000-2019 yılları arasında dünya çapında 7348 doğal afet olayının rapor edildiği belirtilmiştir. Bu raporun içerdiği doğal afetlerin görülme sıklığı verileri Şekil 2.2'de gösterilmektedir.

Bu rapora göre 2000-2019 periyodu içinde Dünya genelinde 3254 sel, 2043 fırtına, 552 deprem, 432 ekstrem sıcaklık, 376 heyelan, 338 kuraklık olayı ve 353 diğer doğal afetler meydana gelmiştir [3].



Şekil 2.2 : Dünya genelinde en yaygın görülen doğal afetler (2000 - 2019) [3].

Bu afetler; 2000-2019 yılları arasında yaklaşık 1,23 milyon (yıllık ortalama 60 bin) can kaybına neden olurken toplamda da 4 milyardan fazla insanda bu afetlerden etkilenmiştir. Yaşanan ekonomik kayıp ise 2,97 trilyon USD'dir. Ayrıca her başlık özelinde bir önceki 20 yıllık periyoda göre artışın olduğu gözlemlenmektedir. Afetlerin neden olduğu etkiler Şekil 2.3'te gösterilmiştir.

	Rapor Edilen Afet Sayısı	Can Kaybı	Etkilenen İnsan Sayısı	Ekonomik Kayıplar (USD)
1980 - 1999	4.212	1.19 Milyon	3.25 Milyar	1.63 Trilyon
2000 - 2019	7.348	1.23 Milyon	4.03 Milyar	2.97 Trilyon

Şekil 2.3 : Doğal afetlerin 1980-1999 ve 2000-2019 yılları arasındaki etkileri [3].

Afetlerde yaşanan can kayıplarının büyüklüğü; afetin çeşidi, konumu, süresi, etkilenen nüfusun boyutu ve afete daha önceden ne kadar hazır olduğu olmak üzere birçok faktöre bağlıdır. 2000-2019 yılları arasında Dünya genelinde doğal afetlerin neden olduğu can kayıplarına bakacak olursak deprem başı çekmektedir.

3. DEPREM

3.1 Temel Kavramlar

3.1.1 Fay

Fay ya da kırık, iki kıta sahanlığının birbirlerine sürtünerek zıt yönlerde hareketleri sonucu oluşan yapıya verilen isimdir. Kırıkların uzunlukları boyunca jeolojik tabakalar iki ayrı blok halinde yer değiştirir. Fayların uzunlukları birkaç milimetreden başlayıp binlerce kilometreye kadar erişebilir [4].

Yer bilimciler, fayları sınıflandırmak için fayın yüzeye göre açısını (eğim olarak bilinir) ve fay boyunca kayma yönünü kullanırlar. Eğim düzlemi yönünde hareket eden faylar, eğim atımlı faylardır ve hareketlerine bağlı olarak normal veya ters (itme) olarak tanımlanırlar. Yatay olarak hareket eden faylar, doğrultu atımlı faylar olarak bilinir ve sağ yanal veya sol yanal olarak sınıflandırılır. Hem eğim atımlı hem de doğrultu atımlı hareket gösteren faylara eğik atımlı faylar denir [5].

3.1.2 Deprem

Yer kabuğu içindeki kırılmalar nedeniyle ani olarak ortaya çıkan titreşimlerin, dalgalar halinde yayılarak yeryüzünü sarsmasına deprem denir [6]. Deprem, yerleşim yerine olan uzaklığı, büyüklüğü, derinliği gibi parametrelere bağlı olarak büyük yıkıma neden olabilen ve kitlesel ölümle sonuçlanabilen bir doğal afettir.

Son zamanlarda teknolojinin gelişmesi itibariyle büyük depremlerin bile potansiyel zararları büyük oranda engellenebilmektedir. Buna rağmen depremler, dünyanın birçok noktasında kayıplara neden olmaya devam etmektedir. Bunun temel nedeni, çarpık kentleşme, yapılaşmada temel ilkelere uyulmaması ve bilinçsizliktir.

3.1.3 Öncü deprem

Daha büyük bir depremden önce gerçekleşen ve o depremle zaman ve mekan ilişkisi olan depremlerdir.

3.1.4 Artçı deprem

Daha büyük bir depremden sonra gerçekleşen ve o depremle zaman ve mekan ilişkisi olan depremlerdir.

3.1.5 Ana şok

Birbirleriyle zaman ve mekan olarak ilişkili olan bir dizi depremden en büyük olan depreme verilen addır. Diğer bir deyişle öncü depremler ile artçı depremler arasında meydana gelen ve bu depremlerin tümünden daha büyük olan depremdir.

3.1.6 Derinlik

Deprem enerjisinin ortaya çıktığı noktanın yeryüzüne olan en kısa uzaklığına denir.

3.1.7 Odak noktası

Odak noktası yerin içinde depremin enerjisinin ortaya çıktığı noktadır. Bu noktaya odak noktası veya iç merkez de denir. Gerçekte, enerjinin ortaya çıktığı bir nokta olmayıp bir alandır, fakat pratik uygulamalarda nokta olarak kabul edilmektedir [6].

3.1.8 Merkez üssü

Depremin odak noktasına en yakın olan yeryüzündeki noktaya merkez üssü denilmektedir. Diğer bir tabirle odak noktasının yeryüzüne olan izdüşümüdür.

3.1.9 Sismoloji

Sismoloji veya diğer bir tabirle deprembilim, jeofiziğin bir alt dalı olarak depremlerin ve yer hareketlerinin incelendiği bir bilim dalıdır.

3.1.10 Sismograf

Yer ses ve sarsıntılarını büyüklük, merkez, zaman ve süre özelliklerinde kaydederek depremlerin ölçümünde kullanılan cihazlara verilen addır.

3.1.11 Sismisite

Depremlerin alansal ve zamana bağlı olarak dağılımıdır [7].

3.1.12 Büyüklük ve şiddet

Büyüklük veya magnitüd, depremin kaynağında meydana gelen kırılma sonucunda kırılan yüzeyin büyüklüğünü dolayısıyla açığa çıkan enerjinin düzeyini belirten bir ölçüdür [6]. Şiddet ise depremin yeryüzünde herhangi bir noktayı ne kadar etkilediğini belirtmek için kullanılan bir terimdir.

Deprem büyüklük ölçümü yapılırken kırılmalar yeraltında kaldığı için bu kırıkları gözle görmek mümkün değildir. Depremlerin yeryüzünde meydana getirdiği sismik dalga genliği gibi etkiler incelenerek depremin büyüklüğü hakkında bilgi sahibi olunabilir.

Depremlerin şiddetleri, uzun yılların verdiği tecrübeyle oluşturulmuş deprem şiddet cetvellerine göre değerlendirilmektedir. Deprem şiddet cetvellerinde şiddetler Romen rakamlarıyla ifade edilmektedir. Bugün kullanılan başlıca şiddet cetvelleri değiştirilmiştir. Bunlar, “Mercalli Cetveli (MM)” ve “Medvedev-Sponheur-Karnik (MSK)” şiddet cetvelidir [8].

Büyüklük değeri ölçüm yapılan yerden bağımsız iken, şiddet değeri ölçüm yapılan yere bağımlıdır. Yani ölçüm yeri değişse bile büyüklük aynı kalırken, şiddet değeri değişiklik göstermektedir.

Depremin büyüklüğü ve şiddetinin deneysel olarak birtakım bağıntıları çıkarılmıştır. Bağıntılardan büyüklük ve şiddet dönüşümleri Çizelge 3.1’deki gibi verilebilir.

Çizelge 3.1 : Büyüklük ve şiddet dönüşüm tablosu ([8]’den alınmıştır).

Şiddet	Ritcher Büyüklüğü
IV	4
V	4,5
VI	5,1
VII	5,6
VIII	6,2
IX	6,6
X	7,3
XI	7,8
XII	8,4

3.1.12.1 Büyüklük türleri

Yerel (lokal) büyüklük (MI)

Depremlerin büyüklüğünü ölçmek için ilk önerilen yöntem olan yerel büyüklük ölçeği, 1935 yılında Charles Richter tarafından meydana getirilmiştir. Depremin meydana

getirdiđi ses dalgalarının oluřturduđu en yksek genlik deđerinin uzaklık ile llendirilmesiyle depremin byklđ hakkında bilgi edilebilir. Byklđ 6,0'dan az ve uzaklıđı 700 kilometreden az depremler iin kullanılır.

Sreye bađlı byklk (Md)

Depremin, sismometre zerinde ne kadar uzun sreli bir titreřim oluřturduđu llr ve deprem merkezinin uzaklıđı ile leklenir. Bu yntem byklđ 5,0'den az ve 300 kilometreden yakın depremler iin kullanılır [9].

Yzey dalgası byklđ (Ms)

Yzey dalgalarının genliđi baz alınarak hesaplanan byklk trdr [10].

Cisim dalgası byklđ (Mb)

Herhangi bir uzaklıkta, herhangi bir aletle kaydedilen bir depremin cisim dalgalarından yararlanarak bir byklk tanımı geliřtirmişlerdir. Blgesel uzaklıkların tesinden gelen (telesismik), depremlerin cisim dalgalarından yararlanarak hesaplanan byklk trne cisim dalgası byklđ denmektedir [11].

Moment byklđ (Mw)

Thomas C. Hanks ve Hiroo Kanamori tarafından 1979 yılında geliřtirilen bu yntem deprem byklđn lmede sismik momentin hesaplanmasına dayalıdır. Gl (8,0'den byk) depremlerin byklklerini hesaplama da en gven duyulan lektir.

3.1.13 Tsunami

Genellikle depremlerle birlikte anılan tsunami, deprem gibi tektonik olayların okyanus ya da deniz tabanında meydana gelmesi ve bu olayların aıđa ıkardıđı enerjinin denize gemesiyle birlikte oluřan uzun periyotlu dalgalara verilen addır. Tsunamiye lkemizde ok sık rastlanılmamaktadır.

3.2 Depremin Olası Etkileri

Depremlerin etkileri bařta byklđ ve meydana geldiđi evrenin yapı stođu olmak zere eřitli etmenlere bađlıdır. Depremler saniyelerce srmesine rađmen, depremin etkisi on yıllarca atlatılamayan zararlara yol aabilir. Depremlerin olası etkileri birok bařlık altında incelenebilir. Depremlerde insan sađlıđı ve yapıların etkilenmesi diđer etkilerinde nn amaktadır.

3.2.1 Depremlerin sađlık ve sađlık sistemi üzerindeki etkileri

Depremın meydana getirdiđi yıkım ile sađlık sisteminin ana unsurlarından olan sađlık yapıları hasar görebileceđi için sađlık sistemi bölgesel olarak sekteye uğrayabilir. Deprem ile öngörülemez şekilde artan yaralı ve ağır yaralı insanlara tıbbi aksiyon konusunda önceden uygun planlama yapılmamışsa ve gerekli tıbbi müdahalelerde yeterli olunmaz ise insan sađlığı doğrudan olumsuz etkilenebilir. Depremi kendisi, yakını yaşayanlar ya da deprem olabileceđi korkusu içinde olan kişiler; kaygı, stres, korku, içe kapanma, öfke gibi çeşitli duyguları sürekli yaşayabilecekleri depresyon, bipolar bozukluk gibi duygudurum bozuklukları yaşayabilirler. Kısa ve net olarak deprem sađlık sistemini ve insan sađlığını doğrudan olarak olumsuz etkilemektedir.

3.2.2 Depremın ekonomi üzerindeki etkileri

Depremın meydana getirdiđi yıkım ile fiziki ve emek kayıpları yaşanabilir. İnsan, yapı, makine, ham madde gibi üretimi oluşturan ana unsurların zarar görmesi ile birlikte üretim sekteye uğrayabilir ve işsizlik oranı artabilir. Doğrudan bölgesel ve dolaylı olarak ulusal üretimin azalmasıyla birlikte enflasyonda artış olmasına, yerel para biriminin değer kaybetmesine neden olabilir. Yeniden imar ve kalkınma çalışmaları için ayrılacak olan bütçeyle birlikte cari açık, faizle borçlanma gibi ekonomik sorunlara yol açabilir.

3.2.3 Depremın çevre üzerindeki etkileri

Depremın meydana getirdiđi yıkım ile karada, denizde ve havada hayvan ölümleri, yaralanmaları gerçekleşebilir. Tarım arazilerinde çökme, kayma ve derin çatlaklar gibi olaylar görülebilir. Bitki örtüsü hasar görebilir. Bu da bitki ve hayvan çeşitliliğinin azalmasına, besin zincirinin bozulmasına neden olabilir. Su kaynaklarına zararlı bileşenler karışabilir ya da su kaynakları toprađa karışabilir. Deprem atıkları toprađa, suya ve havaya karışarak bu yerlerde toprak, su ve hava kirliliğine neden olabilir.

3.2.4 Depremın eğitim sistemi üzerindeki etkileri

Depremın meydana getirdiđi yıkım ile öğretmen, öğrenci gibi insan unsurları ile okul ve materyal gibi yapısal unsurlar zarar göreceđi için eğitim sekteye uğrayabilir. Depremden sonra eğitim hizmetleri aksayabileceđi gibi depremin etkileri atlatılana kadar eğitim kalitesi eskisi kadar verimli olmayabilir. Öğrenci sayısında düşüş gözlemlenebilir.

3.2.5 Depremın turizm üzerindeki etkileri

Depremın meydana getirdiđi yıkım ile tarihi yapılar, dođal yapılar, ticari merkezler, eğlence mekanları, konaklama alanları, sađlık, spor ve kültürel tesisler zarar görebilir. Turizm için önemli olan bu yapıların zarar görmesiyle birlikte turizm verilerinde büyük azalış ve hatta bir süreye kadar yok oluş gözlemlenebilir.

3.3 Meydana Gelen Depremlerin Bilançosu

Depremlerin meydana getirdiđi tahribat depremin büyüklüğüyle, depremin meydana geldiđi yerin yerleşim yerlerine olan uzaklığıyla, meydana geldiđi gün ve saatiyle, meydana geldiđi çevrenin yapı stođunun durumuyla, ulusal ve bireysel olarak alınan önlem ve yapılan hazırlık ile dođru orantılıdır. Bu ve buna benzer maddeler depremin bilançosunun artış ya da azalma göstermesini etkilemektedir. En büyük depremler en büyük zarara yol açar fikri kesin dođruluk taşımaz. Tarihte çok büyük depremlerin çok küçük zararlarla atlatıldığına rastlanılabilir. Aksi şekilde çok büyük olmayan depremler, kendilerinden umulmayan zararlar bırakabilirler.

3.3.1 Dünya genelinde meydana depremlerin bilançosu

Dünya genelinde son 100 yılda meydana gelen büyüklüğü en yüksek 10 adet depreme ve bilançolarına ait veriler Çizelge 3.2’de gösterilmiştir.

Çizelge 3.2 : Dünya genelinde meydana gelen depremlerin bilançosu (Veriler [12]’den alınmıştır).

Yer	Tarih	Büyükük	Can Kaybı	Toplam Hasar (Milyon Dolar)
Valdivia, Şili	22.05.1960	9.5	2226	1000
Alaska, ABD	28.03.1964	9.2	139	400
Sumatra, Endonezya	26.12.2004	9.1	227899	10000
Honshu, Japonya	11.03.2011	9.1	18428	220136,6
Kamçatka, Rusya	04.11.1952	9.0	10000	1
Bio-bio, Şili	27.02.2010	8.8	558	30000
Alaska, ABD	04.02.1965	8.7	-	0,01
Assam, Tibet	15.08.1950	8.6	1530	20
Sumatra, Endonezya	28.03.2005	8.6	1319	37,36
Sumatra, Endonezya	11.04.2012	8.6	10	-

3.3.2 Türkiye’de meydana gelen depremlerin bilançosu

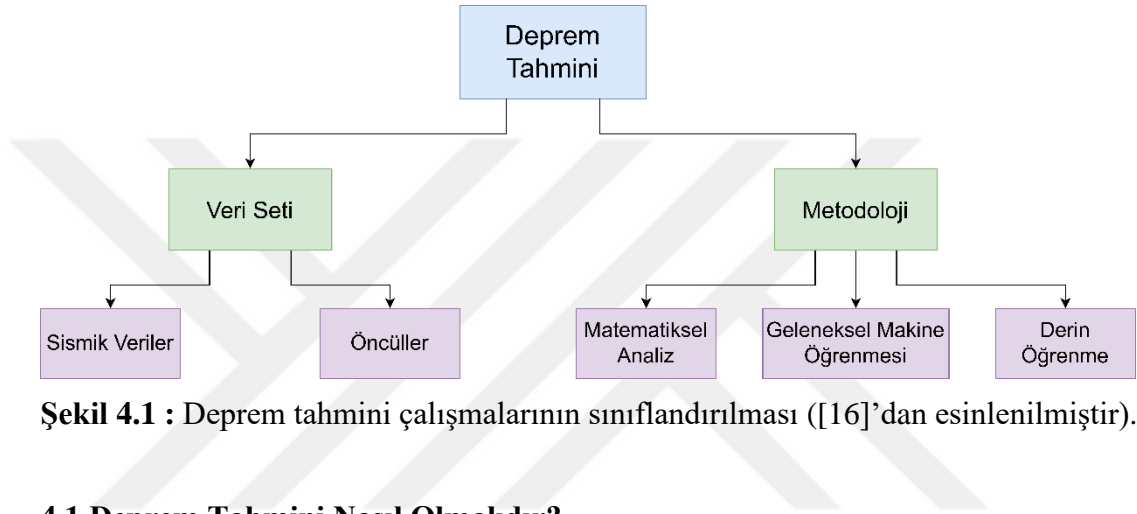
Türkiye’de meydana gelen büyüklüğü en yüksek 10 adet depreme ve bilançolarına ait veriler Çizelge 3.3’de gösterilmiştir.

Çizelge 3.3 : Türkiye’de meydana gelen depremlerin bilançosu (Veriler aksi belirtilmedikçe [13]’ten alınmıştır).

Yer	Tarih	Büyükük	Can Kaybı	Hasarlı Bina
Erzincan	27.12.1939	7,9	32968	116720
Gölcük, Kocaeli	17.08.1999	7,8	17480	73342
Maraş Depremleri	06.02.2023	7,7	62013 [14]	326895 [15]
Muradiye, Van	24.11.1976	7,5	3840	9232
Düzce	12.11.1999	7,5	763	35519
Mürefte, Tekirdağ	09.08.1912	7,3	216	5540
Türk – İran Sınırı	07.05.1930	7,2	2514	-
Ladik, Samsun	27.11.1943	7,2	4000	40000
Gerede, Bolu	01.02.1944	7,2	3959	20865
Yenice, Çanakkale	18.03.1958	7,2	265	6750

4. DEPREM TAHMİN ÇALIŞMALARI

Deprem tahmini üzerine mevcut çalışmalar, kullanılan veri setlerine göre 2'ye, kullanılan metodolojiye göre 3'e ayrılabilir. Şekil 4.1'de deprem tahmin çalışmalarının sınıflandırılması gösterilmiştir.



Şekil 4.1 : Deprem tahmini çalışmalarının sınıflandırılması ([16]'dan esinlenilmiştir).

4.1 Deprem Tahmini Nasıl Olmalıdır?

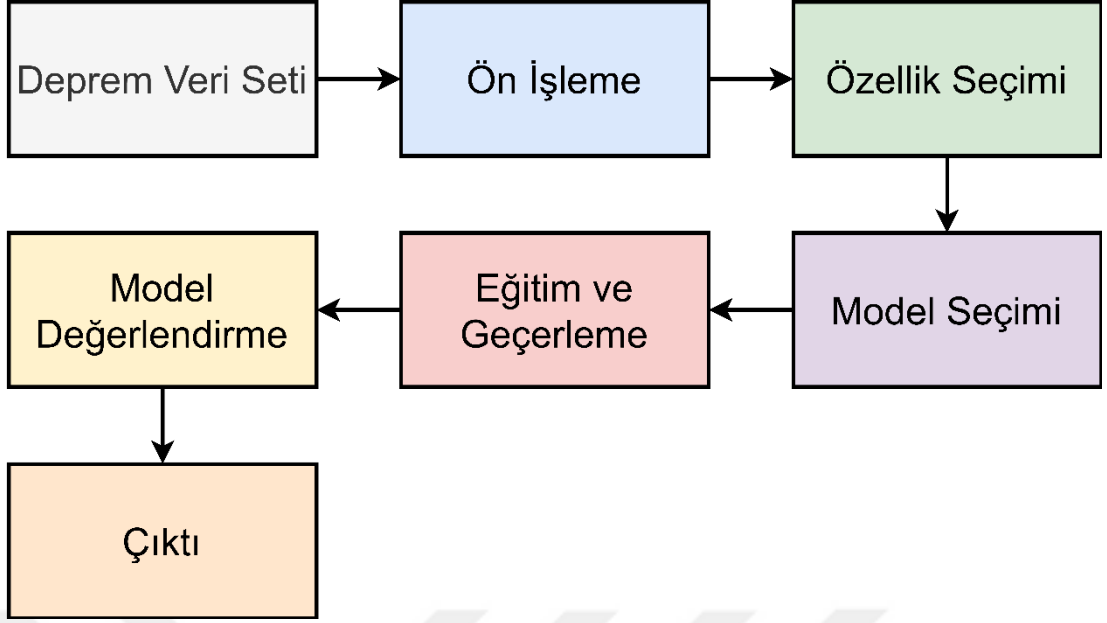
Deprem tahmini, asgari olarak geleceğe yönelik olarak tahmin edilen depremin büyüklüğü, yeri ve zamanını içerecek şekilde yapılmalıdır. Bu tahminler zamansal olarak kısa vadeli ve uzun vadeli süreçler olarak sınıflandırılabilir.

Kısa vadeli süreç, bir depremi meydana gelmeden birkaç gün veya hafta önce tahmin eder ve özellikle tahliye süreci için faydalıdır.

Uzun vadeli süreç ise bir depremi meydana gelmeden birkaç ay veya yıl önce tahmin eder ve yapı stoğunun yenilenmesi gibi geniş çaplı önlemler alınabilir.

4.2 Deprem Tahmini Süreci

Deprem tahmin süreci çalışmadan çalışmaya değişiklik gösterebiliyor olmasına karşın genel olarak 7 farklı adımdan oluşmaktadır. Şekil 4.2'de deprem tahmin süreci gösterilmiştir.



Şekil 4.2 : Deprem tahmin süreci.

4.2.1 Veri setleri

Deprem tahmini için oluşturulan veri setleri içerisinde en azından depremin meydana gelme yeri (enlem, boylam), büyüklüğü ve zamanı ile ilgili sismik verileri içermelidir.

Hemen hemen her ülkenin kendi topraklarında gerçekleşen depremlere ait canlı ve geçmiş verileri yayınlamakla görevli resmi bir kurumu bulunmaktadır. Depremlere ait veriler bu kurumlardan temin edilebilir. Ülkeler ve ülkelere ait bu kurumlar Çizelge 4.1’de gösterilmektedir.

Bununla birlikte geçmiş deprem verileri kaggle, data.world gibi popüler sitelerden de temin edilebilir.

Çizelge 4.1 : Ülkeler ve deprem verilerini yayınlayan kuruluşlar.

Ülke	Resmi Kurum
Türkiye	Afet ve Acil Durum Yönetimi Başkanlığı
Çin	Çin Deprem Ağı Merkezi
Japonya	Japonya Meteoroloji Ajansı
İran	İran Sismoloji Merkezi
ABD	ABD Jeoloji Araştırmaları Kurumu
Uluslararası	Uluslararası Sismoloji Merkezi

4.2.2 Veri ön işleme

Veri ön işleme, model eğitime tabi tutulmadan yani öğrenme süreci başlamadan önce modelin öğrenme başarısı ve verimliliğini artırmak amacıyla veri seti üzerinde yapılan iyileştirmeye yönelik birtakım çalışmalardır. Bu iyileştirme çalışmaları dört farklı başlık altında incelenebilmektedir.

Deprem tahmini çalışmasında veri setinde sadece sismik veriler kullanılmışsa ön işleme adımında genel olarak boş değerlerin tespitine aksiyon alınmasıyla birlikte normalizasyon adımları gerçekleştirilir. Öncüller kullanılmışsa aşağıda sayılan başlıkların altında yer alan çeşitli ön işleme adımları kullanılabilir.

4.2.2.1 Veri temizleme

Veriler doğası gereği aykırı değerler içerebildiği gibi veri setlerinin oluşumu sırasında yaşanan hatalar nedeniyle de alakasız, yanlış ve eksik değerler içerebilir. Bunun dışında veri seti içerisinde bir grup veri tekrar ediyor olabilir. Veri temizleme, bu özelliklere sahip verilerin tespit edilip temizlendiği ve makine öğrenmesi modeli tarafından işlemeye uygun hale getirildiği aşamalardır.

4.2.2.2 Veri birleştirme

Çalışma için hazırlanmış veri seti yeterli veri içermiyor, kapsamı dar kalıyor olabilir ya da daha kapsamlı bir çalışma ile daha başarılı ve geçerli sonuçlar üretmek isteniyorsa aynı problem için oluşturulmuş veri setlerinin birleştirilmesi faydalı olabilir. Veri birleştirme, bu tür sorunlara çözüm olarak aynı problem için oluşturulmuş veri setlerinin birleştirilmesini içerir. Veri birleştirme sonrası daha kapsamlı ve daha başarılı bir çalışma elde edilebilir.

4.2.2.3 Veri dönüştürme

Veri dönüştürmede veri seti içerisindeki verilerin tahmin operasyonlarına uygun şekilde dönüştürülmesi sağlanır [17].

4.2.2.4 Veri indirgeme

Veri setleri bazen oldukça fazla veri içerebilmektedirler. Bu haliyle makine öğrenmesi modelleri zaman ve hafıza bakımından verimli çalışmayabilir. Veri indirgeme işlemi, verimlilik için veri setinin daha az veriyle temsil edilmesi işlemidir.

4.2.3 Özellik seçimi

Özellik seçimi, orijinal veri setini temsil edebilecek en iyi altkümenin seçimi olarak tanımlanmaktadır. Özellik seçimiyle birlikte algoritmanın hızı artar, ilgisiz ve gürültülü veri ortadan kalkar, veri kümesi daha basit bir şekilde tanımlanabilir, görselleştirilebilir ve anlaşılabilir, veri depolamak için gerekli olan hafıza miktarı azalır ve elde edilen modelin başarısı artabilir [18].

Öznelik seçim metotlarının büyük bir kısmı 3 ana kategoriye ayrılabilir.

Deprem tahmini çalışmalarına baktığımızda veri seti olarak sadece sismik veriler kullanıldığı takdirde veri seti içerisinde çok fazla özellik olmaması ve her bir özelliğin önem atfetmesi sebebiyle genelde özellik seçim uygulanmamaktadır. Veri seti içerisinde öncüller kullanıyorsa kullanılan öncüle göre aşağıdaki özellik seçimi yöntemlerine ait alt yöntemlerden birisi uygulanabilir.

4.2.3.1 Filtreleme yöntemleri

Özneliklerin önemini hesaplamak için öznelik ile hedef değişken arasındaki ilişkiyi dikkate alan yöntemlerdir [19].

4.2.3.2 Sarmalayıcı yöntemler

Sarmalayıcı yöntemler, bir alt özellik grubuna sahip modeller oluşturur ve model performanslarını ölçer [19].

4.2.3.3 Gömülü yöntemler

Öznelik seçimi, bazı makine öğrenimi modellerinin sağladığı iç görülerle de elde edilebilir. Örneğin, Lasso ve RF algoritmalarının kendilerine ait öznelik seçim metotları bulunmaktadır [19]. Bu yapıdaki özellik seçim yöntemleri gömülü yöntemler olarak adlandırılabilir.

4.2.4 Model seçimi

Deprem tahmini çalışmaları için model seçerken üç farklı ana başlık karşımıza çıkmaktadır. Bunlar matematiksel analiz yöntemleri, geleneksel makine öğrenmesi yöntemleri ve derin öğrenme yöntemleridir. Model seçimindeki genel yargılar şu şekildedir:

Matematiksel analiz yöntemleri kısıtlı verilerle çalıştıkları ve düşük başarı sonuçları elde ettikleri için [20,21] pek fazla tercih edilmemektedirler.

Kullanımının kolay olması itibariyle geleneksel makine öğrenmesi, deprem tahmininde kullanılan önemli yöntemlerden birisidir.

Derin öğrenme yöntemleri çok yüksek karmaşıklığa ve analizi çok sayıda faktöre bağlı problemleri çözmeye başarısını kanıtlanmış olmasından mütevellit deprem tahmini konusunda da en iyi çözümü üretmişlerdir [16,22]. Son zamanlarda oldukça popülerdir.

4.2.5 Eğitim ve değerlendirme

Makine öğrenmesi modellerinde eğitimin temel hedefi, modelin mevcut veri setiyle en iyi genellemeyi yaparak yüksek doğrulukta tahminler yapmasını sağlamaktır.

Çapraz doğrulama ise parametre ayarlama sırasında eğitim setinin her seferinde farklı bir kısmı ile doğrulama yapma işlemine denir. Örnek ile açıklamak gerekirse, veri setinin seçilen orandaki kısmı test seti olarak ayrıldıktan sonra kalan kısmın ilk %25'lik kısmını ilk model eğitiminde, ikinci %25'lik kısmını ikinci model eğitiminde şeklinde sırası ile uygulanarak tüm kısımlar hem doğrulama hem eğitim sırasında kullanılır. Bu sayede doğrulama setinin doğru şekilde seçilip seçilmediği kaygısı ortadan kalkar, parametre seçimi ise her bir çapraz doğrulama seti ve eğitim seti ile ölçülen metrik skorlarının ortalaması alınarak yapılır [23].

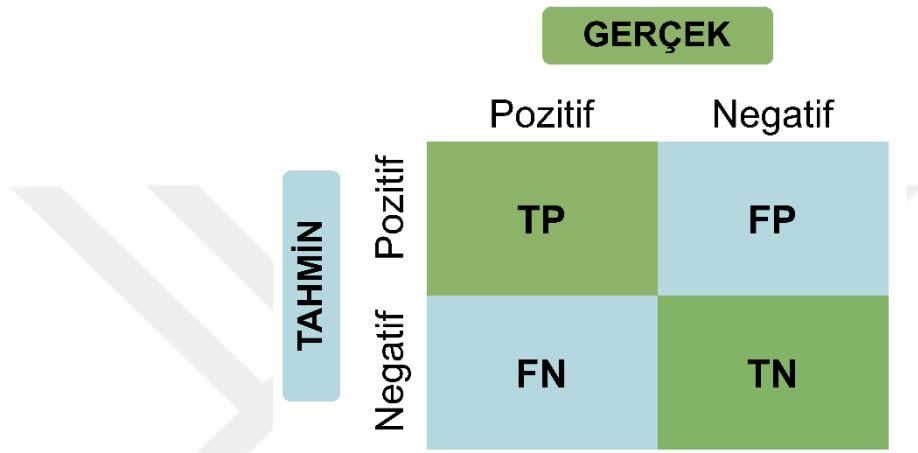
4.2.6 Model değerlendirme

Çeşitli amaçlar için geliştirilmiş olan makine öğrenmesi modellerinin başarı oranlarını ölçmeye model değerlendirme denilmektedir. Geliştirilen model bir regresyon problemini çözmeyi amaçlayabildiği gibi bir sınıflandırma problemini çözmeyi de amaçlayabilir. Bu da modeli değerlendirmede kullanılan metrikleri doğrudan etkilemektedir. Her problemin kendine özgü değerlendirme metriği bulunmaktadır.

4.2.6.1 Sınıflandırma problemlerinde model değerlendirme

Sınıflandırma problemlerinde model değerlendirmede sıklıkla karışıklık matrisi kullanılmaktadır. Karışıklık matrisi, bir modelin performansını değerlendirmek için kullanılan ve görsel olarak bir tablo şeklinde temsil edilen bir araçtır. Veri uzmanlarına, modelin performansı, hataları ve zayıflıkları hakkında daha derin bir

anlayış sağlar [24]. Karışıklık matrisi dört farklı hücreden oluşmaktadır. Burada gerçek pozitifler (TP), kaydedilen depremlerin sayısı ile eşleşen tahmin edilen depremlerin sayısıdır. Gerçek negatifler (TN), gerçek bir deprem olmadığında, tahmin edilen bir deprem olmadığının öngörüsü ile meydana gelir. Model, gerçek bir deprem olmadığında bir deprem öngörüyorsa buna yanlış pozitif (FP) denir ve yanlış negatif (FN), modelin bir deprem olduğunda deprem olmadığını öngördüğünü gösterir. Şekil 4.3'te karışıklık matrisi gösterilmiştir.



Şekil 4.3 : Karışıklık matrisi.

Karışıklık matrisinde yer alan hücreler kullanılarak, birden fazla ölçüt çıkarılabilir. Duyarlılık, kesinlik, özgüllük, f-skör, Matthew korelasyon katsayısı (MCC) ve doğruluk bunlardan birisidir. Bu ölçütlerin bazı durumlarda tek başına kullanılmaları yeterli olmayabilir. Birden fazla ölçütün bir arada kullanılması sonuçların daha net ve daha doğru olduğunu gösterebilir.

Doğruluk ölçütü modelin doğru tahminlerinin toplam tahminine oranıyla elde edilmektedir. Doğruluk ölçütü, problemde tahmin edilen hedef veri sınıflarının dengesiz dağılım gösterdiği durumlarda yetersiz kalmaktadır. Diğer ölçütlerle birlikte kullanılması daha doğru ölçümler ortaya çıkarır. Denklem 4.1'e göre hesaplanmaktadır.

$$ACC = \frac{TP+TN}{TP+TN+FP+FN} \quad (4.1)$$

Kesinlik pozitif olarak tahminlediğimiz değerlerin gerçekten kaç adedinin pozitif olduğunu göstermektedir. Kesinlik değeri özellikle yanlış pozitif tahminlemenin

maliyeti yüksek olduğu durumlarda çok önemlidir [25]. Denklem 4.2'ye göre hesaplanmaktadır.

$$\text{Kesinlik} = \frac{TP}{TP+FP} \quad (4.2)$$

Duyarlılık değeri yanlış negatif olarak tahminlemenin maliyetinin yüksek olduğu durumlarda bize yardımcı olacak bir ölçüttür. Mümkün olduğunca yüksek olması gereklidir [25]. Denklem 4.3'e göre hesaplanmaktadır.

$$\text{Duyarlılık} = \frac{TP}{TP+FN} \quad (4.3)$$

Özgüllük, gerçek negatif oran olarak ifade edilir ve bir testte negatif sonuç veren gerçekten de negatif olan örneklerin oranıdır [26]. Denklem 4.4'e göre hesaplanmaktadır.

$$\text{Özgüllük} = \frac{TN}{TN+FP} \quad (4.4)$$

F-skor değeri bize kesinlik ve duyarlılık değerlerinin harmonik ortalamasını göstermektedir. Basit bir ortalama yerine harmonik ortalama olmasının sebebi ise uç durumları da gözardı etmememiz gerektiğidir [25]. Denklem 4.5'e göre hesaplanmaktadır.

$$F1=2 * \frac{\text{Kesinlik} * \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} \quad (4.5)$$

MCC, dengesiz bir veri kümesi durumunda kullanılan popüler bir performans ölçüsüdür. MCC değeri -1 ile +1 aralığında değişir. MCC değeri 1'e yakınsa daha iyidir [27]. Denklem 4.6'ya göre hesaplanmaktadır.

$$\text{MCC} = \frac{(TP * TN) - (FP * FN)}{\sqrt{(TP+FP)(TP+FN)(TN+FP)(TN+FN)}} \quad (4.6)$$

4.2.6.2 Regresyon problemlerinde model değerlendirme

Regresyon problemlerinde ortalama mutlak hata (MAE), ortalama mutlak yüzde hata (MAPE), ortalama hata karesi (MSE) ve R-kare (R^2) modellerin performanslarını değerlendirmek için yaygın olarak kullanılan ölçütlerdir. Bu ölçütlerin

hesaplanmasında kullanılan formüllerde yer alan sembollerden n gözlem sayısını, y_i i 'inci gözlemin gerçek değerini, \hat{y}_i ise i 'inci gözleme ait tahmin edilen değeri temsil etmektedir.

MAE, bir dizi tahmindeki hataların ortalama büyüklüğünün bir ölçüsünü sağlar. Denklem 4.7'ye göre hesaplanmaktadır.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (4.7)$$

MAPE, bir dizi tahmindeki hataların ortalama büyüklüğünün ölçüsünü yüzdesel olarak sağlar. Denklem 4.8'e göre hesaplanmaktadır.

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (4.8)$$

MSE, MAE gibi bir dizi tahmindeki hataların ortalama büyüklüğünün bir ölçüsünü sağlar, ancak MSE daha büyük hatalara daha yüksek bir ağırlık verirken, MAE tüm hataları eşit olarak ele alır. Denklem 4.9'a göre hesaplanmaktadır.

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (4.9)$$

R-kare, bir regresyon modelindeki bağımsız değişken veya değişkenler tarafından açıklanan bağımlı değişkene ait varyansın oranını temsil eden istatistiksel bir ölçüdür [28]. Denklem 4.10'a göre hesaplanmaktadır.

$$R^2 = 1 - \frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (4.10)$$

Genel olarak, MAE, MAPE ve MSE için daha düşük değerler ve R-kare için daha yüksek değerler daha iyi performans gösteren bir modele işaret eder.

4.3 Örnek Çalışmaların İncelenmesi

4.3.1 Tek algoritma kullanan çalışmaların incelenmesi

Kannan [20], 2014 yılında enlem, boylam ve büyüklük değişkenlerini ve poisson dağılımı ile mesafe faktörünü kullanarak depremleri tahmin etmeye çalışmıştır.

Wang ve diğerleri [16], 2017 yılında deprem tahmini yapmak için USGS (Amerika Birleşik Devletleri Jeoloji Araştırmaları Kurumu)'den aldıkları 1966'dan 2016'ya kadar olan ve büyüklüğü 4,5'ten büyük olan Çin deprem verilerini (zaman, enlem, boylam, büyüklük) ve LSTM algoritmasını kullanarak Çin ankarasında deprem olup olmadığı tahmininde %87,59 doğruluk elde etmişlerdir.

Huang ve diğerleri [22], 2018 yılında geçmiş dönemdeki 30, 60, 90, 120, 150, 180 ve 210 günlük verileri kullanarak önümüzdeki 30 gün içindeki en büyük deprem büyüklüğünü tahmin etmek için Çin Sismik Bilgisi web sitesinden edindikleri verileri (zaman, enlem, boylam, büyüklük) ve CNN modelini kullanmışlardır. En iyi sonucu geçmiş 120 günlük verileri kullandıkları senaryoda R-skor metriğinde 0,303 puan elde ederek etmişlerdir.

Vardaan vd. [29], 2019 yılında bir dizi geçmiş depremin verilerini kullanarak depremler ve eğilimlerini tahmin etmeye çalışmışlardır. Deprem dizisini modellemek için LSTM kullanmışlardır. Kullandıkları modeli sıradan bir ileri beslemeli sinir ağı (FFNN) ile aynı problem özelinde tarih bilgisi, derinlik, büyüklük, boylam ve enlem özelliklerinde karşılaştırmışlardır. Karşılaştırma sonucuna göre LSTM'nin R^2 skoru FFNN'ninkinden genel olarak %59 daha yüksektir.

Karimzadeh ve diğerleri [30], 2019 yılında artçı sarsıntıların mekansal tahminini yapabilmek için İran Sismoloji Merkezi'nden İran'da meydana gelen 7,3 büyüklüğündeki Kirmanşah Depremi'nin ilk saniyesinden itibaren, Eylül 2018'in sonuna kadar olan süreçteki 2,5'den büyük depremlere ait sismik verileri (kayma dağılımı, Coulomb gerilme değişimi ve komşu aktif fayların yerleri) ve Naive Bayes, k-en yakın komşular (kNN), destek vektör makinesi (SVM) ve RF makine öğrenmesi modellerini kullanmışlardır. Artçı sarsıntıların desen tahmininde Naive Bayes için %78, kNN için %58, SVM için %74 ve RF için %73 doğruluk elde etmişlerdir.

Murwantara vd. [31], 2020 yılında depremin yeri, derinliği ve büyüklüğünü tahmin etmek için USGS'den almış oldukları Endonezya'ya ait 30 yıllık sismik verileri (tarih,

saat, enlem, boylam, derinlik ve büyüklük) ve çoklu doğrusal regresyon, SVM, Naive Bayes modellerini kullanmışlardır. RMSE (kök ortalama kare hatası) metriği ile deprem büyüklüğü tahmininde çoklu doğrusal regresyon için 0,777235, SVM için 0,751008, Naive Bayes için 0,922814 puanlarıyla karşılaşmışlardır.

Bhatia vd. [32], 2023 yılında gerçek zamanlı jeolojik ve konumsal verileri kullanarak bulut ve uç bilişimi kullanan akıllı deprem izleme ve tahmin çerçevesi önermişlerdir. Önerilen sistem katmanlara dayalı tasarım içermektedir. İlk katmanda sensörler aracılığıyla jeolojik ve konumsal veriler toplanmaktadır. İkinci katman sismik tahmin için verilerin filtrelenmesini, özelliklerin çıkarılmasını, boyutların küçültülmesini ve olayların sınıflandırılmasını içerir. Üçüncü katman yararlı veri örneklerinin zamana dayalı olarak verimli bir şekilde çıkarılmasını sağlayan veri analiz katmanıdır. Depremlerin büyüklüğünü tahmin etmek için Uyarlanabilir Nöro-Bulanık Çıkarım Sistemi (ANFIS) mekanizmasını kullanmışlardır. ANFIS mekanizması girdi olarak enlem, boylam ve derinlik verilerini kullanır. Son katman ise bulut ve bilgi paylaşımı katmanıdır. Deneysel simülasyona dayanarak, ANFIS iterasyon sayısı 55 seçildiğinde test kümesinde R^2 için 0,807, RMSE için 0,804 ve MAE için 0,784 skorlarını elde etmiştir.

4.3.2 Hibrit ya da topluluk algoritmaları kullanan çalışmaların incelenmesi

Boucouvalas ve diğerleri [21], geçmişte meydana gelen Ridge ölçeğine göre 8,0'den büyük bir depremden önceki bir tarihteki gezegensel açıyı ve evirdikleri FDL (Fibonacci, Dual ve Lucas) yöntemini kullanarak gelecekteki Ridge ölçeğine göre 6,5'den büyük depremlerin başlangıç tarihlerini 1 günlük sapma ile yaklaşık %22 oranında tespit etmeyi başarmışlardır.

Khawaja vd. [33], 2018 yılında depremden on beş gün önce, büyüklüğü 5,0 ve üzerindeki depremleri tahmin etmek için sismik göstergeleri genetik programlama ve AdaBoost ile birleştirerek bir deprem tahmin sistemi önermişlerdir. Önerdikleri sistemi, USGS'den edindikleri Ocak 1980 - Aralık 2016 tarihleri arasında Güney Kaliforniya, Şili ve Hindikuş konumundaki depremlere ait sismik göstergeleri kullanarak test etmişlerdir. Test sonucunda önermiş oldukları model Hindikuş için %78,7, Şili için %84,5 ve Güney Kaliforniya için %86,6 doğruluk puanı elde etmişlerdir.

Majhi vd. [34], 2020 yılında deprem büyüklüklerini tahmin etmek için USGS'den, 5,5'den büyük tüm küresel depremlerin ayrıntılarını içeren veri setini ve güve alevi ile optimize edilmiş fonksiyonel bağlantı yapay sinir ağını (MFOFLANN) kullanmışlardır. RMSE ölçütü için 0,0565 skorunu elde etmişlerdir.

Salam vd. [35], 2021 yılında on beş gün boyunca deprem büyüklüğünü tahmin etmek için iki farklı hibrit makine öğrenmesi modeli önermişlerdir. İlk model, çiçek tozlaşma algoritması (FPA) ile aşırı öğrenme makinesinin (ELM) bir melezi olan FPA-ELM'dir. İkincisi, FPA ve en küçük kareler destek vektör makinesinin (LS-SVM) bir hibriti olan FPA-LS-SVM'dir. Bu iki hibrit modeli Güney Kaliforniya Deprem Merkezi'nden edindikleri sismik veriler üzerinde test etmişler ve en iyi sonucu 0,565476 RMSE skoruyla FPA-LS-SVM hibrit modeli vermiştir.

Kavianpour vd. [36], 2023 yılında tarihsel sismik verileri kullanarak bir sonraki aydaki depremlerin maksimum büyüklüğünü ve sayısını tahmin etmek için CNN, BiLSTM ve bir dikkat mekanizmasının yanı sıra sıfır dereceli tutma (ZOH) ön işleme metodolojisine dayanan bir derin öğrenme modeli kullanmışlardır. Kullandıkları yöntemi Çin'in dokuz farklı bölgesinden alınan bir deprem veri seti üzerinde test etmişlerdir. Test sonuçları, önerilen yöntemin performans ve genelleme açısından kıyaslanan diğer yöntemlerden daha iyi performans gösterdiğini ortaya koymuştur.

4.3.3 Ülkemiz özelinde gerçekleştirilen deprem tahmin çalışmaları

Can vd. [37], 2014 yılında Ocak 1900'den Aralık 2012'ye kadar Bilecik merkezli 100 km yarıçaplı bir alanda meydana gelen ve büyüklükleri en az 4,0 olan depremlerin yıllık frekanslarını Poisson-Hidden Markov Model kullanılarak modellemişlerdir. Daha sonra bu modeli kullanarak bölge çevresinde 2013'ten 2047'ye kadar gelecek 35 yıl için büyüklüğü 4'den yüksek depremlerin yıllık frekanslarını tahmin etmişlerdir.

Kaftan vd. [38], 2017 yılında Batı Türkiye'nin bir bölümüne ait 1975-2009 yılları arasında büyüklüğü 3'ten büyük olan deprem verilerini kullanarak, aylık deprem frekanslarını hesaplamışlar ve ardından elde edilen veri setini çok katmanlı algılayıcı sinir ağları (MLPNN) ve radyal tabanlı fonksiyon sinir ağları (RBFNN) olmak üzere iki sinir ağı ve ANFIS ile değerlendirmişlerdir. Sonuçlar, aylık deprem frekansı tahmini için önerilen RBFNN'nin gerçek verilerle daha yüksek korelasyon katsayıları ve daha küçük RMSE değerleri sağladığını göstermektedir.

Cekim vd. [39], 2021 yılında Türkiye'nin Doğu Anadolu Fayı'nda meydana gelecek bir depremin büyüklüğünü, büyüklüğü dört ve daha fazla olan önceki depremlere dayanarak, otoregresif bütünleşik hareketli ortalama (ARIMA) ve tekil spektrum analizi (SSA) olmak üzere iki zaman serisi yöntemiyle tahmin etmişlerdir. ARIMA ve SSA modellerini, 1900 ve 2019 yılları arasındaki sismolojik olaylardan kaynaklanan depremlerin büyüklüklerinin ortalama ve maksimum değerlerini eğitmek ve tahmin etmek için kullanmışlardır. Değerlendirme ölçütü olarak RMSE kullanmışlardır. ARIMA ortalama deprem büyüklüğü için 0,117, maksimum deprem büyüklüğü için 0,570 skor elde ederken, SSA ortalama deprem büyüklüğü için 0,108, maksimum deprem büyüklüğü için 0,541 skor elde etmiştir.

Doğan ve Demir [40], 2022 yılında deprem tahmini için yapısal tekrarlayan sinir ağlarını kullanarak mekansal yakınlığı ve bölgelerdeki fayların varlığı gibi yapısal özellikleri yakalayan yapısal tekrarlayan sinir ağı (SRNN) kullanan yeni modeller sunmuşlardır. Sunmuş oldukları modelleri USGS'den almış oldukları Çin deprem veri seti ile test ederek deneysel sonuçlar elde etmişlerdir. Çin için SMA, OneNeuron, LSTM ve önermiş oldukları SRNN modellerini test etmişlerdir. Test sonuçlarına göre kesinlik, duyarlılık ve f1-skor metriklerince genel olarak SRNN modelleri biraz daha iyi sonuçlar elde etmiş ve eğitim verileriyle aşırı uyum sağlamamaktadır.

5. İSTANBUL VE CİVARI İÇİN DEPREM EĞİLİMİ TAHMİNİ

5.1 İstanbul

5.1.1 Genel tarihi

İstanbul, Asya ve Avrupa kıtalarının bir kesişim noktası olarak yaklaşık 6 milyar insan arasında köprü vazifesi üstlenen bir dünya şehridir. Bugünkü temelleri 7. yy.da atılmıştır ve tarih öncesi çağlardan bu yana 7 büyük devlet tarafından yönetilmiştir. Bu devletlerden Roma, Bizans, Latin ve Osmanlı Devleti'ne yaklaşık 1600 yıl kadar başkentlik yapmıştır. Bu özelliği itibariyle 4. yy.dan bu yana dünyanın en büyük ve en önemli şehirleri arasında yer almıştır.

5.1.2 Coğrafi konumu

İstanbul 41° Kuzey Paraleli ile 29° Doğu Meridyeni arasında bulunur. İstanbul batıda Tekirdağ ve Kırklareli ile, doğuda Kocaeli ile komşudur. Kuzeyi Karadeniz, güneyi ise Marmara Denizidir. Yüzölçümü 5461 km²'dir. Asya ve Avrupa'yı 3 farklı köprü ile birbirine bağlamaktadır.

5.1.3 Ekolojik yapısı

İstanbul'un bazı kesimlerinde Karadeniz ikliminin, bazı kesimlerinde de Akdeniz ikliminin görülmesi ve toprak yapısı itibariyle oldukça zengin bitki çeşitliliği bulunmaktadır. Yaklaşık olarak 2500 bitki çeşidine ev sahipliği yapmaktadır. İstanbul, yüz ölçümünden yaklaşık olarak 10 kat büyük olan Hollanda'dan ve yaklaşık olarak 50 kat büyük olan İngiltere'den daha fazla bitki çeşidine sahiptir. Ayrıca 2500 bitki çeşidinden 56 tanesi endemiktir [41].

İstanbul konumu ve su kaynakları itibariyle pek çok havyana ev sahipliği yapmaktadır. İstanbul kıyısındaki denizlerde çeşit çeşit balık türleri görülmektedir. İstanbul 352 kuş türüne ev sahipliği yapmaktadır [42]. Bu kuşlardan bazıları göçmen bazıları ise kalıcı kuşlardır. Göçmen kuşlara kartal, şahin, doğan, atmaca, akbaba, leylek çeşitleri örnek verilebilir. Martılar, kumrular, güvercinler ve kargalar ise İstanbul'u yurt edinmiş kuşlara birer örnek olarak gösterilebilir.

5.1.4 Turizm

Birçok devlete ait miras ve izleri barındırması, ekolojik çeşitliliği, doğal yapıları, jeopolitik konumu itibariyle gelişen sanayi ve ürün çeşitliliği İstanbul'u tarihi, sosyal, kültürel, mimari ve benzeri alanlarda önemli bir şehir kılmıştır. Bu özellikleri sayesinde her yıl milyonlarca turist tarafından ziyaret edilmektedir. İstanbul İl Kültür ve Turizm Müdürlüğü'nün yayınlamış olduğu rapora göre 2023 yılında 49.209.180 yabancı Türkiye'ye giriş yaparken, İstanbul'a giriş yapan yabancı sayısı ise 17.370.030'dur [43]. Bu da Türkiye'ye giriş yapan yaklaşık her 3 kişiden 1'inin İstanbul'u tercih ettiğini göstermektedir.

5.1.5 Ekonomi

İstanbul mevcut ve potansiyel iş gücüyle birlikte kara, deniz ve hava ticaret yollarında uluslararası bir öneme sahip olması nedeniyle Türkiye'nin en büyük ve önemli şehir ekonomisidir. 2022 yılında TÜİK tarafından yayınlanan rapora göre 15 trilyon 6 milyar 574 milyon TL Türkiye gayri safi yurt içi hasılasının 4 trilyon 564 milyar 280 milyon TL'sini yani %30,4'ünü İstanbul oluşturmaktadır [44].

5.1.6 Nüfus yapısı

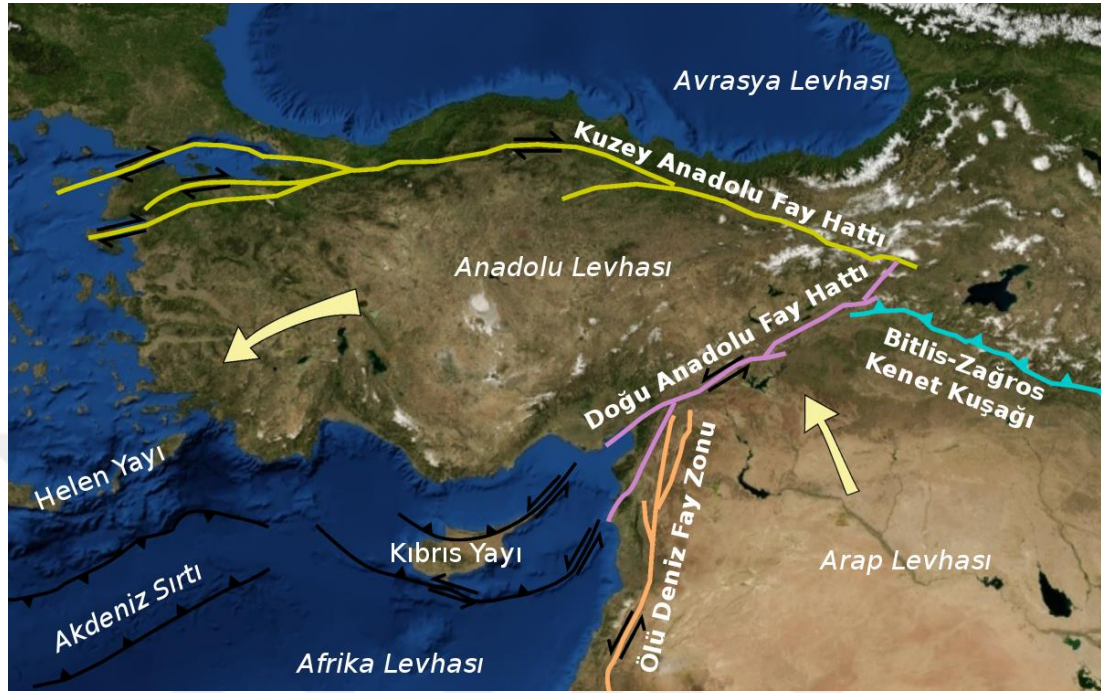
31 Aralık 2023 yılında TÜİK tarafından yayınlanan raporda Türkiye nüfusunun 85.372.377, İstanbul nüfusunun 15.655.924 kişi olduğu görülmüştür [45]. Türkiye'nin en kalabalık şehri İstanbul'dur. İstanbul yüzölçümü açısından Türkiye'nin yaklaşık olarak %7'sine tekabül ederken nüfus açısından Türkiye'nin yaklaşık olarak %17,33'üne denk gelmektedir. Bu veri İstanbul'da nüfusun ne denli yoğun olduğunu göstermektedir.

5.1.7 Sismoloji

İstanbul doğrudan bir fay hattı üzerinde bulunmayan bir şehir olmasına rağmen Marmara Denizi'nin altından geçen Kuzey Anadolu Fay hattının yaklaşık 200 km kuzeyinde yer almaktadır. Bu da İstanbul'u deprem kuşağı bir il yapmakta ve depremden etkilenebilir bir hale getirmektedir.

Kuzey Anadolu Fay hattı, Van Gölü'nden başlayarak Saros Körfezi'ne kadar uzanan 1100 km uzunluğunda dünyanın en hızlı hareket eden ve en aktif sağ-yanal atımlı faylarından biridir. Tek bir faydan oluşmaz, pek çok parçadan oluşan fay zonudur. Fay

hattında, parçalanmış-ezilmiş kayalar, soğuk ve sıcak su kaynakları, gölcükler, traverten oluşumları, genç volkan konilerine rastlanır [46]. Şekil 5.1’de ülkemizde bulunan fay hatları gösterilmiştir.



Şekil 5.1 : Ülkemizde bulunan fay hatları ([47]’den alınmıştır.).

Kuzey Anadolu Fay hattında 20. yy.dan bu yana meydana gelen ve beklenen İstanbul depremiyle alakalı olabilecek olan depremler Çizelge 5.1’de verilmiştir. Bu depremlerden ikisi 1999 yılında gerçekleşen Gölcük ve Düzce depremleridir.

Çizelge 5.1 : Beklenen İstanbul depremiyle alakalı olabilecek olan depremler (Veriler [13]’ten alınmıştır).

Tarih	Yer	Büyükölük	Şiddet	Can Kaybı	Hasarlı Bina
18.05.1929	Suşehri - Sivas	6,1	VIII	64	1357
27.12.1939	Erzincan	7,9	X - XI	32968	116720
20.12.1942	Erbaa - Tokat	7	IX	3000	32000
27.11.1943	Ladik - Samsun	7,2	IX - X	4000	40000
01.02.1944	Gerede - Bolu	7,2	IX- X	3959	20865
13.08.1951	Kurşunlu - Çankırı	6,9	IX	50	3354
26.05.1957	Abant – Bolu	7,1	IX	52	5200
19.08.1966	Varto – Muş	6,9	IX	2396	20007
22.07.1967	Mudurnu - Adapazarı	6,8	IX	89	7116
13.03.1992	Erzincan	6,8	VII	653	8057
17.08.1999	Gölcük - Kocaeli	7,8	X	17480	73342
12.11.1999	Düzce	7,5	IX	763	35519

Prof. Dr. Naci Görür, 1999’da meydana gelen Gölcük ve Düzce depremleri olduğu zaman önemli miktarda stresin Marmara’nın tabanındaki Kuzey Anadolu Fayı’nın

kuzey kolu içerisine yüklendiğini söylemiştir. Prof. Dr. Görür, Kuzey Anadolu'nun biriktirdiği atımın 5 metreyi bulduğunu, 5 metrelik bir atımın ise 7-7,5 büyüklüğünde depreme denk gelebileceğini belirtmiştir [48].

Tarihi kaynakların sunduğu veriler neticesinde İstanbul'da 7 ve üzeri büyüklükte depremlerin meydana geldiği bilinmektedir [49]. Bu depremlerle ilgili detaylı bilgiler ilgili kaynaklarda mevcuttur. Bu kayıtları ve tarihsel depremleri inceleyen araştırmacılar deprem hasar haritaları oluşturmuşlardır. İstatistiksel olarak 7'den büyük depremlerin tekrarlanma periyotlarının 250 yıl, 7 dolayında olanların ise 100 yıl olduğu kestirilmektedir [50]. İstanbul bu iki periyotu da tamamlamıştır ve yakın tarihte 7 ve üzeri büyüklükte bir deprem beklenmektedir.

5.1.8 Yapı stoğu

Dönemin Çevre, Şehircilik ve İklim Değişikliği Bakanı'nın 5 Aralık 2023 tarihinde yapmış olduğu açıklamaya göre İstanbul'da yaklaşık olarak 6 milyon konut ve yaklaşık olarak 1,5 milyon işyeri bulunmaktadır ve 600 bin konut çok riskli görülmektedir [51]. Prof. Dr. Görür'e göre İstanbul'da beklenen deprem 7,2-7,6 büyüklüğünde gerçekleşebilir ve bu büyüklük aralığında meydana gelen bir depremde 2,5 milyon insanın ölüme burun buruna kalabileceğini öngörmektedir [52]. Yıkım ve hasar konusunda öngörülen zarar sadece konut ve işyeriyle kalmamaktadır. İstanbul aynı zamanda birçok tarihi alana da ev sahipliği yapmaktadır. İstanbul Büyükşehir Belediyesi Kültür Varlıkları Daire Başkanı, İstanbul'da 35 bin tarihi alan olduğunu ve 20 bininin risk altında olduğunu paylaşmıştır [53].

5.2 Materyal ve Metot


5.2.1 Veri seti

Çalışmada kullanılan tarihsel sismik veriler İçişleri Bakanlığı Afet ve Acil Durum Yönetimi Başkanlığı Deprem Dairesi Başkanlığı tarafından yayınlanan deprem kataloğundan alınmıştır [54]. Veri seti yaklaşık son 25 yılda 40,316 ve 41,9295 enlemleriyle, 27,4266 ve 30,358 boylamları arasında meydana gelen depremlere ait verileri kapsamaktadır. Bu veri seti içerisinde 9871 depreme ait 8 özellik bulunmaktadır. Ayrıca depremleri kaydederken kullanılan istasyonlara ait ağ, enlem, boylam, sensor türü, yükseklik, il, ilçe, açılış tarihi ve kapanmış ise kapanış tarihi bilgilerine AFAD'ın istasyon kataloğundan erişilebilir [55]. Veri setine ait detaylar

Çizelge 5.2’de gösterilmektedir. Deprem veri setindeki özelliklere ait değerlerin zamansal gösterimi Şekil 5.2’de verilmiştir. Tarihsel depremler veri setine ait istatistikler Çizelge 5.3’te gösterilmektedir.

Çizelge 5.2 : Deprem veri setine ait detaylı bilgi.

Özellik Adı	Veri Tipi	Açıklama
Tarih(UTC)	Tarih/saat	Deprem meydana geldiği tarihi ve saati
Enlem	Ondalıklı sayı	Deprem meydana geldiği enlem
Boylam	Ondalıklı sayı	Deprem meydana geldiği boylam
Derinlik	Ondalıklı sayı	Deprem meydana geldiği derinlik
Rms	Ondalıklı sayı	Deprem genlik spektrumunun ortalama karekökü
Tip	Metinsel	Deprem büyüklüğünün tipi
Büyükük	Ondalıklı sayı	Deprem büyüklüğü
Yer	Metinsel	Deprem meydana geldiği yer
EventID	Tam sayı	Depreme ait benzersiz numara



Şekil 5.2 : Deprem veri setindeki özelliklere ait değerlerin zamansal gösterimi.

Çizelge 5.3 : Deprem veri setine ait istatistikler.

Özellik	Adet	Ortalama	Standard Sapma	En Küçük	En Büyük
Büyükük	10451	2,07	0,73	0	7.4
Enlem	10451	40,7	0,25	40,32	41,91
Boylam	10451	28,64	0,79	27,43	30,36
Derinlik	10451	8,11	3,93	0	76
Rms	10451	0,39	0,27	0	9,64

5.2.2 Veri ön işleme

Veri seti içerisindeki verilere iki ön işleme adımı uygulanmıştır. Bunlar: eksik veri tespiti ve veri normalizasyonudur.

5.2.2.1 Eksik veri tespiti

Eksik veriler, makine öğrenimi modellerinin sonuçlarını saptırabilir ve/veya modelin doğruluğunu azaltabilir. Bunun önüne geçebilmek için eksik verilerin tespit edilmesi ve eksik verilere yönelik aksiyon alınması oldukça önemlidir. Veriler resmî kurumlar aracılığıyla yayımlandığı için eksik veri ile karşılaşılmamıştır.

5.2.2.2 Veri normalizasyonu

Bir ağ, bir dizi değere sahip ölçeklenmemiş verileri işlemeye başladığında büyük girdilerin ağı öğrenmesini ve yakınsamasını yavaşlatması ve bazı durumlarda ağın bilgiyi etkili bir şekilde öğrenmesini engellemesi mümkündür. Bunlar başarılı sonuçlar üretmede sorun teşkil edebilir. Bunun önüne geçmek için verilere min-max normalizasyonu yapılmıştır. Min-max normalizasyonu ile veriler 0 ve 1 aralığında dağılım göstermektedir. Min-max normalizasyonu Denklem 5.1'deki formüle göre hesaplanmaktadır.

$$x_{\text{scaled}} = \frac{x - x_{\text{min}}}{x_{\text{max}} - x_{\text{min}}} \quad (5.1)$$

Burada x , veri seti içerisindeki herhangi bir değeri temsil etmektedir. x_{min} , en düşük x değerine karşılık gelmektedir. x_{max} , en büyük x değerine karşılık gelmektedir. x_{scaled} , 0-1 aralığına ölçeklenmiş x değerini temsil etmektedir.

Değerlendirme aşamasında, modelin performansını doğru bir şekilde değerlendirmek için tahminler tekrar birincil ölçeğe dönüştürülmüştür.

5.2.2.3 Veri bölütleme

Tahminde bulunmadan önce veri seti, eğitim ve test olmak üzere 2'ye ayrılmıştır. Böylelikle eğitim seti üzerinde model eğitilir ve test seti üzerinde tahminler yapılabilir. Eğitim seti büyüdükçe model daha iyi öğrenecektir. Test seti büyüdükçe ise değerlendirme metrikleri daha güvenilir, daha sıkı güven aralıklarında olacaktır. Eğitim ve test veri seti farklı oranlarda birçok kez ayrıştırılıp model başarısı test edilmiş, en iyi başarıya sahip oranlar seçilmiştir.

5.2.3 Model inşası

Model inşa edilirken ve yürütülürken derin öğrenme uygulamalarını gerçekleştirmek için Keras ve Tensorflow kütüphaneleri kullanılmıştır.

Deprem tahmini yaparken girdi verileri tek değişkenli ve çok değişkenli olarak her model için farklı şekilde uygulanmış ve test edilmiştir. Girdi olarak tek değişkenin kullanılması örneğin gelecekteki depremlere ait büyüklüklerin tahminini yapmak için geçmişteki depremlere ait büyüklüklerin kullanılması ile büyüklük değişkenin zaman uzayında mevsimselliği, durağanlığı ve trendi gibi keşifler yapmayı sağlamaktadır. Girdi olarak çok değişkenin kullanılması ise örneğin gelecekteki depremlerin büyüklüklerini tahmin etmek için geçmişteki depremlere ait büyüklük, enlem, boylam, derinlik gibi verilerin kullanılması tek değişkenliye ek olarak nedenselliğin keşfedilmesine de yardımcı olmaktadır.

5.2.3.1 Uzun kısa süreli bellek

LSTM, deprem tahmini dahil olmak üzere tahmin çalışmalarında başarılı sonuçlar elde edebilen oldukça popüler bir derin öğrenme yöntemidir. LSTM, zaman serilerini ve uzun süreli bağımlılık problemini modellemek için tasarlanmış yapay bir RNN mimarisidir [56].

Geleneksel sinir ağları, birbirine bağlı giriş, gizli ve çıkış katmanlarında yer alan organize edilmiş bir dizi nörondan oluşmaktadır. Bu nöronlar aracılığıyla birkaç fonksiyon kullanılarak çıktı üretilir. Çıktının üretilmesiyle birlikte sonraki işlemlerden geri dönülemez şekilde izole edilmiş halde kalır. Geleneksel sinir ağları bu tasarım ilkelerine bağlı olarak sıralı verileri işlerken zamansallığı ve durumsallığı sürdürmemesi nedeniyle zaman serisi problemleri, doğal dil işleme gibi verilerin birbirleriyle sıralı olduğu problemleri barındıran uygulamalarda performans açısından sınırlı kalmaktadır. RNN'ler ise bir geri bildirim döngüsü içermesiyle birlikte, bir tür hafızaya sahip olur. Bu da sıralı verilere sahip problemlerin çözümünde daha fazla başarı elde edilmesini sağlamaktadır.

Sıralı verileri işlemede oluşan fark, LSTM ile RNN arasındaki en temel farklılığı ortaya koymaktadır. Kaybolan veya patlayan gradyan sorunu düzenli olarak RNN'lerde karşılaşılabilen problemlerdendir. Kaybolan gradyan sorunu, eğitim aşamasında ağı güncellemek için kullanılan gradyanların yok olmasıdır. Patlayan gradyan sorunu ise gradyanların katlanarak artmasıdır. Her iki gradyan problemi ağı

optimal çözüme kavuşturulmasında büyük bir engeldir. Geniş aralıklı koşulların keşfinin zor olması nedeniyle ortaya çıkarlar. Çok uzun dizilerde RNN kullanmak aktivasyon fonksiyonlarına bağlı olarak oldukça zor olabilir. LSTM modellerinin RNN modellerine kıyasla anlaşılması daha zor bir mimari yapıya sahip olması nedeniyle LSTM modellerini uygulamanın nispeten daha zor olabileceği söylenebilir. Lakin LSTM'lerin RNN'lere kıyasla geniş aralıklı koşulları keşfetme ve kaybolan veya patlayan gradyan sorunu gibi problemlerle daha az karşılaşma gibi birçok alanda çok daha iyi olduğu söylenebilir.

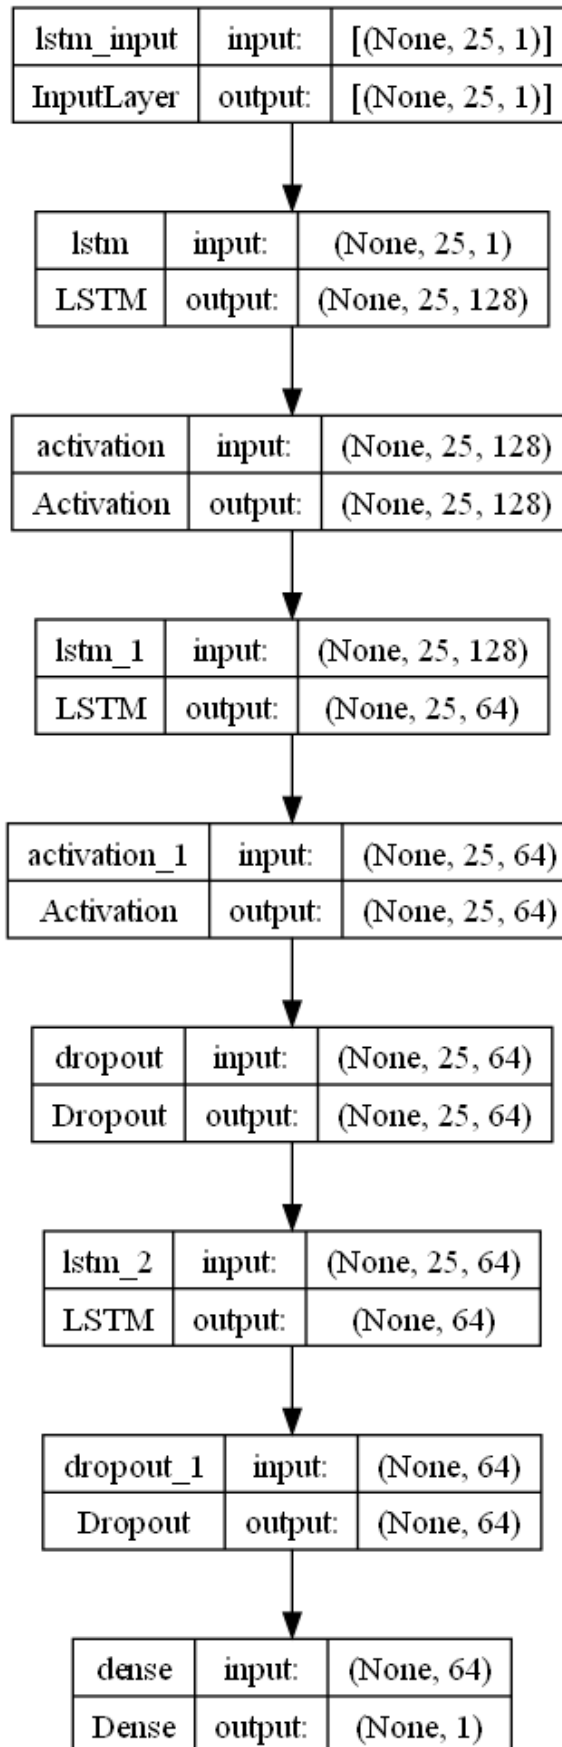
LSTM mimari olarak dört kapıdan oluşmaktadır. Bunlar hücre kapısı, giriş kapısı, çıkış kapısı ve unut kapısıdır. Her bir bileşenin kendine has görevi bulunmaktadır.

Deprem tahmin probleminde kullanılacak olan LSTM modeline ait akış diyagramı Şekil 5.3'te verilmiştir.

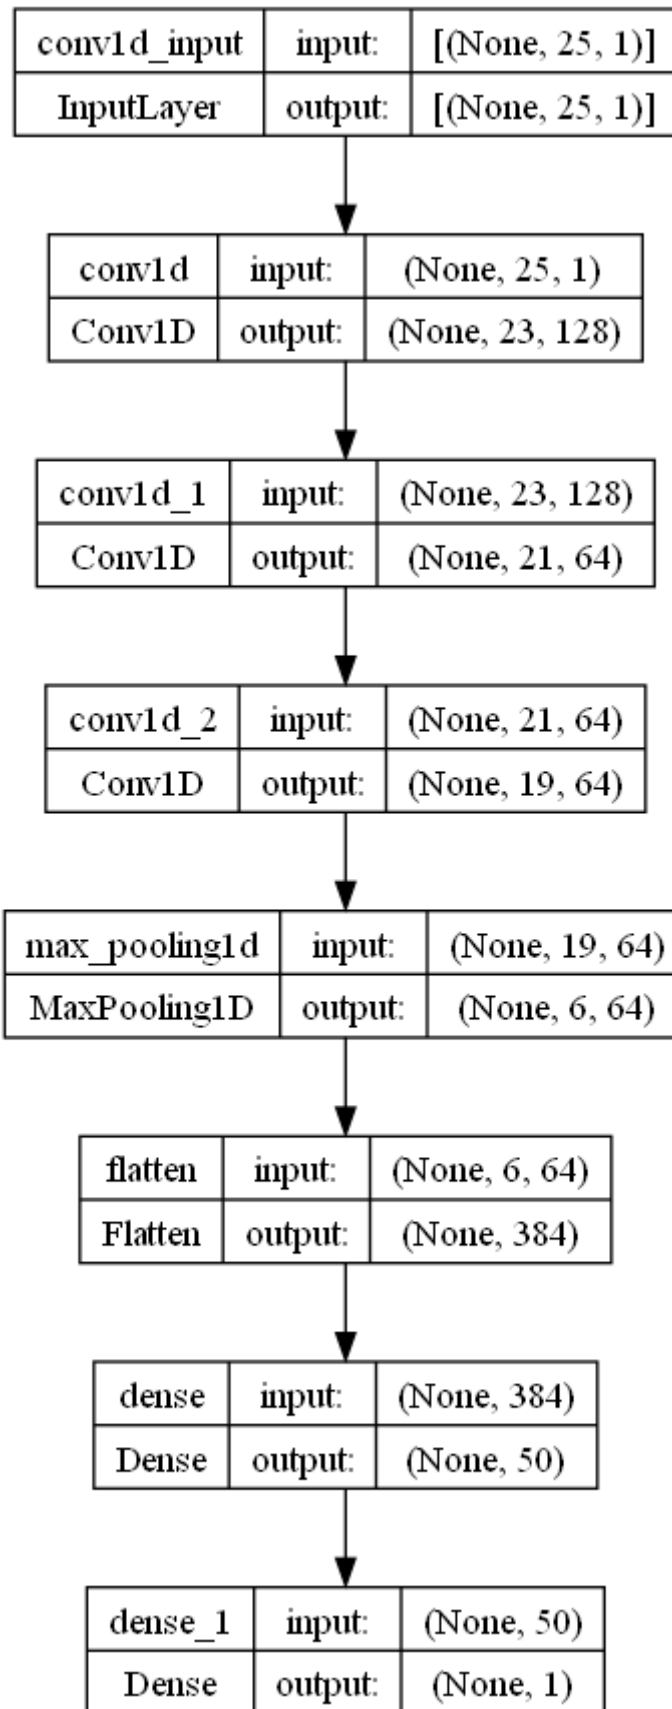
5.2.3.2 Evrişimsel sinir ağları

CNN, başta görüntü işleme olmak üzere zaman serisi problemleri, beyin - bilgisayar ara yüzleri gibi birden fazla alanda çokça tercih edilen bir derin öğrenme yöntemidir. Belirli bir düzende birbirine bağlanmış ve görüntü gibi değerlerden oluşan bir ızgarayı işlemek üzere uzmanlaşmış, birden fazla nöron katmanından oluşan bir sinir ağıdır [57]. CNN, giriş katmanı, evrişimsel katman, havuzlama katmanı ve tam bağlı katmanlar olmak üzere birden fazla katmandan oluşmaktadır. Evrişimsel katman, özellikleri çıkarmak için giriş verisine filtreler uygular, havuzlama katmanı hesaplamayı azaltmak için veriyi küçültür ve tam bağlı katman son tahmini yapar. Ağ, geri yayılım ve gradyan inişi yoluyla en uygun filtreleri öğrenir [58].

Deprem tahmin probleminde kullanılacak olan CNN modeline ait akış diyagramı Şekil 5.4'te verilmiştir.



Şekil 5.3 : LSTM akış diyagramı.



Şekil 5.4 : CNN akış diyagramı.

5.2.4 Model deęerlendirme

Bu alıřmada, İstanbul ve civarında deprem eęilimini tahmin etmek iin nerilen yntemin bařarısını lmek ve dięer alıřmalarla kıyaslamak iin MAE, MSE ve MAPE metrikleri kullanılmıřtır.



6. SONUÇLAR

Çalışma Python 3.9 kullanılarak JupyterLab 3.5.0 IDE'de uygulanmıştır. Intel i7-6700HQ 2,60 GHz CPU ve 16 GB RAM'e sahip bir bilgisayarda başarıyla yürütülmüştür.

Veri setinin tahmin sonuçlarını ne denli etkilediğini hesaplamak için de tahminler aynı veri seti içerisinde yer alan son 25 yıllık deprem verileri, son 10 yıllık deprem verileri, son 5 yıllık deprem verileri ve son 1 yılda gerçekleşen deprem verileri kullanılarak gerçekleştirilmiştir.

6.1 Parametre Seçimi

Model yürütülürken birden fazla parametreye ihtiyaç duymaktadır. Bu parametrelere aktivasyon fonksiyonu, iterasyon sayısı (epoch), sönümlleme değeri (dropout), kayıp fonksiyonu, optimizasyon fonksiyonu örnek verilebilir. Bu parametrelerin seçilen değerleri sonucu direkt olarak etkileyebilir. Çalışmada, çalışmanın sonucunu doğrudan etkileyebilecek olan aktivasyon fonksiyonu, iterasyon sayısı ve sönümlleme değeri parametrelerinde parametre seçimi uygulanmıştır.

6.1.1 Aktivasyon fonksiyonu seçimi

Aktivasyon fonksiyonları, derin sinir ağı mimarilerinde bilginin bir sonraki nörona aktarılıp aktarılmayacağına karar vermek için kullanılır. Derin öğrenme algoritmalarında aktivasyon fonksiyonları, öğrenme sürecinin sağlıklı bir şekilde gerçekleştirilmesi, aşırı uyumun engellenmesi, doğruluk performansının artırılması ve hesaplama maliyetinin düşürülmesi gibi özellikler dikkate alınarak geliştirilmiştir [59].

Keras kütüphanesi içerisinde yer alan aktivasyon fonksiyonlarından olan relu, sigmoid, softmax, softplus, softsign, tanh, selu, elu, exponential, leaky_relu, relu6, silu, gelu, hard_sigmoid, linear ve log_softmax aktivasyon fonksiyonlarının sonucu ne kadar etkilediği problem üzerinde eşit şartlarda test edilmiştir. Bu test esnasında her aktivasyon fonksiyonu için iterasyon sayısı 100, sönümlleme değeri 0,25, test oranı 0,25 olarak seçilmiştir. Diğer parametreler varsayılan olarak seçilmiştir. Aktivasyon

fonksiyonu testler sonucunda LSTM için relu6, CNN için softsign olarak seçilmiştir. Sigmoid, softmax, softplus, exponential, hard_sigmoid ve log_softmax aktivasyon fonksiyonları seçildiğinde model hemen hemen hep aynı değeri tahmin olarak verdiği için bu aktivasyon fonksiyonlarına tabloda yer verilmemiştir. Testlerde değerlendirme için mae, mse, mape ve bu üç hata hesaplamasını içeren toplam hata kullanılmıştır. Toplam hata Denklem 6.1'e göre hesaplanmaktadır. Test sonuçları LSTM modelleri için Çizelge 6.1'de, CNN modeli için Çizelge 6.2'de gösterilmiştir. Hata fonksiyonlarının düşük olması daha başarılı sonuçları işaret ettiğinden her hata özelinde en düşük değer kalın rakamlarla yazılmıştır.

$$\text{Toplam Hata} = \text{MAE} + \text{MSE} + \frac{\text{MAPE}}{100} \quad (6.2)$$

Çizelge 6.1 : LSTM modellerinde aktivasyon fonksiyonu seçimi için yapılan testlerin sonuçları.

Aktivasyon Fonksiyonu	MAE	MSE	MAPE (%)	Toplam Hata
Relu	0,4051	0,2877	25,4451	0,9473
Softsign	0,4107	0,2922	25,8284	0,9612
Tanh	0,4122	0,2930	26,0056	0,9653
Selu	0,4093	0,2912	25,7555	0,9580
Elu	0,4117	0,2933	25,9230	0,9642
Leaky_relu	0,4046	0,2882	25,3262	0,9461
Relu6	0,4027	0,2876	25,1091	0,9414
Silu	0,4187	0,2988	26,5953	0,9835
Gelu	0,4213	0,3005	26,8507	0,9903
Linear	0,4106	0,2926	25,8179	0,9614

Çizelge 6.2 : CNN modelinde aktivasyon fonksiyonu seçimi için yapılan testlerin sonuçları.

Aktivasyon Fonksiyonu	MAE	MSE	MAPE (%)	Toplam Hata
Relu	0,4093	0,2936	25,6016	0,9589
Softsign	0,4074	0,2914	25,5077	0,9539
Tanh	0,4075	0,2908	25,5968	0,9543
Selu	0,4073	0,2969	25,2757	0,9570
Elu	0,4080	0,2919	25,5899	0,9558
Leaky_relu	0,4111	0,2960	25,6604	0,9637
Relu6	0,4085	0,2940	25,4955	0,9575
Silu	0,4107	0,2955	25,6189	0,9624
Gelu	0,4113	0,2964	25,6417	0,9641
Linear	0,4073	0,2929	25,4950	0,9552

6.1.2 Sönümlenme değeri seçimi

Aşırı öğrenmeyi önleyerek performansın artırılması için sönümlenme kullanılmaktadır. Sönümlenme, sinir ağı içerisindeki nöronların rastgele bir oranda ortadan kaldırılmasıdır. Buradaki rastgele orana sönümlenme değeri denilmektedir. Sönümlenme değeri kullanıcı tarafından belirlenmektedir.

Sönümlenme değeri 0,1'den başlayarak 0,9'a kadar 0,1 artırılarak sönümlenme değerinin sonucu ne kadar etkilediği problem üzerinde eşit şartlarda test edilmiştir. Bu test esnasında her aktivasyon fonksiyonu için relu6, iterasyon sayısı 100, ve test oranı 0,25 olarak seçilmiştir. Diğer parametreler varsayılan olarak seçilmiştir. CNN modelinde sönümlenme katmanı olmaması nedeniyle sönümlenme değeri seçimi sadece LSTM modelleri için yapılmıştır. Sönümlenme değeri testler sonucunda 0,2 olarak seçilmiştir. Testler Çizelge 6.3'te gösterilmiştir. En düşük değerler kalın olarak işaretlenmiştir.

Çizelge 6.3 : Sönümlenme değeri seçimi için yapılan testlerin sonuçları.

Sönümlenme Değeri	MAE	MSE	MAPE (%)	Toplam Hata
0,1	0,4070	0,2900	25,5023	0,9520
0,2	0,4049	0,2884	25,3445	0,9467
0,3	0,4081	0,2887	25,7766	0,9546
0,4	0,4061	0,2878	25,5823	0,9497
0,5	0,4062	0,2878	25,5764	0,9498
0,6	0,4150	0,2908	26,6291	0,9721
0,7	0,4141	0,2907	26,5243	0,9700
0,8	0,4147	0,2911	26,5820	0,9716
0,9	0,4170	0,2924	26,8193	0,9776

6.1.3 İterasyon sayısı seçimi

İterasyon değeri 25'den başlayarak 150'ye kadar 25'er artırılarak iterasyon değerinin sonucu ne kadar etkilediği problem üzerinde eşit şartlarda test edilmiştir. Bu test esnasında LSTM modellerinde her aktivasyon fonksiyonu için relu6, sönümlenme değeri 0,2, ve test oranı 0,25 olarak seçilmiştir. CNN modellerinde her aktivasyon fonksiyonu için softsign ve test oranı 0,25 olarak seçilmiştir. Diğer parametreler varsayılan olarak seçilmiştir. İterasyon değeri testler sonucunda hem LSTM hem de CNN modelleri için 100 olarak seçilmiştir. Test sonuçları LSTM modelleri için Çizelge 6.4'te, CNN modelleri için Çizelge 6.5'te gösterilmiştir. En düşük değerler kalın olarak işaretlenmiştir.

Çizelge 6.4 : LSTM modellerinde iterasyon sayısı seçimi için yapılan testlerin sonuçları.

İterasyon Sayısı	MAE	MSE	MAPE (%)	Toplam Hata
25	0,4141	0,2931	26,3341	0,9705
50	0,4096	0,2899	25,8888	0,9584
75	0,4056	0,2886	25,4815	0,9490
100	0,4049	0,2884	25,3445	0,9467
125	0,4070	0,2887	25,6262	0,9520
150	0,4072	0,2896	25,6094	0,9529

Çizelge 6.5 : CNN modelinde iterasyon sayısı seçimi için yapılan testlerin sonuçları.

İterasyon Sayısı	MAE	MSE	MAPE (%)	Toplam Hata
25	0,4131	0,2961	26,0000	0,9692
50	0,4129	0,2952	26,0163	0,9683
75	0,4110	0,2939	25,8659	0,9636
100	0,4074	0,2914	25,5077	0,9539
125	0,4101	0,2934	25,8197	0,9617
150	0,4085	0,2925	25,6187	0,9572

6.1.4 Test oranı seçimi

Test oranı 0,1'den başlayarak 0,9'a kadar 0,1 artırılarak test oranının sonucu ne kadar etkilediği problem üzerinde eşit şartlarda test edilmiştir. Bu test esnasında LSTM modellerinde her aktivasyon fonksiyonu için relu6, iterasyon değeri 100, ve sönümleme değeri 0,2 olarak seçilmiştir. CNN modelinde her aktivasyon fonksiyonu için softsign ve iterasyon değeri 100 olarak seçilmiştir. Diğer parametreler varsayılan olarak seçilmiştir. Test oranı, testler sonucunda hem LSTM hem de CNN modelleri için 0,5 olarak seçilmiştir. Testlerde değerlendirme için MAE, MSE, MAPE ve bu üç hata hesaplamasını içeren toplam hata kullanılmıştır. Testler LSTM modelleri için Çizelge 6.6'da, CNN modeli için Çizelge 6.7'de gösterilmiştir. En düşük değer kalın rakamlarla yazılmıştır.

Çizelge 6.6 : LSTM modellerinde test oranı seçimi için yapılan testlerin sonuçları.

Test Oranı	MAE	MSE	MAPE (%)	Toplam Hata
0,1	0,4096	0,3068	25,3455	0,9699
0,15	0,4079	0,2971	25,1780	0,9568
0,20	0,4032	0,2837	25,3418	0,9403
0,25	0,4049	0,2884	25,3445	0,9467
0,30	0,4016	0,3015	24,3435	0,9465
0,35	0,4003	0,3127	23,6141	0,9491
0,4	0,3959	0,2976	24,0018	0,9335
0,45	0,4054	0,2860	26,0750	0,9522
0,5	0,3970	0,2844	24,9159	0,9306

Çizelge 6.7 : CNN modelinde test oranı seçimi için yapılan testlerin sonuçları.

Test Oranı	MAE	MSE	MAPE (%)	Toplam Hata
0,1	0,4198	0,3134	26,2663	0,9959
0,15	0,4115	0,3014	25,3795	0,9667
0,20	0,4088	0,2892	25,7784	0,9558
0,25	0,4074	0,2914	25,5077	0,9539
0,30	0,4121	0,3063	25,4346	0,9727
0,35	0,4072	0,3114	24,5686	0,9643
0,4	0,4029	0,3010	24,6341	0,9502
0,45	0,4119	0,2910	26,6055	0,9690
0,5	0,3950	0,2898	24,1455	0,9263

6.2 Performans Ölçümü

Bu çalışmada, İstanbul ve civarı için deprem eğilimini tahmin etmek için önerilen LSTM modelinin başarısı MAE, MSE ve MAPE metrikleri kullanılarak ölçüklendirilmiştir.

Veri setinin tahmin sonuçlarını ne denli etkilediğini hesaplamak için de tahminler, aynı veri seti içerisinde yer alan son 25 yıllık deprem verileri, son 10 yıllık deprem verileri, son 5 yıllık deprem verileri ve son 1 yılda gerçekleşen deprem verileri kullanılarak gerçekleştirilmiştir. Çizelge 6.8'de son 25 yılda gerçekleşen deprem verilerini kullanarak üretilen sonuçların performans ölçümü yer almaktadır.

Çizelge 6.8 : İstanbul ve civarında son 25 yılın deprem verileri kullanılarak yapılan performans ölçümü.

Model	Özellik	MAE	MSE	MAPE (%)
Tek Değişkenli – LSTM	Büyüklik	0,3933	0,2805	24,6527
	Enlem	0,1975	0,0722	0,4835
	Boylam	0,5620	0,4852	1,9727
	Derinlik	1,4587	6,7960	16,5233
Çok Değişkenli – LSTM	Büyüklik	0,3970	0,2844	24,9159
	Enlem	0,1968	0,0718	0,4819
	Boylam	0,5684	0,4872	1,9924
	Derinlik	1,5341	6,7221	17,8603
Tek Değişkenli – CNN	Büyüklik	0,3961	0,2911	24,1860
	Enlem	0,1948	0,0709	0,4775
	Boylam	0,5679	0,4966	1,9929
	Derinlik	1,5948	7,2361	19,1965

Çizelge 6.9’da son 10 yılda gerçekleşen deprem verilerini kullanarak üretilen sonuçların performans ölçümü yer almaktadır.

Çizelge 6.9 : İstanbul ve civarında son 10 yılın deprem verileri kullanılarak yapılan performans ölçümü.

Model	Özellik	MAE	MSE	MAPE (%)
Tek Değişkenli - LSTM	Büyüklik	0,4009	0,3113	23,2398
	Enlem	0,1740	0,0550	0,4267
	Boylam	0,5942	0,5100	2,0951
	Derinlik	1,4864	6,6741	17,4240
Çok Değişkenli - LSTM	Büyüklik	0,4018	0,3118	23,2398
	Enlem	0,1732	0,0550	0,4252
	Boylam	0,5913	0,5088	2,0850
	Derinlik	1,5138	6,6717	17,8869
Tek Değişkenli - CNN	Büyüklik	0,4031	0,3130	23,9390
	Enlem	0,1735	0,0560	0,4251
	Boylam	0,5967	0,5208	2,1032
	Derinlik	1,6896	6,7350	20,8104

Çizelge 6.10’da son 5 yılda gerçekleşen deprem verilerini kullanarak üretilen sonuçların performans ölçümü yer almaktadır.

Çizelge 6.10 : İstanbul ve civarında son 5 yılın deprem verileri kullanılarak yapılan performans ölçümü.

Model	Özellik	MAE	MSE	MAPE (%)
Tek Değişkenli - LSTM	Büyüklik	0,4059	0,2950	25,0568
	Enlem	0,1990	0,0681	0,4888
	Boylam	0,6261	0,5359	2,2000
	Derinlik	1,7215	7,8241	19,5669
Çok Değişkenli - LSTM	Büyüklik	0,4059	0,2957	24,9857
	Enlem	0,1971	0,0672	0,4842
	Boylam	0,6129	0,5325	2,1542
	Derinlik	1,6928	7,8950	19,0236
Tek Değişkenli - CNN	Büyüklik	0,4113	0,2991	25,4223
	Enlem	0,1924	0,0659	0,4724
	Boylam	0,6281	0,5493	2,2082
	Derinlik	1,7359	7,9096	19,9632

Çizelge 6.11’de son 1 yılda gerçekleşen deprem verilerini kullanarak üretilen sonuçların performans ölçümü yer almaktadır.

Çizelge 6.11 : İstanbul ve civarında son 1 yılın deprem verileri kullanılarak yapılan performans ölçümü.

Model	Özellik	MAE	MSE	MAPE (%)
Tek Değişkenli - LSTM	Büyüklik	0,4225	0,2979	27,3584
	Enlem	0,1945	0,0729	0,4765
	Boylam	0,5110	0,4207	1,8034
	Derinlik	1,9536	8,5947	25,8068
Çok Değişkenli - LSTM	Büyüklik	0,4242	0,2993	27,5567
	Enlem	0,1953	0,0723	0,4787
	Boylam	0,5143	0,4201	1,8144
	Derinlik	1,9580	8,5966	25,8681
Tek Değişkenli - CNN	Büyüklik	0,4274	0,3038	27,9395
	Enlem	0,1981	0,0737	0,4857
	Boylam	0,5048	0,4386	1,7822
	Derinlik	1,9450	8,7263	25,6910

Çizelge 6.12’de sonuçlar zaman aralığı ve tahmin edilen özelliğe göre en düşük hata skoru elde eden modeller listelenmiştir. Burada T. D. ile tek değişkenli, Ç. D. ile çok değişkenli kast edilmektedir.

Çizelge 6.12 : İstanbul ve civarında zaman aralığı ve tahmin edilen özelliğe göre en düşük hata skoru elde eden modeller.

Zaman Aralığı	Özellik	MAE	MSE	MAPE
25 Yıl	Büyüklik	T. D. LSTM	T. D. LSTM	T. D. CNN
	Enlem	T. D. CNN	T. D. CNN	T. D. CNN
	Boylam	T. D. LSTM	T. D. LSTM	T. D. LSTM
	Derinlik	T. D. LSTM	Ç. D. LSTM	T. D. LSTM
10 Yıl	Büyüklik	T. D. LSTM	T. D. LSTM	T. D. ve Ç. D. LSTM
	Enlem	Ç. D. LSTM	T. D. ve Ç. D. LSTM	T. D. CNN
	Boylam	Ç. D. LSTM	Ç. D. LSTM	Ç. D. LSTM
	Derinlik	T. D. CNN	Ç. D. LSTM	T. D. CNN
5 Yıl	Büyüklik	T. D. ve Ç. D. LSTM	T. D. LSTM	Ç. D. LSTM
	Enlem	T. D. CNN	T. D. CNN	T. D. CNN
	Boylam	Ç. D. LSTM	Ç. D. LSTM	Ç. D. LSTM
	Derinlik	Ç. D. LSTM	T. D. LSTM	Ç. D. LSTM
1 Yıl	Büyüklik	T. D. LSTM	T. D. LSTM	T. D. LSTM
	Enlem	T. D. LSTM	Ç. D. LSTM	T. D. LSTM
	Boylam	T. D. CNN	Ç. D. LSTM	T. D. CNN
	Derinlik	T. D. CNN	T. D. LSTM	T. D. CNN

İstanbul ve civarında deprem eğilimi tahminini kapsayan bu çalışmada büyüklik tahmin başarısı MAE, MSE metriklerince incelendiğinde en iyi sonucu son 25 yıllık deprem verilerinin kullanıldığı tek değişkenli LSTM modeli vermiştir. MAPE metriğince incelendiğinde ise en iyi sonucu son 10 yıllık deprem verilerinin kullanıldığı hem tek değişkenli hem de çok değişkenli LSTM modeli vermiştir.

Enlem tahmin başarısı MAE metriğince incelendiğinde en iyi sonucu son 10 yıllık deprem verilerinin kullanıldığı çok değişkenli LSTM modeli vermiştir. MSE metriğince incelendiğinde en iyi sonucu son 10 yıllık deprem verilerinin kullanıldığı hem tek değişkenli hem de çok değişkenli LSTM modeli vermiştir. MAPE metriğince incelendiğinde en iyi sonucu son 10 yıllık deprem verilerinin kullanıldığı tek değişkenli CNN modeli vermiştir.

Boylam tahmin başarısı MAE ve MAPE metriğince incelendiğinde en iyi sonucu son 1 yıllık deprem verilerinin kullanıldığı tek değişkenli CNN modeli vermiştir. MSE metriğince incelendiğinde en iyi sonucu son 1 yıllık deprem verilerinin kullanıldığı çok değişkenli LSTM modeli vermiştir.

Derinlik tahmin başarısı MAE ve MAPE metriğince incelendiğinde en iyi sonucu son 25 yıllık deprem verilerinin kullanıldığı tek değişkenli LSTM modeli vermiştir. MSE

metriğince incelendiğinde en iyi sonucu son 10 yıllık deprem verilerinin kullanıldığı çok değişkenli LSTM modeli vermiştir.

Modellerin performans ölçümüne göre deprem tahmini problemlerinde tahmin için kullanılacak olan verilerin zaman aralığı önem taşımaktadır. Modellerin son 25 ve son 10 yıldaki deprem verilerinde diğer yıllara göre daha iyi performans gösterdiği söylenebilir. Bununla birlikte tahmin yapmak için kullanılan modeller yaklaşık olarak benzer sonuçlar üretmiştir.

6.3 Bingöl - Karlıova Civarı İçin Deprem Eğilimi Tahmini

Geliştirilen modelin geçerliliğini test etmek için model bir diğer deprem beklenen bölgelerden olan Bingöl - Karlıova civarı için de test edilmiştir. Bingöl - Karlıova civarını kapsayan tarihsel sismik veriler İçişleri Bakanlığı Afet ve Acil Durum Yönetimi Başkanlığı Deprem Dairesi Başkanlığı tarafından yayınlanan deprem kataloğundan alınmıştır [54]. Veri seti yaklaşık son 25 yılda 38,4913 ve 40,1046 enlemleriyle, 39,5488 ve 42,4798 boylamları arasında meydana gelen depremlere ait verileri kapsamaktadır. Bu veri seti içerisinde 17819 depreme ait 8 özellik bulunmaktadır. Veri setinden büyüklüğü 0'a eşit olan, derinliği 2'den küçük ve 60'tan büyük olan 193 adet deprem, modeli daha doğru değerlendirebilmek için çıkarılmıştır. Geliştirilen tek ve çok değişkenli LSTM ile tek değişkenli CNN modelleri Bölüm 6.1'de seçilen parametrelere ek olarak girdi uzunluğu 50 seçilerek veri seti üzerinde test edilmiştir. Çizelge 6.13'de son 25 yılda gerçekleşen deprem verilerini kullanarak üretilen sonuçların performans ölçümü yer almaktadır.

Çizelge 6.13 : Bingöl - Karlıova civarında son 25 yılın deprem verileri kullanılarak yapılan performans ölçümü.

Model	Özellik	MAE	MSE	MAPE (%)
Tek Değişkenli – LSTM	Büüklük	0,8187	0,9086	29,3838
	Enlem	0,3726	0,1967	0,9482
	Boylam	0,6768	0,6410	1,6515
	Derinlik	2,7720	22,3654	30,2172
Çok Değişkenli – LSTM	Büüklük	0,8346	0,9386	29,9849
	Enlem	0,3738	0,1983	0,9505
	Boylam	0,6899	0,6742	1,6795
	Derinlik	2,7077	22,9321	28,4487
Tek Değişkenli – CNN	Büüklük	0,7540	0,7838	27,1713
	Enlem	0,3795	0,2051	0,9653
	Boylam	0,6808	0,6637	1,6598
	Derinlik	2,7509	22,8714	29,3941

Çizelge 6.14'te son 10 yılda gerçekleşen deprem verilerini kullanarak üretilen sonuçların performans ölçümü yer almaktadır.

Çizelge 6.14 : Bingöl - Karlıova civarında son 10 yılın deprem verileri kullanılarak yapılan performans ölçümü.

Model	Özellik	MAE	MSE	MAPE (%)
Tek Değişkenli - LSTM	Büyüklik	0,4817	0,3566	30,8246
	Enlem	0,3908	0,2182	0,9932
	Boylam	0,6842	0,6550	1,6731
	Derinlik	1,7629	11,2211	19,7776
Çok Değişkenli - LSTM	Büyüklik	0,4778	0,3531	30,4112
	Enlem	0,3922	0,2192	0,9971
	Boylam	0,6870	0,6549	1,6808
	Derinlik	1,7491	11,2269	19,5523
Tek Değişkenli - CNN	Büyüklik	0,4865	0,3628	31,1550
	Enlem	0,3955	0,2252	1,0043
	Boylam	0,6896	0,6783	1,6846
	Derinlik	1,4890	11,5115	15,2660

Çizelge 6.15'te son 5 yılda gerçekleşen deprem verilerini kullanarak üretilen sonuçların performans ölçümü yer almaktadır.

Çizelge 6.15 : Bingöl - Karlıova civarında son 5 yılın deprem verileri kullanılarak yapılan performans ölçümü.

Model	Özellik	MAE	MSE	MAPE (%)
Tek Değişkenli - LSTM	Büyüklik	0,4488	0,3708	25,4724
	Enlem	0,3462	0,1860	0,8818
	Boylam	0,6271	0,5734	1,5353
	Derinlik	1,9906	10,6542	22,5521
Çok Değişkenli - LSTM	Büyüklik	0,4479	0,3686	25,3598
	Enlem	0,3476	0,1877	0,8854
	Boylam	0,6239	0,5722	1,5267
	Derinlik	1,9760	10,6345	22,3254
Tek Değişkenli - CNN	Büyüklik	0,4484	0,3726	25,2388
	Enlem	0,3514	0,1900	0,8954
	Boylam	0,6308	0,5874	1,5449
	Derinlik	2,1498	11,0293	25,0176

Çizelge 6.16'da son 1 yılda gerçekleşen deprem verilerini kullanarak üretilen sonuçların performans ölçümü yer almaktadır.

Çizelge 6.16 : Bingöl - Karlıova civarında son 1 yılın deprem verileri kullanılarak yapılan performans ölçümü.

Model	Özellik	MAE	MSE	MAPE (%)
Tek Değişkenli - LSTM	Büyüklik	0,4539	0,3791	26,0223
	Enlem	0,4606	0,2797	1,1754
	Boylam	0,6260	0,5688	1,5332
	Derinlik	2,0449	9,6492	22,4963
Çok Değişkenli - LSTM	Büyüklik	0,4536	0,3795	25,9556
	Enlem	0,4619	0,2809	1,1788
	Boylam	0,6258	0,5727	1,5326
	Derinlik	1,9961	9,7272	21,6279
Tek Değişkenli - CNN	Büyüklik	0,4641	0,3814	27,7686
	Enlem	0,4623	0,2837	1,1784
	Boylam	0,6273	0,5719	1,5367
	Derinlik	2,0778	9,9656	22,9744

Çizelge 6.17’de sonuçlar zaman aralığı ve tahmin edilen özelliğe göre en düşük hata skoru elde eden modeller listelenmiştir. Burada T. D. ile tek değişkenli, Ç. D. ile çok değişkenli kast edilmektedir.

Çizelge 6.17 : Bingöl – Karlıova civarında zaman aralığı ve tahmin edilen özelliğe göre en düşük hata skoru elde eden modeller.

Zaman	Özellik	MAE	MSE	MAPE
25 Yıl	Büyüklik	T. D. CNN	T. D. CNN	T. D. CNN
	Enlem	T. D. LSTM	T. D. LSTM	T. D. LSTM
	Boylam	T. D. LSTM	T. D. LSTM	T. D. LSTM
	Derinlik	Ç. D. LSTM	T. D. LSTM	Ç. D. LSTM
10 Yıl	Büyüklik	Ç. D. LSTM	Ç. D. LSTM	Ç. D. LSTM
	Enlem	T. D. LSTM	T. D. LSTM	T. D. LSTM
	Boylam	T. D. LSTM	Ç. D. LSTM	T. D. LSTM
	Derinlik	T. D. CNN	T. D. LSTM	T. D. CNN
5 Yıl	Büyüklik	Ç. D. LSTM	Ç. D. LSTM	T. D. CNN
	Enlem	T. D. LSTM	T. D. LSTM	T. D. LSTM
	Boylam	Ç. D. LSTM	Ç. D. LSTM	Ç. D. LSTM
	Derinlik	Ç. D. LSTM	Ç. D. LSTM	Ç. D. LSTM
1 Yıl	Büyüklik	Ç. D. LSTM	T. D. LSTM	Ç. D. LSTM
	Enlem	T. D. LSTM	T. D. LSTM	T. D. LSTM
	Boylam	Ç. D. LSTM	T. D. LSTM	Ç. D. LSTM
	Derinlik	Ç. D. LSTM	T. D. LSTM	Ç. D. LSTM

Büyüklik tahmin başarısı MAE metriklerince incelendiğinde en iyi sonucu son 5 yıllık deprem verilerinin kullanıldığı çok değişkenli LSTM modeli vermiştir. MSE metriğince incelendiğinde ise en iyi sonucu son 10 yıllık deprem verilerinin kullanıldığı çok değişkenli LSTM modeli vermiştir. MAPE metriğince incelendiğinde

ise en iyi sonucu son 5 yıllık deprem verilerinin kullanıldığı tek deęişkenli CNN modeli vermiştir.

Enlem tahmininin başarısı MAE, MSE ve MAPE metrięince incelendięinde en iyi sonucu son 5 yıllık deprem verilerinin kullanıldığı tek deęişkenli LSTM modeli vermiştir.

Boylam tahminin başarısı MAE ve MAPE metrięince incelendięinde en iyi sonucu son 5 yıllık deprem verilerinin kullanıldığı çok deęişkenli LSTM modeli vermiştir. MSE metrięince incelendięinde en iyi sonucu son 1 yıllık deprem verilerinin kullanıldığı tek deęişkenli LSTM modeli vermiştir.

Derinlik tahminin başarısı MAE ve MAPE metrięince incelendięinde en iyi sonucu son 10 yıllık deprem verilerinin kullanıldığı tek deęişkenli CNN modeli vermiştir. MSE metrięince incelendięinde en iyi sonucu son 1 yıllık deprem verilerinin kullanıldığı tek deęişkenli LSTM modeli vermiştir.

Modellerin son 5 ve 10 yıldaki deprem verilerinde dięer yıllara göre daha iyi performans gösterdięi söylenebilir. Bununla birlikte tahmin yapmak için kullanılan modeller yaklaşık olarak benzer sonuçlar üretmiştir.

7. DEĞERLENDİRME VE ÖNERİLER

Bu tez çalışmasında tarihsel deprem verileri ve LSTM modeli kullanılarak, İstanbul ve civarı kapsamında deprem tahmini yapılmıştır ve bu konum için deprem tahmin çalışmalarına teşvik etmek amacı taşınmaktadır. Resmi makamlardan elde edilen verilere, ön işleme adımları uygulandıktan sonra veri setini zamanlara bölerek tek ve çok değişkenli LSTM modelleri ve CNN modeli ile eğitimler gerçekleştirilmiştir. Her iki bölge içinde büyüklük özelliği tahmininde LSTM modelleri, enlem özelliği tahmininde tek değişkenli LSTM ve CNN modelleri, boylam özelliği tahmininde LSTM modelleri ve derinlik özelliği tahmininde ise LSTM modelleri daha iyi sonuçlar üretmişlerdir. Bu da kullanılan modellerin tahminleme görevlerinde birbirlerine farklı alanlarda üstünlükleri olduğunu gösterse de mevcut problem ve bölgeler özelinde tek ve çok değişkenli LSTM modellerinin daha fazla tahmin görevinde en iyi sonucu elde ettiğini göstermektedir. Mevcut problem özelinde birden fazla model ve değerlendirme ölçütünün kullanımı zaman ve hafıza uzayı bakımından daha masraflı olsa da elde edilen sonuçların doğruluğunu pekiştirmektedir.

Test sonuçları neticesinde İstanbul ve civarı için genelde 25 ve 10 yıllık veri aralıklarında daha iyi sonuçlar üretilirken, Bingöl – Karlıova civarı için genelde 10 ve 5 yıllık veri aralıklarında daha iyi sonuçlar üretilmiştir. Bu da model eğitilirken veri setinin zamanlara bölünmesinin, mevcut problem üzerinde ve genel olarak makine öğrenmesi çalışmalarında zaman ve veri seçiminin önemi bir kez daha gözler önüne sermiştir. Ayrıca LSTM'nin iki farklı şekilde tek değişkenli ve çok değişkenli olarak kullanılması veri setinde yer alan özelliklerin öğrenmeye olan katkılarını incelemek için önem taşımaktadır. Tek değişkenli LSTM modeline kıyasla çok değişkenli LSTM modelinde kullanılan özelliklerin büyük bir ayrıcalık doğurmadığı görülmüştür.

Deprem tahmin problemleri, depremlerin karmaşık yapısıyla doğru orantılı olarak oldukça zordur ve depremlerin olası etkileri dolayısıyla oldukça önem taşımaktadır. Ülkemizde meydana gelen depremlere ait veri setleri maalesef içerikleri açısından zayıf kalmaktadır. Bu veri setlerinin hem doğrudan depremlerle alakalı veriler hem de dolaylı olarak depremlere neden olabileceği düşünülen olgulara ait verilerle genişletilmesi ülkemiz bekası açısından elzemdir.

Mevcut veri setlerinin zenginleştirilmesiyle ve çeşitli derin öğrenme metotlarının mevcut probleme uygulanmasıyla birlikte ülkemizi konum edinen deprem tahmin çalışmaları daha başarılı sonuçlar elde edecektir.

7.1 Öneriler

Bu çalışmada doğal afetlere ve doğal afetlerin bir çeşidi olan depremlere dair bilgiler verilmiştir. Depremlerin oluşumunu anlayarak deprem tahmin çalışmalarına, bu çalışmaların nasıl olması gerektiğine, bu tür çalışmaların hangi süreçler sonrasında ortaya çıktığına ve mevcut deprem tahmin çalışmalarının incelenerek yeni bir çalışmanın nasıl olması gerektiğine dair bilgiler verilmiştir. Ayrıca bu bilgiler doğrultusunda Kahramanmaraş'ta meydana gelen depremlerin ardından gözler jeologların uzun zamandır üzerinde durduğu, yapı stoğunun büyük bir çoğunluğunun eskiye dayandığı ve üzerinde neredeyse hiç deprem tahmin çalışması yapılmayan İstanbul'a yönelik bir deprem tahmin çalışması gerçekleştirilmiştir. Bu çalışma gerçekleştirilirken ülkemizde meydana gelen ve resmi kurumlarca paylaşılan depremlere ait veri setlerinin az sayıda özellik barındırmasından dolayı depremlerin oluşumunu anlamada çok iyi sonuçlar elde edilememektedir. Bu depremlere ait veri setlerinin içerik olarak zenginleştirilmesi hem çalışma sayısı açısından hem de çalışmaların içerikleri açısından kayda değer bir gelişme kaydedilmesine neden olacaktır. Ayrıca literatürde yer alan çalışmalarda depremi önceden haber verdiği düşünülen çevresel etmenlerin incelendiği çalışmalarda mevcuttur. Başta İstanbul olmak üzere ülkemizi kapsayan deprem tahmin çalışmalarında deprem verileri bu çevresel veriler ile zengileştirilerek daha detaylı ve daha başarılı olabilecek çalışmalar gerçekleştirilebilir. Özellikle ülkemiz özelinde meydana gelen depremlerin verileri, depremler meydana gelir gelmez direkt canlı olarak edinilebilir, böylece deprem tahminin probleminde anlık çözümler üretilebilir. İstanbul özelinde geliştirilen deprem tahmin çalışması jeologlarımızın işaret ettiği ülkemizin diğer kesimleri için de gerçekleştirilebilir. Bu çalışmalarda farklı derin öğrenme yöntemlerinin başarı oranları test edilebilir. Çalışmalarda daha başarılı sonuçlar elde etmek için hibrit metotlar denenebilir. Depremlere ait verilerin sensörlerle ölçüldüğü andan, deprem tahminlerinin kullanıcılara sunulacağı ana kadar olan süreci içeren, bulut bilişim ve nesnelerin internetini kullanan deprem erken uyarı sistemleri gerçekleştirilebilir. Çalışmamızdan elde edilen deprem tahminleri, depremin meydana getirebileceği

hasarları hesaplamak için makine öğrenmesi kullanan çalışmalarca kullanılabilir. Böylelikle fiziksel olarak engellenemeyen depremlerin meydana getirebileceği hasarlar önceden tahmin edilebilir ve bu hasarlar en aza indirgenecek şekilde önlemler alınabilir.



KAYNAKLAR

- [1] **Below, R., Wirtz, A. & GUHA-SAPIR, S.** (2009). *Disaster Category Classification and peril Terminology for Operational Purposes* (Rapor No. 264). Brussels: Centre for Research on the Epidemiology of Disasters.
- [2] **The International Disaseter Database.** <<http://www.emdat.be>>, erişim tarihi 28.05.2024.
- [3] **Centre for Research on the Epidemiology of Disasters.** (2020). *Human Cost of Disasters (2000-2019)* (Rapor No: 61). Brussels: Centre for Research on the Epidemiology of Disasters.
- [4] **Fay** (t.y.). Vikipedi. Erişim: 30 Temmuz, 2024, <https://tr.wikipedia.org/wiki/Fay>
- [5] **What is a fault and what are the different types.** (t.y.). United States Geological Survey. Erişim: 28 Mayıs 2024, <https://www.usgs.gov/faqs/what-a-fault-and-what-are-different-types>
- [6] **Depremle ilgili Teknik Bilgiler.** (t.y.). Kandilli Rasathanesi ve Deprem Araştırma Enstitüsü. Erişim: 28 Mayıs 2024, <http://www.koeri.boun.edu.tr/sismo/bilgi/depremedir/>
- [7] **Sismisite.** (t.y.). İstanbul Deprem ve Zemin İnceleme Şube Müdürlüğü Deprem Sözlüğü. Erişim: 30 Temmuz, 2024, <https://depremezmin.ibb.istanbul/deprem-sozlugu/>
- [8] **Depremın Büyüklüğü Ve Şiddeti Aynı Kavramlar Mıdır.** (t.y.). İçişleri Bakanlığı Afet ve Acil Durum Yönetimi Başkanlığı. Erişim: 30 Temmuz, 2024, <https://www.afad.gov.tr/depremin-buyuklugu-ve-siddeti-ayni-kavramlar-midir>
- [9] **Büyüklik (Magnitüd) Nedir.** (t.y.). Kandilli Rasathanesi ve Deprem Araştırma Enstitüsü. Erişim: 30 Temmuz, 2024, <http://www.koeri.boun.edu.tr/bilgi/buyukluk.htm>
- [10] **Depremler ve Faylar.** (t.y.). Sakarya Üniversitesi Sakarya Meslek Yüksekokulu Sismoloji. Erişim: 30 Temmuz, 2024, http://www.sismo.sakarya.edu.tr/depremler_faylar.htm
- [11] **Depremın Ölçeklendirilmesi.** (t.y.). Ankara Üniversitesi Açık Ders Malzemeleri. Erişim: 30 Temmuz, 2024, https://acikders.ankara.edu.tr/pluginfile.php/119322/mod_resource/content/0/Ders_10_Depremin_Olceklendirilmesi_%28Siddet_Buyukluk_Enerji%29.pdf
- [12] **National Geophysical Data Center / World Data Service (NGDC/WDS): NCEI/WDS Global Significant Earthquake Database. NOAA National Centers for Environmental Information.**

<<https://www.ngdc.noaa.gov/hazel/view/hazards/earthquake/search>>, erişim tarihi 28.05.2024.

- [13] **Büyük Depremler.** (t.y.). Kandilli Rasathanesi ve Deprem Araştırma Enstitüsü. Erişim: 28 Mayıs 2024, <http://www.koeri.boun.edu.tr/sismo/2/deprem-bilgileri/buyuk-depremler/>
- [14] **2023 Kahramanmaraş Depremleri.** (t.y.) Vikipedi. Erişim: 30 Haziran, 2024, https://tr.wikipedia.org/wiki/2023_Kahramanmara%C5%9F_depremleri
- [15] **T.C. Cumhurbaşkanlığı Strateji ve Bütçe Başkanlığı.** (2023). *2023 Kahramanmaraş ve Hatay Depremleri Raporu*. Ankara: T.C. Cumhurbaşkanlığı Strateji ve Bütçe Başkanlığı.
- [16] **Wang, Y., Wang, Z., Cao, Z. & Lan, J.** (2017). Deep learning for magnitude prediction in earthquake early warning. *IEEE Transactions on Emerging Topics in Computing*, 8 (1), 148-158.
- [17] **Veri Ön İşleme Nedir?** (t.y.). msHOWTO. Erişim: 28 Mayıs, 2024, <https://www.mshowto.org/veri-on-isleme-nedir.html>
- [18] **Budak, H.** (2018). Özellik Seçim Yöntemleri ve Yeni Bir Yaklaşım. *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 22 (Özel Sayı), 21-31.
- [19] **Öznitelik Seçimi (Feature Selection) Teknikleri.** (t.y.). Medium. Erişim: 28 Mayıs, 2024, <https://medium.com/@gulcanogundur/oznitelik-seçimi-feature-selection-teknikleri-5cd8cbab7706>
- [20] **Kannan, S.** (2014). Innovative mathematical model for earthquake prediction. *Engineering Failure Analysis*, 41, 89-95.
- [21] **Boucouvalas, A., Gkasios, M., Tselikas, N. & Drakatos, G.** (2015). Modified-Fibonacci-Dual-Lucas Method for Earthquake Prediction. *Third International Conference on Remote Sensing and Geoinformation of the Environment*. Cyprus: Paphos, June 19.
- [22] **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.
- [23] **Kaggle.** *Makine Öğrenmesinde Çapraz Doğrulama ve Test.* <<https://www.kaggle.com/code/k4tr4n/makine-renmesinde-apraz-dorulama-ve-test/notebook>>, erişim tarihi 28.05.2024.
- [24] **Confusion Matrix (Karışıklık Matrisi).** (t.y.). Medium. Erişim: 28 Mayıs, 2024, <https://medium.com/@serapozden922/confusion-matrix-kar%C4%B1%C5%9F%C4%B1k%C4%B1k-matrisi-62c43b8ad2b0>
- [25] **Kesinlik (Precision), Duyarlılık (Recall) ya da F1 Score?** (t.y.). Medium. Erişim: 28 Mayıs, 2024, <https://oguzhanyenen.medium.com/classification-problemlerinde-g%C3%BCvenilirli%C4%9Fin-tespiti-sensitivity-specificity-c930ab3878ad>
- [26] **Classification Problemlerinde Güvenilirliğin Tespiti: Sensitivity, Specificity.** (t.y.). Medium. Erişim: 28 Mayıs, 2024,

<https://medium.com/@gulcanogundur/do%C4%9Fruluk-accuracy-kesinlik-precision-duyarl%C4%B1l%C4%B1k-recall-ya-da-f1-score-300c925feb38>

- [27] **Islam, M.M., Hossain, M.B., Akhtar, M.N., Moni, M.A. & Hasan, K. F.** (2022). CNN Based on Transfer Learning Models Using Data Augmentation and Transformation for Detection of Concrete Crack. *Algorithms*, 15 (8), 1-17.
- [28] **Veri Bilimi Regresyon Analizlerinde (Supervised) Önemli Kavramlar Rehberi (Cheat Sheet).** (t.y.). Medium. Erişim: 28 Mayıs, 2024, <https://yigitsener.medium.com/veri-bilimi-regresyon-analizlerinde-supervised-önemli-kavramlar-rehberi-cheat-sheet-347bd796ec74>
- [29] **Vardaan, K., Bhandarkar, T., Satish, N., Sridhar, S., Sivakumar, R. & Ghosh, S.** (2019). Earthquake trend prediction using long short-term memory RNN. *International Journal of Electrical and Computer Engineering*, 9 (2), 1304-1312.
- [30] **Karimzadeh, S., Matsuoka, M., Kuang, J. & Ge, L.** (2019). Spatial Prediction of Aftershocks Triggered by a Major Earthquake: A Binary Machine Learning Perspective. *ISPRS International Journal of Geo-Information*, 8 (10).
- [31] **Murwantara I. M., Yugopuspito, P. & Hermawan, R.** (2020). Comparison of machine learning performance for earthquake prediction in Indonesia using 30 years historical data. *Telkonnika (Telecommunication Computing Electronics and Control)*, 18 (3), 1331,1342.
- [32] **Bhatia, M., Ahanger, T. A. & Manocha, A.** (2023). Artificial intelligence based real-time earthquake prediction. *Engineering Applications of Artificial Intelligence*, 120.
- [33] **Asim, K. M., Idris, 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.
- [34] **Majhi, S. K., Hossain, S. S. & Padhi, T.** (2020). MFOFLANN: moth flame optimized functional link artificial neural network for prediction of earthquake magnitude. *Evolving Systems*, 11, 45-63.
- [35] **Salam, M. A., Ibrahim, L. & Abdelminaam, D. S.** (2021). Earthquake Prediction using Hybrid Machine Learning Techniques. *International Journal of Advanced Computer Science and Applications*, 12 (5), 654-665.
- [36] **Kavianpour, P., Kavianpour, M., Jahani, E. & Ramezani, A.** (2023). A CNN-BiLSTM model with attention mechanism for earthquake prediction. *International Journal of Advanced Computer Science and Applications*, 79, 19194–19226.
- [37] **Can, C., Ergun, G. & Gokceoglu, C.** (2014). Prediction of earthquake hazard by hidden Markov model (around Bilecik, NW Turkey). *Open Geosciences*, 6 (3), 403-414.

- [38] **Kaftan, I., Şalk, M. & Şenol, Y.** (2017). Processing of earthquake catalog data of Western Turkey with artificial neural networks and adaptive neuro-fuzzy inference system. *Arabian Journal of Geosciences*, 10.
- [39] **Cekim, H. O., Tekin, S. & Özel, G.** (2021). Prediction of the earthquake magnitude by time series methods along the East Anatolian Fault, Turkey. *Earth Science Informatics*, 14, 1339-1348.
- [40] **Doğan, A. & Demir, E.** (2022). Structural recurrent neural network models for earthquake prediction. *Neural Computing and Applications*, 34, 11049-11062.
- [41] **İstanbul'un Endemik Bitkilerini Tanıyalım.** (2021). Retrieved May 28, 2024, from https://yesil.istanbul/haber_istanbul-un-endemik-bitkilerini-taniyalim-1
- [42] **İstanbul Kuş Göçü Gözlem Etkinliği Yapıldı.** (2022). Retrieved May 28, 2024, from https://yesil.istanbul/haber_istanbul-kus-gocu-gozlem-etkinligi-yapildi
- [43] **İstanbul İl Kültür ve Turizm Müdürlüğü Strateji Geliştirme Şube Müdürlüğü.** (2024). *İstanbul Turizm İstatistikleri Raporu Mart - 2024*. İstanbul: İstanbul İl Kültür ve Turizm Müdürlüğü Strateji Geliştirme Şube Müdürlüğü.
- [44] **Türkiye İstatistik Kurumu.** (2023). *İl Bazında Gayrisafi Yurt İçi Hasıla, 2022* (Rapor No: 45867). Ankara: Türkiye İstatistik Kurumu.
- [45] **Türkiye İstatistik Kurumu.** (2024). *Adrese Dayalı Nüfus Kayıt Sistemi Sonuçları, 2023* (Rapor No: 49684). Ankara: Türkiye İstatistik Kurumu.
- [46] **Ketin, İ.** (1969). Kuzey Anadolu Fayı Hakkında. *Bulletin of the Mineral Research and Exploration*, 72 (72), 1-27.
- [47] **Kuzey Anadolu Fay Hattı.** (t.y.). Vikipedi. Erişim: 28 Mayıs, 2024, https://tr.wikipedia.org/wiki/Kuzey_Anadolu_Fay_Hatt%C4%B1
- [48] **BBC.** (2023, 4 Aralık). Kuzey Anadolu Fay Hattı hakkında neler biliniyor? *BBC News Türkçe*. Erişim adresi <https://www.bbc.com/turkce/articles/cd1pwnv0z0vo>
- [49] **Ambraseys N. N. & Finkel C.** (1995). *The Seismicity Of Turkey and Adjacent Areas A Historical Review, 1500-1800*. İstanbul: Eren Yayınevi.
- [50] **Yılmaz, Y.** (2023). Deprem Olgusu, Türkiye'de Deprem ve İstanbul Depremi. *İTÜ Vakfı*. Retrieved July 30, 2024, from <https://www.ituvakif.org.tr/deprem-olgusu-turkiyede-deprem-ve-istanbul-depremi>
- [51] **Coşkun, O.** (2023, 5 Aralık). Bakan Özhasseki: Yerinde dönüşüme 250 bin civarında müracaat var. *Anadolu Ajansı*. Erişim adresi <https://www.aa.com.tr/tr/gundem/bakan-ozhaseki-yerinde-donusume-250-bin-civarinda-muracaat-var/3074151>
- [52] **Habertürk.** (2023, 5 Ağustos). Prof. Dr. Naci Görür: 2.5 milyon insan risk altında. *Habertürk*. Erişim adresi <https://www.haberturk.com/prof-dr-naci-gorur-den-haberturk-e-aciklamalar-3612278>

- [53] **Çapan, M.** (2023, 11 Mart). Yaklaşan İstanbul depreminde tarihi eserlerin durumu ne olacak? *Gerçek Gündem*. Erişim adresi <https://www.gercekgundem.com/istanbul/yaklasan-istanbul-depreminde-tarihi-eserlerin-durumu-ne-olacak-414766>
- [54] **T.C. İçişleri Bakanlığı Afet ve Acil Durum Yönetimi Başkanlığı Deprem Dairesi Başkanlığı.** <<https://deprem.afad.gov.tr/event-catalog>>, erişim tarihi 28.05.2024.
- [55] **T.C. İçişleri Bakanlığı Afet ve Acil Durum Yönetimi Başkanlığı Deprem Dairesi Başkanlığı.** <<https://deprem.afad.gov.tr/stations>>, erişim tarihi 28.05.2024.
- [56] **Hochreiter, S. & Schmidhuber, J.** (1997). Long short-term memory. *Neural Computation*, 9 (8), 1735–1780.
- [57] **Torres, A. D., Yan, H., Aboutalebi, A. H., Das, A., Duan, L. & Rad, P.** (2018). Patient facial emotion recognition and sentiment analysis using secure cloud with hardware acceleration. In A.K. Sangaiah, M. Sheng, Z. Zhang (Eds.), *Computational Intelligence for Multimedia Big Data on the Cloud with Engineering Applications* (Vol. 1, pp.61-89). Retrieved from <https://www.sciencedirect.com/science/article/abs/pii/B9780128133149000037>
- [58] **Introduction to Convolution Neural Network.** (t.y.). GeeksforGeeks. Erişim: 30 Temmuz, 2024, <https://www.geeksforgeeks.org/introduction-convolution-neural-network>
- [59] **Kılıçarslan, S., Adem, K. & Çelik, M.** (2021). An overview of the activation functions used in deep learning algorithms. *Journal of New Results in Science*, 10 (3), 75–88.

ÖZGEÇMİŞ

Ad-Soyad : Yasin KARAKUŞ

ÖĞRENİM DURUMU:

- **Lisans** : 2022, Bartın Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği

DİĞER ESERLER, SUNUMLAR VE PATENTLER:

Karakuş, Y. (2024). Elektronik Sağlık Kaydı Verilerinden Yapay Sinir Ağlarıyla Alkol Kullanıcısı Tahmini, *5th International Bursa Scientific Researchs Congress*, Bursa, Türkiye : March 1-3.

Karakuş, Y., & Altuntaş, V. (2024). Protein complex detection from protein-protein interaction networks with machine learning methods. *Pamukkale University Journal of Engineering Sciences*, 30 (3), 333–342.

Karakuş, Y., & Bilgin, T. T. (2024). Laptop Price Range Prediction with Machine Learning Methods. *IJMSIT*, 8(1), 40–45.