



**T.C.
BATMAN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANA BİLİM DALI**

YÜKSEK LİSANS TEZİ

**UZAKTAN ALGILAMA VERİLERİ KULLANILARAK YAPAY
ZEKA İLE DEPREM SONRASI HASAR TESPİTİ**

Serkan KAYA

**Aralık-2024
BATMAN**

**T.C.
BATMAN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANA BİLİM DALI**

YÜKSEK LİSANS TEZİ

**UZAKTAN ALGILAMA VERİLERİ KULLANILARAK YAPAY
ZEKA İLE DEPREM SONRASI HASAR TESPİTİ**

Serkan KAYA

**Danışman
Doç. Dr. Emrullah ACAR**

Diğer Jüri Yeleri

Doç. Dr. Yılmaz KAYA Doç. Dr. Melih KUNCAN

**Aralık-2024
BATMAN**

TEZ KABUL VE ONAYI

Serkan KAYA tarafından hazırlanan “UZAKTAN ALGILAMA VERİLERİ KULLANILARAK YAPAY ZEKA İLE DEPREM SONRASI HASAR TESPİTİ” adlı tez çalışması 16/12/2024 tarihinde aşağıdaki jüri tarafından oy birliği ile Batman Üniversitesi Lisansüstü Eğitim Enstitüsü Elektrik ve Elektronik Mühendisliği Ana Bilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Başkan

Doç. Dr. Melih KUNCAN

.....

Danışman

Doç. Dr. Emrullah ACAR

.....

Üye

Doç. Dr. Yılmaz Kaya

.....

Yukarıdaki sonucu onaylarım.

Dr. Öğr. Üyesi Ömer Murat ÖTER
Lisansüstü Eğitim Enstitüsü Müdürü

ETİK BEYANI

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını beyan eder, aksinin ortaya çıkması durumunda her türlü yasal sorumluluğu kabullendiğimi bildiririm.

ETHICAL DECLARATION

I declare that all the information in this thesis has been obtained within the framework of ethical behavior and academic rules, and that the source of any statements and information that do not belong to me in this study prepared in accordance with the thesis writing rules has been fully cited, and I declare that I accept all kinds of legal responsibility in case of any contrary situation.

Serkan KAYA

Tarih:

ÖZET

YÜKSEK LİSANS TEZİ

UZAKTAN ALGILAMA VERİLERİ KULLANILARAK YAPAY ZEKA İLE DEPREM SONRASI HASAR TESPİTİ

Serkan KAYA

Batman Üniversitesi Lisansüstü Eğitim Enstitüsü

Elektrik-Elektronik Mühendisliği Ana Bilim Dalı

Danışman: Doç. Dr. Emrullah ACAR

2024, 76 Sayfa

Deprem meydana gelen büyüklüğe bağlı olarak oldukça yıkıcı etkilere sebep olabilmektedir. Özellikle Türkiye’de 6 Şubat 2023 tarihinde meydana gelen 7.7 ve 7.6 büyüklüğündeki depremler örnek olarak verilebilir. Hatay bu iki büyük depremden fazlasıyla etkilenmiş ve çok geçmeden 20 Şubat tarihinde 6.4 büyüklüğünde üçüncü bir deprem daha yaşamıştır. Her üç depremde çok fazla sayıda insan yaralanmış, hayatını kaybetmiş, binalar hasar görmüş veya yıkılmıştır. Depremin sebep olduğu hasarı tespit etmek ise kurtarma ve yardım faaliyetlerinin bölgeye koordineli ve hızlı bir şekilde iletilebilmesi konusunu gündeme getirmiştir. Depremlerin kısa süreli aralıklarla meydana gelmesi deprem sonrası bina hasarı tespitinin ivedilikle yapılması gerektiği gerçeğini gözler önüne sermiştir.

Çalışmada, Hatay iline ait deprem sonrası uzaktan algılama yöntemi ile elde edilen Sentinel-2 uydusu tarafından çekilen görüntüler kullanılmıştır. Bu görüntülerden ulaşılan veriler makine öğrenmesi yöntemi türü olan gözetimli öğrenme modeline ait beş algoritma (destek vektör makinesi, karar ağaçları, Naive Bayes ve k-NN ve ensemble) tarafından çözümlenmiştir. K-En yakın komşuluk (KNN) modeli ile % 85.1; karar ağaçları (Decision Tree-DT) modeli ile % 81.6; destek-vektör matrisi ile %62.1; Naive Bayes modeli ile %66.8 ve Ensemble modeli ile % 86 başarı oranı sağlanmıştır. Çalışma sayesinde deprem sonrası bina hasar tespitine ait görüntü yansıma verilerinin yapay zekâya öğretilmesi ile daha hızlı sonuç elde edildiği görülmüştür. Çalışmanın amacı bu işlevin gerçekleşmesi ile yardım faaliyetlerinin koordinasyonunun hızlı bir şekilde yerine getirilmesidir.

Anahtar Kelimeler: Bina Hasar Tespiti, Deprem, Makine Öğrenimi, Uzaktan Algılama, Sentinel 2, Yapay Zekâ.

ABSTRACT
MASTER THESIS
DAMAGE ASSESSMENT USING REMOTE SENSING DATA WITH
ARTIFICIAL INTELLIGENCE

Serkan KAYA

Batman University Graduate Education Institute

Electrical And Electronics Engineering Department of Science

Advisor: Assoc. Prof. Dr. Emrullah ACAR

2024, 76 Pages

Depending on the magnitude of the earthquake, it can cause quite destructive effects. The magnitude 7.7 and 7.6 earthquakes that occurred on 6 February 2023 in Turkey can be given as an example. Hatay was heavily affected by these two major earthquakes and soon experienced a third earthquake of magnitude 6.4 on 20 February. In all three earthquakes, many people were injured or killed, and buildings were damaged or destroyed. Determining the damage caused by the earthquake raised the issue of coordinated and rapid delivery of rescue and relief activities to the region. The fact that the earthquakes occurred at short-term intervals revealed the fact that building damage assessment should be carried out immediately after the earthquake.

In this study, images of Hatay province taken by Sentinel-2 satellite obtained by remote sensing method after the earthquake were used. The data obtained from these images were analysed by five algorithms (support vector machine, decision trees, Naive Bayes, k-NN, decision trees and ensemble) belonging to the supervised learning model, which is a type of machine learning method. K-Nearest Neighborhood (KNN) model achieved 85.1% success rate, Decision Tree (DT) model 81.6, support vector machine model %62.1, Navie Bayes %66.8 and ensemble model 86%. Thanks to the study, it has been observed that faster results are obtained by teaching the image reflection data of post-earthquake building damage detection to artificial intelligence. The aim of the study is to fulfil the coordination of relief activities quickly with the realisation of this function.

Keywords: Building Damage Assessment, Earthquake, Machine Learning, Remote Sensing, Sentinel 2, Artificial Intelligence.

ÖN SÖZ

Yüksek Lisans Tez çalışma sürecimde yapmış olduğu eleştirileri ve çok kıymetli olumlu olumsuz değerlendirmeleri ile bana yol gösteren çok değerli sayın danışman hocam Doç. Dr. Emrullah ACAR'a teşekkürlerimi sunarım.

Çalışmanın gerçekleşmesi sürecinde sıklıkla faydalandığım Google Earth Engine- Code Editor (GEE-CE) platformu kurucularına ve bu platformda kullandığım Sentinel-2 Uydu verileri için European Space Agency (ESA) çalışanlarına teşekkürlerimi sunarım.

Tez çalışma sürecimde zamanımı ayıramadığım sevgili eşim Esra KAYA ve biricik kızım Serra KAYA'ya bana vermiş oldukları manevi destekten dolayı teşekkür ederim.

Serkan KAYA
BATMAN-2024



İÇİNDEKİLER

ÖZET	iv
ABSTRACT.....	v
ÖN SÖZ	vi
İÇİNDEKİLER	vii
ÇİZELGELER/TABLolar LİSTESİ.....	ix
ŞEKİLLER LİSTESİ	x
SİMGELER VE KISALTMALAR	xii
1. GİRİŞ	1
1.1. Araştırmanın Amacı ve Önemi	3
1.2. Araştırma Problemi ve Hipotezi	5
1.3. Sayıltı	5
1.4. Araştırmanın Varsayımları ve Sınırlılıkları	5
1.5. Evren ve Örneklem	6
2. KAYNAK ARAŞTIRMASI	7
2.1. Deprem Sonrası Uzaktan Algılama Yöntemi ve Yapay Zekâ ile Bina Hasar Tespiti	7
2.1.1. Uzaktan algılama yöntemi nedir?	12
2.1.1.1. Dijital uydu görüntüsü	15
2.1.1.2. Çözünürlük.....	17
2.1.1.3. Dijital görüntü işleme	24
2.1.2. Yapay zekâ (YZ) nedir?	26
2.1.2.1. Makine öğrenimi (Machine learning)	29
2.2. Literatür Çalışmaları	31
2.2.1. Uzaktan algılama yöntemi ile ilgili literatür çalışmaları	31
2.2.2. Hem yapay zekâ hem de uzaktan algılama ile ilgili literatür çalışmaları	32
3. YÖNTEM	35
3.1. Önerilen Sistem Mimarisi	35
3.2. Çalışma Alanı	36
3.3. Verilerin Toplanması	36
3.3.1. Sentinel-2 uydusu özellikleri ve işleyişi	37
3.3.2. Google Earth Engine-Code Editor (GEE-CE) platform yapısı ve işleyişi....	43
3.4. Verilerin Çözümlemesi için Uygulanan Makine Öğrenmesi Yöntemleri	44
3.4.1. Destek vektör makinesi/DVM (Support vector machine-SVM)	45
3.4.2. Naive Bayes (NB) algoritması	46
3.4.3. Karar ağacı algoritması (Decision tree algorithm)	47
3.4.4. K-En yakın komşuluk (k-Nearest neighbours-kNN)	49
3.4.5. Ensemble sınıflandırma algoritması	51
3.5. Konfüzyon Matrisi	52

3.5.1. Doğruluk	53
3.5.2. Hata oranı.....	53
3.5.3. Hassasiyet	54
3.5.4. Duyarlılık	54
3.5.5. F1 skor	54
3.6. ROC Eğrisi.....	54
3.6. Cross Validation (Çapraz Doğrulama)	56
4. BULGULAR VE TARTIŞMA.....	57
4.1. Doğal Renk Bandına Ait Sonuçlar (B4, B3, B2).....	59
4.1.1. Makine öğrenmesi ile elde edilen sonuçlar.....	59
5. SONUÇLAR VE ÖNERİLER	66
5.1 Sonuçlar	66
5.2 Öneriler	68
KAYNAKLAR	70

ÇİZELGELER/TABLolar LİSTESİ

Çizelge 4. 1. Makine öğrenmesi yöntemleri ile elde edilen performans parametre değerleri	63
Çizelge 4. 2. Makine öğrenmesi yöntemleri ile elde edilen performans parametre değerleri	64



ŞEKİLLER LİSTESİ

Şekil 2. 1. Bina hasar tespitleri (Kaynak: TMMOB, 2024: 8).....	9
Şekil 2. 2. Afet öncesi ve sonrası aşamaları (Kaynak: Ergünay, 2008: 2).....	10
Şekil 2. 3. Afet yönetim döngüsü (Kaynak: Carter, 2008: 20)	11
Şekil 2. 4. Uzaktan algılama yöntemi (Kaynak: Wikipedia, t.y.)	14
Şekil 2. 5. Uzaktan algılama sistemi (Kaynak: Sunar, Özkan ve Osmanoğlu, 2011: 6) 14	
Şekil 2. 6. Hatay’da deprem öncesi ve sonrası uydu görüntülerinin karşılaştırılması (Kaynak: TRTHABER, 2023)	15
Şekil 2. 7. Analogdan dijital görüntüye dönüşüm (Kaynak: Sunar, Coşkun ve Osmanoğlu, 2011: 96).....	16
Şekil 2. 8. Örnekleme ve nicemleme adımları (Kaynak: Sunar, Coşkun, Osmanoğlu, 2011: 95).....	16
Şekil 2. 9. Görüntü seçiminde doğru sensörü seçmek (Kaynak: Yücel Erbay, 2005: 19).	17
Şekil 2. 10. Hatay’ın deprem öncesi ve sonrası gece çekilen uydu görüntüleri karşılaştırması	18
(Kaynak: NASA, 2023)	18
Şekil 2. 11. Sırasıyla 0.1 m., 1 m., ve 5 m. çözünürlüklü görüntüler (Gültekin, 2023)..	19
Şekil 2. 12. İzlanda’nın Reykjavik kentinin 7 Temmuz 2019’da çekilen ve piksel çözünürlüğündeki farkı gösteren Landsat 8 görüntüsü (Kaynak: NASA Earth Observatory, 2019)	19
Şekil 2. 13. Radyometrik çözünürlük ile elde edilen görüntü (NASA Earth Observatory, 2019).....	20
Şekil 2. 14. Değer aralıklarına göre radyometrik çözünürlük gösterimi (Kaynak: Wikimedia Commons, 2012).....	21
Şekil 2. 15. Spektral çözünürlük örneği (Kaynak: NASA JPL, 2019)	22
Şekil 2. 16. Elektromanyetik spektrum (Kaynak: UYDUSHOP, t.y.).....	23
Şekil 2. 17. Zamansal çözünürlüğün gösterimi [Kaynak: NASA Applied Remote Sensing Training (ARSET)]	24
Şekil 2. 18. Segmentasyon (Sabuncu, 2018: 37)	25
Şekil 2. 19. Artificial Intelligence (Kaynak: CFI TEAM, t.y.).....	27
Şekil 2. 20. Yıllık yayın sayısı (Kaynak: Kaynak, 2021:3)	28
Şekil 2. 21. Artificial Intelligence Process (Kaynak: LİveHome3D, 2024)	29
Şekil 3. 1. İş akış şeması	35
Şekil 3. 2. Çalışma alanı Google Earth uydu görüntüsü (sağ) ve geçmiş döneme ait deprem aktivitesi (sol) (Kaynak: AFAD, 2023: 3)	36
Şekil 3. 3. Sağlam bina Google ve Sentinel-2 uydu görüntüleri (Kaynak: GEE Platformu, 2024)	37
Şekil 3. 4. Yıkılmış bina Google ve Sentinel-2 uydu görüntüleri (Kaynak: GEE Platformu, 2024)	37
Şekil 3. 5. Sentinel-2 uyduları için spektral bantlar ve mekânsal çözünürlük (Kaynak: ESA, 2015).....	38
Şekil 3. 6. İkiz uydu Sentinel-2 yörünge konfigürasyonu (Kaynak: ESA, 2015: 9)	39
Şekil 3. 7. Çalışma alanının Copernicus Sentinel 2 uydu görüntüsü 1 (Kaynak: ESA, 2023).....	42
Şekil 3. 8. Çalışma alanının Copernicus Sentinel 2 uydu görüntüsü 2 (Kaynak: ESA, 2023).....	42
Şekil 3. 9. Makine öğrenmesi türleri (Kaynak: Towards Datas Science, t.y.).....	45
Şekil 3. 10. DVM yapısı (Kaynak: Akca, 2020).....	46

Şekil 3. 11. Karar ağacının genel yapısı	48
Şekil 3. 12. K-NN algoritmasının çalışması (Kaynak: Anand, 2023)	50
Şekil 3. 13. Konfüzyon matris düzeni (Kaynak: ibm, 2024)	52
Şekil 3. 14. ROC eğrisi (Kaynak: Google, 2024)	55
Şekil 4. 1. Kandilli Rasathanesi-Büyükçat-Samandağ-Hatay (Ml=6.4) depreminin lokasyon haritası (Kaynak: tmmob, 2023: 4).....	57
Şekil 4. 2. Hasarsız binaların sentinel-2 msı uydusu spektral bant.....	58
Şekil 4. 3. Hasarlı/Yıkık binaların sentinel-2 msı uydusu spektral bant.....	59
Şekil 4. 4. Veri setine uygulanan makine öğrenmesi modelleri ve elde edilen doğruluk oranları	60
Şekil 4. 5. DVM sınıflandırma algoritması ROC eğrisi (sol) ve konfüzyon matrisi (sağ)	61
Şekil 4. 6. Navie Bayes sınıflandırma algoritması ROC eğrisi (sol) ve konfüzyon matrisi (sağ)	61
Şekil 4. 7. KNN sınıflandırma algoritması ROC eğrisi (sol) ve konfüzyon matrisi (sağ)	62
Şekil 4. 8. Karar ağaçları sınıflandırma algoritması ROC eğrisi (sol) ve konfüzyon matrisi (sağ)	62
Şekil 4. 9. Bagged Trees sınıflandırma algoritması ROC eğrisi (sol) ve konfüzyon matrisi (sağ)	63

SİMGELER VE KISALTMALAR

Kısaltmalar

AFAD	: Afet ve Acil Durum Yönetimi Başkanlığı
AI/YZ	: Yapay Zekâ
ASTER	: Gelişmiş Uzay Kaynaklı Termal Emisyon ve Yansıma Radyometresi
AVIRIS	: Havadan Görülebilir/Infrared Görüntüleme Spektrometresi
CBS	: Coğrafi Bilgi Sistemi
CNN	: Evrişimli Sinir Ağı
CSC WAN	: Copernicus Uzay Bileşeni Geniş Alan Ağı
DL	: Derin Öğrenme
DT	: Karar Ağaçları
EDRS	: Avrupa Veri Aktarım Uydusu
ENIAC	: Elektronik Sayısal Entegratör ve Hesaplayıcı
ESA	: Avrupa Uzay Ajansı
FPS	: Uçuş Operasyonu Bölümü
GDEM	: Küresel Dijital Yükseklik Modeli
GEE	: Google Earth Engine
GEE-CE	: Google Earth Engine-Code Editor
GIO EMS	: Copernicus Acil Durum Yönetim Hizmeti Haritalama Bileşeni
GNSS	: Küresel Navigasyon Uydu Sistemi
GPW	: Grided Dünya Nüfusu
GRUMP	: Küresel Kırsal-Kentsel Haritalama Projesi
GSI	: Yer Örnekleme Aralığı
IFOV	: Anlık Görüş Alanı
İHA- UAV	: İnsansız Hava Aracı
Km ²	: Kilometre Kare
KNN	: K-En Yakın Komşuluk
M	: Metre
ML	: Makine Öğrenimi
MPC	: Model Öngörülü Kontrolcülü
MTA	: Maden Tetkik ve Arama
NASA	: Ulusal Havacılık ve Uzay Dairesi
NB	: Naive Bayes
OLI	: Operasyonel Arazi Görüntüleyicisi
PACS	: Görüntü Arşivleme ve İletişim Sistemleri
POD	: Sentinel Hassas Yörünge Belirleme
SRTM	: Mekik Radar Topografya Görevi
SVM/DVM	: Destek Vektör Makinaları
T.C.	: Türkiye Cumhuriyeti
TÜİK	: Türkiye İstatistik Kurumu
VIIRS	: Görünür Kızılötesi Görüntüleme Radyometre Paketi

1. GİRİŞ

Deprembilimciler tarafından depremin meydana geleceği fay hattı hakkında bilgiler sunulsa da depremin ne zaman gerçekleşebileceği ile ilgili olarak kesin tarih verilememektedir. Deprembilimcilerin ifadeleri doğrultusunda bir fay hattının ne büyüklükte deprem üretebileceği bilgisine ulaşılsa da bunun ne zaman gerçekleşeceği tam olarak bilinemediğinden depreme yönelik hazırlık çalışmaları da istenilen seviyede olamamaktadır. Bu yüzden deprem sonrası hasar tespit çalışmasının hızlı bir şekilde yapılması gerekmektedir. Ayrıca bu durum deprem sonrası yürütülecek olan faaliyetlerin koordinasyonunu da engellemektedir. Çalışmaların koordinasyonunun aksaması ise bölgeye müdahaleyi geciktirmektedir. Bu durum depremde etkilenen halk üzerinde olumsuz sonuçlara neden olmaktadır. Enkaz çalışmalarında yaşanan en küçük bir gecikme bir cana mâl olabilmektedir. Öte yandan afet sonrası normalleştirme çalışmaları da aksamaktadır. Bu nedenle deprem sonrası yapılacak olan bina hasar tespiti oldukça önemlidir. Ancak bu tespitlerin hızlı bir şekilde gerçekleştirilmesi de elzemdir.

Uzaktan algılama yönteminin yapay zekâ ile entegre edilmesi ile oluşturulacak olan bir uygulama sayesinde bina hasar tespitlerinin hızla yapılabilmesi düşünülmektedir. Çalışma, uzaktan algılama yöntemi ile elde edilen uydu görüntülerinin yapay zekâyâ öğretilmesi sonucunda verilerin doğrudan AFAD gibi ilgili kurumlara aktarımını kolaylaştırmayı amaçlamaktadır. Verilere hızlı bir şekilde ulaşan kurum ise faaliyetlerin koordinasyonu için yeterli zamanı elde edebilecektir.

Bu çalışmada 6 Şubat tarihinde meydana gelen Kahramanmaraş merkezli deprem afetinden en çok etkilenen Hatay ilinin Antakya ilçesinde manuel olarak işaretlediğimiz toplam 1000 adet noktada Sentinel-2 uydusunun doğal renk bantları üzerinden elde edilen yansıma değerlerine makine öğrenmesi modelleri uygulanarak deprem hasarının tespit edilebilirliği araştırılmıştır. Bu doğrultuda çalışmada uzaktan algılama sonucunda elde edilen görüntülerin yansıma değerlerinin yapay zekâ ile analiz edilmesi sonucunda çıktı verilerin elde edilmesi; yapay zekâ ile ulaşılan verilerin doğruluk analizinin yapılarak kontrolünün sağlanması ve yapay zekâ verilerinin doğruluk oranının yüksek çıkması durumunda sistemin işlevselliğinin sağlanması olmak üzere üç hipotez üzerinde durulmaktadır. Çalışma bu yönüyle literatürde var olan diğer çalışmalardan ayrılmaktadır. Bu alanda uygulanan makine öğrenmesi modellerinin

başarı oranı yüksek bulunmuştur. Bu da hasarlı bina bölgelerinin kolay bir şekilde ayırt edilmesi açısından elzemdir. Söz konusu çalışmada oluşturulan “özgün” veri seti ile hasarsız ve hasarlı/yıkık bina alanlarının otomatik olarak belirlendikten sonra kurtarma faaliyetlerine erken safhada başlatılması amaçlanmıştır.

Literatürde yer alan benzer çalışmalarda özellikle Sentinel-1 uydu görüntüleri ile çalışıldığı görülmektedir. Sentinel-2 uydusu ile yapılmış çalışmalar literatürde az sayıda yer almaktadır. Bu çalışmada ise farklı olarak Sentinel-2 uydusundan elde edilen görüntüler üzerinde çalışılmış ve doğal renk bandı kullanılmıştır. Bu uydunun seçilmesinin sebebi ise karasal ve kıyı sularında uzamsal çözünürlükte (10m ila 60m) optik görüntüler elde ederek çevresel izleme, tarım, ormancılık ve afet yönetimi gibi çeşitli alanlarda kullanılması ve özellikle RGB ve kızılötesi verileri sayesinde çok sayıda uygulama için geniş bir yelpazeye hizmet ediyor olmasıdır. Uydu aracılığıyla elde edilen görüntülerin makine öğrenmesi modelleri ile analiz edilmesi de çalışmayı önemli kılan diğer noktalardan biridir. Çünkü makine öğrenmesi modelleri elde edilen verilerin doğruluk ve başarı oranlarını kıyaslama açısından oldukça etkili bir yöntemdir. Çalışmada da bu yöntem ile başarılı sonuçlar elde edilmiştir.

Çalışma alanı olarak 6 Şubat ve 20 Şubat 2023 tarihlerinde sırasıyla 7.7; 7.6 ve 6.4 büyüklüklerinde toplamda üç depremin meydana geldiği ve bu depremlerde yaklaşık 24 bin kişinin hayatını kaybettiği Hatay ili seçilmiştir. T.C. Cumhurbaşkanlığı Strateji ve Bütçe Başkanlığı tarafından 6 Mart 2023 tarihinde yayınlanan “2023 Kahramanmaraş ve Hatay Depremleri” başlıklı rapora göre Hatay, Adana’dan sonra en çok yıkımın yaşandığı il olarak kaydedilmiştir. Hatay’da deprem öncesine ait 2021 yılı TÜİK verilerine göre toplam konut sayısı 847.380’dir. Deprem sonrasında ise mesken sayısı 357.467; işyeri sayısı 33.511; kamu binası sayısı 10.382 ve diğer binaların sayısı 5.489 olmak üzere toplamda 406.849 bina depremde etkilenmiştir. Aynı rapora göre toplam acil+ağır+yıkık konut sayısı 215.255; orta hasarlı konut sayısı 25.957 ve az hasarlı konut sayısı ise 189.317 olarak tespit edilmiştir¹. Bu verilere göre Hatay’daki toplam binaların yarısına yakını depremde dolayı zarar görmüştür. Verilerden de anlaşılacağı üzere çalışma alanında depremler sonrası meydana gelen enkaz olayının ciddi seviyelerde olduğu ve bu durumun hayatı zamansal, ekonomik ve sosyal açıdan olumsuz bir şekilde etkilediği görülmektedir. Bundan dolayı deprem sonrası bina

¹ T.C. Cumhurbaşkanlığı Strateji ve Bütçe Başkanlığı, 2023, 2023 Kahramanmaraş ve Hatay Depremleri Raporu, [online], 2023 Kahramanmaraş ve Hatay Depremleri Raporu - T.C. Cumhurbaşkanlığı Strateji ve Bütçe Başkanlığı - SBB, [Erişim Tarihi: 16.07.2024], ss. 26, 33 ve 36.

hasarlarının erken tespiti ne kadar hızlı yapılabilirse hem kurtarma faaliyetleri hem de sosyal yaşama adaptasyon o kadar hızlı şekilde gerçekleşecektir.

Giriş bölümünün ardından çalışmanın “Kaynak Araştırması” başlıklı ikinci bölümünde öncelikle deprem afeti kavramına yer verilmiş ve çalışmanın odak noktası olan Hatay depremi ve bina hasar tespit süreci hakkında bilgiler aktarılmıştır. Ardından ise çalışmanın amacı doğrultusunda deprem sonrası bina hasar tespitlerinde kullanılan bir yöntem olarak uzaktan algılama ele alınmıştır. Son olarak yapay zekâ kavramı incelenmiş ve literatür taramasına yer verilmiştir.

Çalışmanın “Yöntem” başlıklı üçüncü bölümünde önerilen sistem mimarisi, çalışma alanı, verilerin nasıl toplandığı ve verilerin nasıl çözümlendiği açıklanmıştır.

Çalışmanın “Bulgular ve Tartışma” başlıklı dördüncü ve son bölümde ise literatür taraması yapılması sonucunda ikincil kaynaklardan elde edilen bulgular ortaya koyularak yorumlanmıştır. Hem uzaktan algılama yöntemleri ile çekilen görüntülere ikincil kaynak olarak ulaşılabildiğinden hem de çalışmanın depremin üzerinden bir yıl geçmesinin ardından gerçekleştiriliyor olmasından dolayı (çoğu bina yıkıldığından ve iyileştirme çalışmaları başladığından saha çalışması yapmak zordur) birincil kaynaktan elde edilen verilere ulaşmak mümkün olamamaktadır.

Uzaktan algılama yöntemi ve yapay zekâ ile deprem sonrası bina hasar tespitinin yapılmasına ilişkin değerlendirmeler ve öneriler ise “Sonuç ve Öneriler” başlığı altında aktarılmıştır. Bu bölümde çalışmanı kısa bir özeti yapılarak elde edilen bulgular yorumlanmıştır.

1.1. Araştırmanın Amacı ve Önemi

Türkiye’nin de üzerinde yer aldığı Alp-Himalaya Kuşağı dünyanın önemli deprem kuşaklarından biridir ve ülkede yer alan fayların büyük bir çoğunluğu aktif haldedir. Maden Tetkik ve Arama (MTA) Genel Müdürlüğü tarafından 1992 yılında Türkiye Diri Fay Haritası hazırlanmış ve bu haritaya göre Bayındırlık ve İskân Bakanlığı Deprem Bölgeleme Haritasını yenilemiştir. Kuzey Anadolu, Doğu Anadolu ve Batı Anadolu Fay Hatları olmak üzere Türkiye’de üç önemli fay hattı bulunmaktadır. Merkez üssü Kahramanmaraş’ın Pazarcık ilçesi olan, çok sayıda insanın yaralandığı ve hayatını kaybettiği, Kahramanmaraş dahil toplamda on ilde etkisini gösteren ve büyük yıkımlara sebep olan 7.7 ve 7.6 şiddetlerinde meydana gelen depremler ile 20 Şubat’ta Hatay’da 6.4 büyüklüğünde meydana gelen deprem Doğu Anadolu Fay Hattı üzerinde

gerçekleşmiştir. Hatay’da ilk iki depremin yaratmış olduğu hasar daha tam olarak tespit edilemeden kısa bir süre içerisinde üçüncü bir depremin meydana gelmiş olması deprem sonrası süreci oldukça olumsuz bir şekilde etkilemiştir. Şehirde meydana gelen yıkımın geniş bir alana yayılmış olması hasar tespiti sürecini zorlaştırmış ve hatta baraj patlamasına yönelik sosyal medyada yer alan duyurular bölgede panik yaşanmasına sebebiyet vermiştir. Yaşanan sorunların deprem ile ilgili doğru verilere ulaşımın zor olmasından dolayı kaynaklandığı gözlemlenmiştir. Bu durum Hatay’da meydana gelen bu üç depremin yaratmış olduğu yıkımın hasar tespitinin kısa sürede yapılması gerekliliğini ortaya çıkarmış ve böylece sürecin en hızlı şekilde gerçekleşmesi sonucunda da dezenformasyonun engellenebileceği öngörülmüştür.

Çalışmada, uzaktan algılama yöntemi ile elde edilen verilerin yapay zekâya aktarılmasıyla oluşturulabilecek bir uygulama sayesinde deprem sonrası hasar tespitinin belirlenmesi, kurtarma faaliyetlerinin planlaması, hasar giderimi, onarım, kolay ulaşım yollarının konum bilgisi, temel ihtiyaçların koordinasyonu, tahliye, yardım malzemelerinin sevki gibi konularda ivedilikle hareket edilmesinin sağlanması amaçlanmaktadır. Bu amaç doğrultusunda çalışmada uzaktan algılama yönteminin seçilmiş olmasının nedeni bu yöntem sayesinde geniş ölçekli uydu görüntüleri kullanılarak afet alanına ait daha fazla bilginin daha hızlı şekilde elde edilebilmesidir. Böylece tüm Hatay iline ait deprem sonrası uydu görüntüleri incelenebilecek ve geniş çaplı hasar tespiti yapılabilecektir. Elde edilen görüntülerin yapay zekâ ile analiz edilmesi ile; hasarlı bina oranları bölgesel olarak hızlı şekilde belirlenmesi ve arama kurtarma, enkaz kaldırma, tahliye ve yardım malzemelerinin ulaştırılması gibi planlamalarda karar vericilere teknik danışmanlık yapılması amaçlanmaktadır. Bu tespitlerin deprem sonrası yeniden inşaat sürecini de hızlandıracakları planlanmaktadır.

Hasar tespitinin yapılması ile deprem sonrası süreçte destek ve yardım faaliyetlerinin hızlı bir şekilde gerçekleşmesi etki alanının yeniden inşasına büyük katkı sağlayacaktır. Uzaktan algılama ile elde edilen fotoğrafların yapay zekâ aracılığı ile detaylı analizi binalarda meydana gelen yıkımın derecesini belirleyebilecek ve depreme dayanıklı binaların inşasında önemli bir yol gösterici olacaktır. Bu bağlamda Birleşmiş Milletler Genel Kurulu Sürdürülebilir Kalkınma Amaçlarından “Sürdürülebilir Şehirler ve Topluluklar başlıklı 11. amacın “...afetlere karşı dayanıklılığa yönelik entegre politikaları ve planları benimseyen ve uygulanan şehirlerin ve insan yerleşimlerinin önemli ölçüde arttırılması.” konulu 9. hedefi, çalışma kapsamında değerlendirilebilir. Çalışma çerçevesinde geliştirilebilecek bir uygulama, geniş ölçekte ve hızlı bir şekilde

bina hasar tespit oranlarının belirlenmesini sağlayarak yaşanabilecek bir deprem sonrası olası yıkımın en aza indirilmesine katkı sunacaktır. Çalışma sürdürülebilir şehirler ve toplumlar oluşturulmasında etkili ve işlevsel bir yöntem olarak kullanılabilir. Her ne kadar çalışmanın odak noktası deprem olsa da uygulama diğer afet hasar tespitlerinde de kullanılması için revize edilmeye açıktır. Bu da çalışmanın hem güncelliğini ve geçerliliğini korumasını hem de uygulama alanının genişletilmesi ile literatüre önemli bir katkı sağlamasını mümkün kılmaktadır.

1.2. Araştırma Problemi ve Hipotezi

Araştırma problemi: Uzaktan algılama yöntemi ile deprem sonrası süreçte hasar tespiti noktasında yapay zekâ kullanılabilir mi?

Hipotez 1: Uzaktan algılama sonucunda elde edilen görüntülerin yapay zekâ ile analiz edilmesi sonucunda verilerin elde edilmesi.

Hipotez 2: Yapay zekâ ile ulaşılan verilerin doğruluk analizinin yapılarak kontrolünün sağlanması.

Hipotez 3: Yapay zekâ verilerinin doğruluk oranının yüksek çıkması durumunda sistemin işlevselliğinin sağlanması.

1.3. Sayıltı

Google Earth Engine (GEE)'den elde edilen uydu görüntüleri ve literatür taraması sonucunda elde edilen bilgiler çalışmanın konusu ile ilgili yapılmış olan tüm çalışmaları kapsamaktadır.

1.4. Araştırmanın Varsayımları ve Sınırlılıkları

Çalışma ile yaşanan bir deprem sonrasında bölgenin fotoğraflarına uzaktan algılama yöntemi aracılığıyla ulaşılarak, yapay zekâ sayesinde hasarın tespit derecesinin belirlenerek deprem sonrası müdahalenin en hızlı ve en doğru biçimde gerçekleştirilmesi varsayılmaktadır. Deprem gerçekleştikten hemen sonra ayakta kalan ve yıkılan binaların tespitlerinin ve bunların aldıkları hasarın derecesinin doğru bir şekilde yapılması bölgeye yapılacak kurtarma operasyonlarının verimli bir şekilde yerine getirilmesine olanak sağlayacaktır. Özellikle yıkılan veya molozlardan dolayı

kapanan yolların konumunun tespit edilebilmesi destek ve yardım ekiplerinin bölgeye ulaşımı noktasında alternatif çözümler üretilmesini sağlayacak ve ekiplerin doğrudan o yollara yönlendirilmesi sağlanarak zamandan tasarruf edilebilecektir.

Hatay ilinde büyük hasara sebep olan üç büyük depremin ardından yapılan yardım ve destek faaliyetlerinin koordinasyonunda yaşanan sıkıntıdan dolayı çalışma bölgesi Hatay ili olarak belirlenmiştir. Zaman aralığı olarak ise 6-20 Şubat 2023 depremlerinden itibaren yapay zekânın deprem tespiti ve deprem sonrası hasarının giderilmesinde etkisinin olup olamayacağına doğru genel bir eğilimin artmış olmasından dolayı bu tarihten itibaren yapılan çalışmalar baz alınmış ve yapay zekâyâ olan ilginin artmaya başladığı dönem olan 2000 sonrası incelenmiştir.

1.5. Evren ve Örneklem

Çalışmada her üç depremden de etkilendiği için büyük bir yıkıma uğrayan Hatay ili evren olarak seçilmiştir. Bu anlamda deprem sonrası elde edilen görüntülerin yapay zekâ aracılığıyla yapılan hasar tespiti sonuçları ile deprem sonrasında belirlenen hasar tespitinin karşılaştırılması sağlanmış ve yapay zekânın doğruluk payı ortaya koyulmuştur. Hasar tespitlerinin ivedilikle gerçekleşmesi deprem halkının kısa sürede toparlanmasına katkı sağlayacağından depremden etkilenen insanlar ve yapılar bu çalışmanın örneklemine oluşturmaktadır. Bu iki örneklem üzerinde meydana gelen olumlu dönütler çalışmanın başarı sağlaması açısından önemlidir.

2. KAYNAK ARAŞTIRMASI

Bu bölümde öncelikle deprem afeti kavramına yer verilmiş ve çalışmanın odak noktası olan Hatay depremi ve bina hasar tespit süreci hakkında bilgiler aktarılmıştır. Ardından ise çalışmanın amacı doğrultusunda deprem sonrası bina hasar tespitlerinde kullanılan bir yöntem olarak uzaktan algılama ele alınmıştır. Son olarak yapay zekâ kavramı incelenmiş ve literatür taramasına yer verilmiştir.

2.1. Deprem Sonrası Uzaktan Algılama Yöntemi ve Yapay Zekâ ile Bina Hasar Tespiti

*“Yerkabuğu içindeki kırılmalar nedeniyle ani olarak ortaya çıkan titreşimlerin dalgalar halinde yayılarak geçtikleri ortamları ve yer yüzeyini sarsma olayına deprem adı verilmektedir”*². Depremler hafif ve hasarsız atlatılan sarsıntılar yapabildikleri gibi toprak üzerindeki yapıların yıkılmasına bağlı olarak can kayıplarına neden olacak şekilde şiddetli de olabilmektedir³. Genellikle kısa süreli bir afet olayı olan deprem hafif sarsıntılar şeklinde başlayıp daha sonrasında şiddetlenmesi ile kendisini hissettirmektedir. Bu anlamda büyük depremde önce gerçekleşen hafif sarsıntılara “öncü deprem”, büyük deprem sonrası gerçekleşen daha düşük ölçekli sarsıntılara ise “artçı deprem” denilmektedir⁴. Revize deprem ise depremin üzerinden belirli bir zaman geçtikten sonra yapılan hesaplama ile deprem bilgisini vermekte ve büyük depremde sonra meydana gelebilecek artçı depremlerin tahmin edilmesine yardımcı olmaktadır⁵.

Kamuoyunda “deprem büyüklüğü” ve “deprem şiddeti” kavramları sıklıkla birbirlerinin yerine kullanılsa da bu kavramlar farklı anlamlara sahiptir. Deprem sonucunda ortaya çıkan toplam enerjinin ölçülmesi ve hesaplanması ile elde edilen değer deprem büyüklüğünü, depremin çevreye, insanlara, yapılara vermiş olduğu hasarın boyutu ise depremin şiddetini göstermektedir⁶.

² Depremle İlgili Teknik Bilgiler, “Deprem Nedir?”, Deprem Nedir? (boun.edu.tr), Erişim Tarihi: 15.07.2024.

³ Arama Kurtarma Derneği (AKUT), “Deprem Nedir?”, Deprem Nedir? | Deprem Önlemleri | AKUT Arama Kurtarma Derneği, Erişim Tarihi: 15.07.2024.

⁴ T.C. İçişleri Bakanlığı, “Deprem Nedir?”, Deprem Nedir? Deprem Klavuzu (imranli.gov.tr), Erişim Tarihi: 15.07.2024.

⁵ AXA Sigorta (11.07.2023). “Revize Deprem, Artçı Deprem ve Öncü Deprem Nedir?”, Revize Deprem, Artçı Deprem ve Öncü Deprem Nedir? (axasigorta.com.tr), Erişim Tarihi: 15.07.2024.

⁶ T.C. İçişleri Bakanlığı Afet ve Acil Durum Yönetimi Başkanlığı, “Deprem Nedir?”, deprem_nedir.pdf (afad.gov.tr), Erişim Tarihi: 15.07.2024.

Depremler meydana geliş şekillerine göre farklı türlere ayrılmaktadır. Yeryüzünde meydana gelen depremlerin % 90'ını tektonik depremler oluşturmaktadır. Tektonik deprem, iç kuvvetlerin yol açtığı gerilimlerin boşalması sonucunda meydana gelmektedir. Şiddet ve etki alanı bakımından en etkili olan deprem türüdür. Türkiye'deki depremlerin çoğu da bu gruba girmektedir. Yerin derinliklerindeki erimiş maddenin yeryüzüne çıkışı ile volkanik püskürtmeler meydana gelir ve bunun sonucunda da volkanik depremler oluşur. Japonya ve İtalya gibi ülkelerde bu deprem türü sıklıkla görülürken Türkiye'de aktif yanardağ olmadığından bu türe rastlanmamaktadır. Son olarak ise yer altındaki boşluklarda (mağara), kömür ocaklarındaki galerilerde, tuz ve jipsli arazilerde erime sonucu tavan blokunun çökmesi ile çöküntü depremleri meydana gelmektedir. Özellikle karstik alanlarda meydana gelmesinden dolayı Türkiye'de en çok Akdeniz bölgesinde görülmektedir. Verdiği zarar daha az ve etki alanı daha dardır⁷.

Şubat'ta 7.7 ve 7.6 büyüklüğünde meydana gelen iki deprem 11 ilde⁸ yıkıcı bir etki yaratan geniş çaplı bir tektonik depremdir. Yıkımın en ağır hissedildiği illerden biri olan Hatay'ın Yayladağı ilçesinde 20 Şubat tarihinde 6.4 büyüklüğünde başka bir deprem daha meydana gelmiş ve ilde diğer iki depremin hasar tespit çalışmaları ve arama kurtarma faaliyetleri devam ederken yeni bir yıkım daha yaşanmıştır. Deprem sonrası ortaya çıkan enkaz doğru bir şekilde kaldırılamadığı için yeraltı suları, tarım arazileri, bitki örtüsü, kültür mirasları önemli ölçüde zarar görmüştür. Enkaz kaldırma çalışmaları sırasında ağır iş makinelerinin, "kültür yıkıntısı" olarak nitelendirilen enkazlar üzerinde çalışması bu değerlerin daha fazla zarar görmesine neden olmuştur. Dahası zemin katları üzerinde çalışan ağır iş makineleri zemin kotunun altında hem kendi dönemlerine hem de kendinden önceki dönemlere ait mahzenleri, bodrum katları, su kuyuları ve sarnıçları olan birçok yapıya da zarar vermiştir. Ayrıca depremle birlikte işsizlik, istihdam yetersizliği ve sosyal güvenlik açıkları gibi sorunlar ortaya çıkmış ve hane halkı yoksulluğu artmıştır. Binaların tamamen yıkılması ya da ağır hasarlı olması ise barınma sorununa neden olmuştur. Deprem bölgesinde Çevre, Şehircilik ve İklim Değişikliği Bakanlığı Yapı İşleri Genel Müdürlüğünün verilerine göre acil yıkılacak,

⁷ Weebly, "Deprem Çeşitleri", Deprem Çeşitleri - DEPREMLER (weebly.com), Erişim Tarihi: 15.07.2024; Coşkun İşçi, Deprem Nedir ve Nasıl Korunuruz?, *Journal of Yasar University*, cilt 3, sayı 9, 2008, ss. 961.

⁸ Depremler merkez üssü Kahramanmaraş'ın Pazarcık ve Elbistan ilçeleri olmak üzere Hatay, Gaziantep, Adıyaman, Malatya, Kilis, Şanlıurfa, Adana, Osmaniye, Diyarbakır ve Elazığ'da büyük yıkımlara ve can kayıplarına neden olmuştur.


ağır hasarlı, yıkık, orta hasarlı konut sayısı 311 bin 333 buna karşılık gelen bağımsız bölüm sayısı ise 848 bin 110 olarak tespit edilmiştir⁹.

			TOPLAM:	
İÇMAL	BİNA SAYISI	BAĞIMSIZ BÖLÜM	TOPLAM BİNA SAYISI	2.376.167
HASARSIZ	1.313.096	3.551.335	TOPLAM BAĞIMSIZ BÖLÜM	6.609.408
AZ HASARLI	644.933	2.029.883	TOPLAM ACİL+AĞIR+YIKIK+ORTA BİNA	311.331
ORTA HASARLI	43.746	165.533	TOPLAM ACİL+AĞIR+YIKIK+ORTA KONUT SAYISI	674.164
AĞIR HASARLI	206.907	500.339	TOPLAM ACİL+AĞIR+YIKIK+ORTA TİCARETHANE SAYISI	115.359
YIKIK	39.441	103.755	TOPLAM ACİL+AĞIR+YIKIK+ORTA AHIR VE SAMANLIK SAYISI	24.672
ACİL YIKILACAK	21.237	78.483	TOPLAM ACİL+AĞIR+YIKIK+ORTA DİĞER HANE SAYISI:	33.915
TESPİT YAPILAMADI	106.807	180.080		
TOPLAM	2.376.167	6.609.408		

Şekil 2. 1. Bina hasar tespitleri (Kaynak: TMMOB, 2024: 8)

Aynı gün içerisinde iki büyük depremin yaşanmış ve daha bu depremlerin yıkıcı etkileri bertaraf edilememişken iki hafta gibi kısa bir sürede başka bir büyük depremin meydana gelmiş olması deprem sonrası faaliyetlerin hızlı bir şekilde gerçekleştirilmesi gerektiği gerçeğini gözler önüne sermiştir. Verilere doğru ve hızlı bir şekilde ulaşamama faaliyetlerin koordineli bir şekilde yürütülememesine ve üçüncü depremde de bina yıkımlarına ve can kayıplarına neden olmuştur. Özellikle bina hasar tespitinin kısa sürede yapılması yaşanacak can kaybını en aza indirebilecektir.

Hayatın olağan akışını bozan ve insanları fiziksel, ekonomik, sosyal açıdan etkileyen bir afet olan depremde de diğer afetlerde olduğu gibi faaliyetler şu dört aşama ile yürütülmektedir: Zarar azaltma, hazırlık, olaya müdahale ve iyileştirme. Bahsi geçen ilk iki aşama afet gerçekleşmeden önceki faaliyetleri kapsadığından “risk yönetimi” son ikisi ise afet sonrası faaliyetleri içerdiğinden “acil risk yönetimi” olarak adlandırılmaktadır. Her iki aşamada yürütülmesi gereken faaliyetler birbirinden bağımsız değil aksine iç içe geçmiş bir şekilde etkileşim halindedir. Aşamalar aşağıdaki şekilde görüldüğü üzere bir döngü halindedir¹⁰.




Şekil 2. 2. Afet öncesi ve sonrası aşamaları (Kaynak: Ergünay, 2008: 2)

Afetin sebep olacağı tehlikenin ve riskin belirlenmesi, mümkün olduğunca önlenmesi ya da hasarın en aza indirilmesi için gerekli olan tüm önlemlerin alınması, toplumun afetler hakkında bilgilendirilmesi, bu konuda bilinçlenmenin sağlanması, afet öncesi ve sonrası uygulanacak olan mevzuat ve kurumsal yapılanmanın geliştirilmesi gibi pek çok faaliyet zarar azaltma aşamasında yürütülmektedir. Bu aşamadaki çalışmalar, acil durum planların hazırlandığı ve bu süreçte görev alacak personelin sorumluluklarının belirlendiği, eğitim ve tatbikatların düzenlendiği, arama-kurtarma faaliyetlerinin koordinasyonunun sağlandığı, erken uyarı sistemlerinin geliştirildiği ve acil yardım malzemelerinin yerel ölçekte stoklandığı hazırlık aşaması ile desteklenmektedir. Yaşanan afet sonrası derhal müdahaleyi içeren olaya müdahale aşaması ise yaşanan afetin büyüklüğüne bağlı olarak afet sonrası yaklaşık bir iki aylık süreçte gerçekleştirilen barınma, beslenme, tahliye, korunma, ısınma, güvenlik, psikolojik destek gibi faaliyetleri kapsamaktadır. Son olarak yine afet sonrası müdahaleyi içeren iyileştirme aşaması ise haberleşme, ulaşım, su, elektrik, altyapı, eğitim, sosyal aktiviteler, geçici ve kalıcı barınma olanakları ve çalışma hayatı gibi konularda yapılan düzenlemelerdir¹¹. Bu aşamada afetzedeler için güvenli ve yaşanabilir bir yaşam sahası oluşturulmaya çalışılmakta ve insanların olağan hayat akışına uyumlarına yardım edilmektedir.

Carter ise aşağıdaki şekilde görüldüğü üzere afet yönetim döngüsünü afet sonrası (müdahale, yeniden inşa, kalkınma) ve afet öncesi (önleme/risk azaltma ve hazırlık) şeklinde ayırmaktadır¹².

¹¹ A.g.m. ss. 2-3.

¹² W. Nick Carter, *Disaster Management A Disaster Manager's Handbook*. Asian Development Bank, 2008,



Şekil 2. 3. Afet yönetim döngüsü (Kaynak: Carter, 2008: 20)

Bu döngüye göre de tüm evreler birbirleri ile bağlantılı bir şekilde hareket etmektedir. Bu yüzden bir önceki aşamada gerçekleştirilen faaliyetin başarısı ya da başarısızlığı bir sonraki aşamadaki faaliyeti etkileyeceğinden afetlerin en az hasarla bertaraf edilebilmesi için her evre dikkatle incelenmeli ve tüm faaliyetler teknolojik ve yönetsel faaliyetler de kullanılarak eksiksiz bir şekilde yerine getirilmelidir¹³.

Çalışmada da yapay zekâ ve uzaktan algılama yöntemleri ile deprem sonrası sürecin analizi ve planlanması amaçlandığından olaya müdahale aşaması ve iyileştirme aşaması çalışma kapsamında değerlendirilmektedir. Çalışmada bu iki aşamada yer alan faaliyetlerin hızlı bir şekilde gerçekleştirilmesi için yapay zekânın uzaktan algılama yöntemleri ile entegre bir şekilde çalışması gerektiği ön görülmektedir.

Yaşanan afet sonrası binalarda meydana gelen hasarın doğru ve hızlı bir şekilde tespit edilmesi bina kullanılabilirliğinin belirlenebilmesi için yetkili kurum ve kuruluşlar tarafından ivedilikle yapılması gereken bir sorumluluktur. Yapısal hasar, bir yapının/yapı taşlarının, kullanımı esnasında standart veya tanımlanmış özelliklerini bir nedenden ötürü tamamen ya da kısmen kaybetmesidir. Türkiye’de yapı stoğunun büyük bir kısmı betonarme olup bu binalarda meydana gelen hasarların nedeni ise depremdir. Bu durum maddi ve manevi anlamda önemli kayıpların yaşanmasına yol açmaktadır¹⁴.

¹³ Necmettin Şahin, Afet Yönetimi ve Acil Yardım Planları. TMMOB İzmir Kent Sempozyumu, 2009, ss. 132.

¹⁴ Aslı Sabuncu, Yüksek Mekânsal Çözünürlüklü Uydu/Uçak Platformlu Görüntüler Ve Cbs Teknolojisi Kullanılarak Van-Erciş Depremi Sonrası Bina Hasar Tespiti. Doktora Tezi, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, Geomatik Mühendisliği Anabilim Dalı, 2018, İstanbul, ss. 17.

2.1.1. Uzaktan algılama yöntemi nedir?

Herhangi bir fiziksel etkileşim/temas olmadan yeryüzünün ve yer kaynaklarının incelenmesinde kullanılan uzaktan algılama tekniği ile elde edilen görüntüler konum, boyut ve nesneler arasındaki ilişkiler hakkında bilgi vermektedir. Çinli filozof Konfüçyüs'e ait olduğu iddia edilen “Bir resim bin kelimeye değer.” sözünü günümüzün uzaktan algılama yöntemleri için düşünebiliriz. Ama elbette ki dili olmayan resmin bize ayrıntılı bilgiyi sunması şartıyla. Bu yüzden de uzaktan algılama yöntemleri ile elde edilen görüntülerin yüksek çözünürlükte olmaları doğru veri girişinin sağlanması açısından oldukça elzemdir.

Bilinen ilk hava fotoğrafı 1858 yılında yerden yaklaşık 700 feet yükseklikteki bir balondan Gaspard Felix Tournachon tarafından çekilen Paris görüntüsüdür. 1903 yılında ise Julius Neubronner tarafından belirli bir hat boyunca uçmaları için eğitilen posta güvercinlerine 70 gram ağırlığında takılan kamera ile 30 saniyelik aralıklarla görüntüler elde edilmiş ve Neubronner kameranın patentini almıştır. Wilbur Wright ve L. P. Bonvillain 1908 yılında uçaktan ilk hava görüntüsünü çekmiştir. Bu duruma olan ilgi İkinci Dünya Savaşı'nın sonlarına doğru artmış ve havadan görüntü alma olayları artmaya başlamıştır. Özellikle Soğuk Savaş döneminde uyduya dayalı uzaktan algılama tekniğinin kullanımı artmış ve dönemin süper güçleri olan ABD ile SSCB uydu görüntüleri elde etme yarışına girmiştir¹⁵. Alman V-2 roketlerine yerleştirilen otomatik foto-kamera sistemi de ilk uzaydan algılama faaliyetidir. Uzayda belirli bir yörüngedeki uzay aracına film kameralarının takılması ile mümkün olan SPUTNIK uydusu 4 Ekim 1957'de ve meteoroloji uydularından siyah beyaz görüntüler elde edilmesini sağlayan TIROS-1 ise 1960'larda kullanılmıştır. SKYLAB ve LANDSAT sistemleri ile yeryüzü hakkındaki bilgilerin periyodik olarak toplanması 1970'lerde operasyonel olarak başlamış ve bu amaçla doğal ve kültürel kaynakların haritalanabilmiş ve bir radar sistemi olan SeaSAT'da aynı beklentilerle 1978'de geliştirilmiştir. 1982 yılına gelindiğinde SIR-A uydusunun fırlatılmasıyla askeri olmayan ilk radar sistemi başlamıştır¹⁶.

1960-1972 US Corona Programı uyduya dayalı keşif amaçlı ilk görüntü elde edilen çalışma iken 1972'de LANDSAT-1'in başarı ile çalışması 1975'de

¹⁵ Ulusal Açık Ders Malzemeleri Konsorsiyumu, “Uzaktan Algılamaya Giriş”, Microsoft PowerPoint - Unite1_Uzaktan_Alglamaya_Giris.pptx (ktu.edu.tr), Erişim Tarihi: 16.07.2024.

¹⁶ Filiz Sunar, Coşkun Özkan ve Batuhan Osmanoglu, *Uzaktan Algılama*, Anadolu Üniversitesi Yayınları, Eskişehir, 2011, ss. 2.


LANSAT-2'nin de başarıya ulaşmasını tetiklemiştir. 1982 yılında ABD menşeli LANDSAT-4, 7-Kanallı çok bandlı 30 mono-pan, 1984 yılında LANDSAT-5, 15 mono-panlık mekânsal çözünürlüklü görüntüler sağlarken 1986 yılında Fransa menşeli SPOT-1 çok bandlı 20 mono-pan ve 1990 yılında SPOT-2 10 mono-panlık görüntüler elde etmeye başlamıştır. 1990'larda Rusya, ABD, Fransa ve Hindistan tarafından yüksek çözünürlüklü uydu görüntüleri ticari hale getirilmiştir¹⁷.

Uzaktan algılama yöntemleri kullanım amaçlarına göre ayrılmaktadır. Bir mahalle için kentsel dönüşüm planı hazırlanması için İnsansız Hava Aracı (İHA); bir ülkenin kıyı şeridinde meydana gelen değişimleri tespit etmek için pasif sensörlerle elde edilen uydu görüntüleri; gece yapılacak gemi takibi için aktif sensörlerle elde edilen uydu görüntüleri gibi örneklerin arttırılabileceği pek çok alanda İHA, uydu, radar ve lazer gibi farklı uzaktan algılama araçlarının kullanmak mümkündür. Öte yandan uzaktan algılama teknikleri tarım, orman, haritacılık, maden, savunma, istihbarat, afet yönetimi, enerji, kaynak yönetimi gibi birçok farklı alanda da kullanılmaktadır. Bu durum zaman, maliyet ve insan gücünün sınırlı olması gibi durumlarda kolaylık sağlamaktadır¹⁸. Uzaktan algılama yöntemlerinin birden fazla alanda kullanılması onun etki kapasitesinin genişliğini de göstermektedir. Ancak bu çalışmada sözü edilen yöntem deprem sonrası bina hasar tespiti açısından ele alınmaktadır. Bu yüzden diğer kullanım alanları hakkındaki bilgiler sınırlı tutulmaktadır¹⁹.

¹⁷ Ulusal Açık Ders Malzemeleri Konsorsiyumu, "Uzaktan Algılamaya Giriş", Microsoft PowerPoint - Unite1_Uzaktan_Algılamaya_Giris.pptx (ktu.edu.tr), Erişim Tarihi: 16.07.2024.

¹⁸ Buğçe Gökçe, "Uzaktan Algılama Nedir?", Uzaktan Algılama Nedir? | ATAY (ataymuhendislik.com), 24 Eylül 2022, Erişim Tarihi: 16.07.2024.


¹⁹ Uzaktan algılama yöntemlerinin kullanım alanları hakkında daha fazla bilgiye ulaşmak için bkz. Başarsoft, "Uzaktan Algılama", Uzaktan Algılama Nedir? - Kullanım Alanları | Başarsoft (basarsoft.com.tr), Erişim Tarihi: 16.07.2024.



- | | |
|------------------------------|------------------------------|
| 1) Enerji kaynağı | a) Pasif sensör (algılayıcı) |
| 2) Hedef | b) Aktif sensör sistemiyle |
| 3) Transmisyon (iletim) yolu | |

Şekil 2. 4. Uzaktan algılama yöntemi (Kaynak: Wikipedia, t.y.)

Pasif mikrodalga radyometresi ve radyometre gibi hedef cisimden yayılan/yansıtılan ısıtım enerjisini ölçen yani güneş enerjisine ihtiyaç duyan algılayıcılar pasif algılayıcı sistemler, güneş enerjisine ihtiyaç duymayan kendi enerjisi ile hedefe iletilen sinyalin geri yansıtılan enerjisini ölçen LIDAR ve RADAR gibi algılayıcılar ise aktif algılayıcı sistemler olarak adlandırılmaktadır.



Şekil 2. 5. Uzaktan algılama sistemi (Kaynak: Sunar, Özkan ve Osmanoğlu, 2011: 6)

Sistemdeki temel bileşenler; yeryüzündeki bir cisim/materyal olan hedef, hedefi aydınlatan veya elektromanyetik enerji kaynağı sağlayan enerji kaynağı, hedeften algılayıcıya bilginin iletilmesini sağlayan iletim (yayılım) yolu ve hedeften gelen ışınımı ölçen ve kaydeden algılayıcı şeklindedir. Öncelikle hedeften gelen enerji kaydedilmektedir. Ardından bir uydu yer istasyonunda görüntüye dönüştürülür ve hedef hakkında bilgi almak adına görsel yorumlaması yapılır ya da elektronik olarak yani dijital görüntü işleme algoritmaları kullanılarak işlenir²⁰.

2.1.1.1. Dijital uydu görüntüsü


Bilgisayarda işlenmesi ve depolanması için dijital forma dönüştürülen analog görüntüye dijital görüntü denilmektedir. Uydu görüntülerinin büyük bir kısmı bu şekilde elde edilmektedir. 0 ile 2^{n-1} arasında değer alan dijital sayı (Digital Number-DN), dijital görüntüdeki bir piksele atanan parlaklık değeridir²¹.



Şekil 2. 6. Hatay’da deprem öncesi ve sonrası uydu görüntülerinin karşılaştırılması (Kaynak: TRTHABER, 2023)


²⁰ Filiz Sunar, Coşkun Özkan ve Batuhan Osmanoglu, *Uzaktan Algılama*, Anadolu Üniversitesi Yayınları, Eskişehir, 2011, ss. 5.

²¹ Sabuncu, 2018, 28.



Şekil 2. 7. Analogdan dijital görüntüye dönüşüm (Kaynak: Sunar, Coşkun ve Osmanoğlu, 2011: 96).

Dijital görüntüler; binari, gri renk seviyeli, renkli, çok spektrumlu (multispektral) olmak üzere farklı gruplara ayrılmaktadır. 0 değeri siyah 1 değeri beyaz renge karşılık gelen binari en basit görüntü çeşididir. Sadece parlaklık bilgisi içeren gri renk seviyeli görüntü monokrom veya tek renkli görüntülerdir. Pankromatik görüntü, elektromanyetik spektrumun geniş bir bölümünden yansıyan enerjiyi ölçebilen algılayıcılar tarafından elde edilen bir görüntü türü ve insan gözünün gördüğü tüm renkleri tek bir kanalda kaydedebilirken, elektromanyetik spektrumun Kırmızı, Yeşil ve Mavi bölgelerinden alınmış dijital görüntülerin (RGB) katmanında görüntülenmesi ile elde edilen ise renkli görüntülerdir. Spektrumun farklı bölgelerinden alınan görüntüler ise çok spektrumlu görüntü adını almaktadır²². Dijital uydu görüntüleri sayesinde ince ayrıntılar ön plana çıkarılmaktadır.



Şekil 2. 8. Örnekleme ve nicemleme adımları (Kaynak: Sunar, Coşkun, Osmanoğlu, 2011: 95)

Şekil 2.8’de örnekleme (sampling) ve nicemleme (quantization- genliğin ayrıklaştırılması) adımlarından oluşan ve dijitalleştirme olarak da adlandırılan analog

²² Sabuncu, 2018, 29.

bir görüntünün dijital görüntüye dönüştürülmesi işlemi gösterilmektedir. Şekil 2.11’de ise örnekleme ve nicemleme adımları verilmiştir. Dijital görüntünün piksellerinin elde edilmesi örnekleme, gri yoğunluk değerleri ise (belirli konumda yeryüzü bölgesinden yansıtılan veya yayılan elektromanyetik enerjinin kaydı-parlaklık değeri, DN) nicemleme işlemi ile elde edilmektedir.

Görüntü Tipi	Uygulama Alanları
Pankromatik	• Yüzey yapılarını ve objelerinin fiziksel görüntülerine bakarak (örneğin: şekil, boyut, renk, yönelme vb.) belirlemek, ölçmek ve yerleştirmek. • İnsan yapısı binalar, yollar, evler, havaalanı gibi yapıların doğru olarak lokasyonunu belirlemek ve haritalamak • Var olan haritalardaki fiziksel yapıları güncellemek. • Su ve kara sınırını belirlemek • Şehirlerin büyümesini ve gelişmesini incelemek • Oldukça yüksek doğrulukta dijital yükseklik modeli elde etmek. • Arazi kullanımını tespit etmek.
Multispektral	• Çok belirgin olmayan yüzey özelliklerini (örneğin; mineral içeriği, nem oranı, klorofil miktarı, bitki türü veya kimyasal özellikler) belirlemek ve tanımlamak. • Baskın ağaç, bitki örtüsü tipini belirlemek • Doğal yaşam ve ekosistemlerdeki değişikliklerin belirlenmesi • Yüzeylenmiş kaya ve toprağın sıkışma ve içeriğinin belirlenmesi • Bataklıkların belirlenmesi • Kıyı alanlarında su derinliğinin tahmin edilmesi • Toprak örtüsünün sınıflandırılması
SAR - Synthetic Aperture Radar	• Devamlı bulut, sis veya karanlık olan alanların görüntülenmesinde • Buzdağlarının veya buzulların ve diğer okyanus yüzey koşullarının haritalanmasında • Gizli yüzey şekillerinin ortaya çıkarılmasında. Örneğin, Faylar (kıvrıklar) ve kıvrımlar
Hava Fotoğrafları	• Bir metreden küçük yapıların haritalanmasında • 1000 km² den küçük alanların haritalanmasında • Çok acil , belli bir amaç için yapılacak haritalarda, örneğin; sel, tayfun veya fırtına gibi.

Şekil 2. 9. Görüntü seçiminde doğru sensörü seçmek (Kaynak: Yücel Erbay, 2005: 19).


2.1.1.2. Çözünürlük

Uzaktan algılama yöntemleri ile elde edilen görüntülerin çözünürlük kalitesi verilerin doğru bir şekilde analiz edilebilmesi için oldukça önemlidir. Özellikle yaklaştırma işlemi yapıldığında görüntü kalitesinin düşmemesi verilerin detaylandırılması için gereklidir. Görüntü kalitesinin farklı olması ile ortaya farklı çözünürlük çeşitleri çıkmaktadır. Bunlar zamansal, mekânsal, spektral ve radyometrik olmak üzere toplamda dört gruba ayrılmaktadır.

Mekânsal çözünürlük (Spatial Resolution), yersel ayırma gücü olarak da adlandırılan bu çözünürlük çeşidi piksel boyutu ile ilişkilidir. Görüntüler mekânsal

olarak ayırt edilmektedir²³. Nesnelerin ayırt edilebilmesi ve görüntü analizinin yapılabilmesi mekânsal çözünürlük ile doğru orantılıdır. Mekânsal çözünürlük azaldıkça analizin de başarı oranı düşmektedir.

Hedefteki bir görüntü çözünürlüğü hücresinin veya odak düzlemindeki piksellerin boyutunu tanımlayan mekânsal çözünürlük yer örnekleme aralığı (GSI), ayak izi, piksel boyutu veya IFOV (anlık görüş alanı) cinsinden ifade edilmektedir²⁴.



Şekil 2. 10. Hatay'ın deprem öncesi ve sonrası gece çekilen uydu görüntüleri karşılaştırması (Kaynak: NASA, 2023)

Şekil 2.10'daki haritalar, Antakya şehir merkezi ve çevresindeki toplulukların depremden önce ve sonra yaydığı ışık miktarını göstermektedir. Soldaki harita 4 Şubat 2023 tarihine sağdaki harita ise 8 Şubat 2023 tarihine aittir. Uydulardan elde edilen veriler neticesinde depremlerden sonra bölgenin büyük bir kısmının elektrik enerjisini kaybettiği görülmektedir. Haritalar, NASA/USRA Black Marble bilim ekibinden Eleanor Stokes ve Ranjay Shrestha tarafından sağlanan Black Marble HD'den elde edilmiştir. Haritalar, NASA-NOAA Suomi NPP uydusundaki Görünür Kızılötesi Görüntüleme Radyometre Paketi (VIIRS) sensöründen elde edilen verilere dayanmaktadır. Temel harita ise Landsat 9 uydusu tarafından toplanan verilerden oluşturulmuştur.

²³ Derya Öztürk, “Uzaktan Algılama Ders Notları”, 2020, Samsun, https://avys.omu.edu.tr/storage/app/public/dozturk/71478/dozturk_ua_ders4.pptx, Erişim tarihi: 17.07.2024.

²⁴ Buğçe Gökçe Gültekin, “Mekânsal Çözünürlük Nedir?”, Mekânsal Çözünürlük Nedir? - Uydu Shop, 22 Ağustos 2023, Erişim Tarihi: 17.07.2024.

Mekânsal çözünürlükte görüntünün çekilme yüksekliği önemlidir. Algılayıcı platform yüksekliği ne kadar düşük ya da hedefe yakın ise çözünürlük o kadar net olmaktadır. Bir uçaktan alınan görüntü ile uydudan alınan görüntü karşılaştırıldığında uçak daha düşük platform yüksekliğine sahip olduğundan mekânsal çözünürlüğü de daha fazladır. Dolayısıyla görüntü daha detaylıdır. Teknolojinin sürekli gelişmesi ile uydu-bazlı elde edilen görüntüler de yüksek çözünürlüklü olabilmektedir. Ancak dijital hava fotoğraflarına karşın yine de daha düşük seviyede kalmaktadır²⁵.



Şekil 2. 11. Sırasıyla 0.1 m., 1 m., ve 5 m. çözünürlüklü görüntüler (Gültekin, 2023)

Çözünürlük değeri düşük olduğunda detaylandırma fazla olmaktadır. Çözünürlük değeri arttıkça görüntü bulanıklaşmaya başlamaktadır. Aşağıda NASA tarafından paylaşılan başka bir görüntü yer almaktadır.




Şekil 2. 12. İzlanda'nın Reykjavik kentinin 7 Temmuz 2019'da çekilen ve piksel çözünürlüğündeki farkı gösteren Landsat 8 görüntüsü (Kaynak: NASA Earth Observatory, 2019)

²⁵ Sunar, Özkan ve Osmanoğlu, 2011, 105.

Çözünürlük ne kadar ince olursa (sayı ne kadar düşük olursa), o kadar fazla ayrıntı görebilirsiniz. Şekil 2.12’de 30 m/piksel görüntü (soldaki resim), 100 m/piksel görüntü (ortadaki resim) ve 300 m/piksel görüntü (sağdaki resim) arasındaki pikselleşme farkı gösterilmektedir.

Radyometrik çözünürlük (Radiometric Resolution), her bir pikseldeki bilgi miktarı, yani kaydedilen enerjiyi temsil eden bit sayısıdır. Her bir bit 2’nin bir üssünü kaydeder. Örneğin, 8 bitlik bir çözünürlük 2^8 ’dir ve bu da sensörün bilgi depolamak için 256 potansiyel dijital değere (0-255) sahip olduğunu göstermektedir. Bu nedenle, radyometrik çözünürlük ne kadar yüksek olursa, bilgi depolamak için o kadar fazla değer mevcut olur ve enerjideki en küçük farklılıklar arasında bile daha iyi ayrım sağlamaktadır. Örneğin, su kalitesini değerlendirirken, okyanus rengindeki ince farklılıkları ayırt etmek için radyometrik çözünürlük gereklidir²⁶.




Şekil 2. 13. Radyometrik çözünürlük ile elde edilen görüntü (NASA Earth Observatory, 2019)

Uzaktan algılama teknolojisindeki gelişmeler uydu görüntülerini önemli ölçüde iyileştirmiştir. Bu ilerlemeler arasında radyometrik çözünürlükteki ya da bir aletin elektromanyetik enerjideki küçük farklılıklara karşı ne kadar hassas olduğu

²⁶ NASA Earth Observatory, 2019.

konusundaki gelişmeler de yer almaktadır. Yüksek radyometrik çözünürlüğe sahip sensörler ışıktaki daha fazla ayrıntıyı ve varyasyonu ayırt edebilir. Şekil 2.16'daki görüntü NASA Dünya Gözlemevi'nden Joshua Stevens tarafından ABD Jeolojik Araştırmalar Kurumu'nun Landsat verileri kullanılarak elde edilmiştir.




Şekil 2. 14. Değer aralıklarına göre radyometrik çözünürlük gösterimi (Kaynak: Wikimedia Commons, 2012)

Değer arttıkça renk siyahtan griye doğru dönüşmektedir. Radyometrik çözünürlükte kısaca objeleri tanımlamada kullanılan toplam renk tonu sayısı demektir. Her objenin farklı enerji seviyelerinde kaydedilmesinin nedeni yansıyan ışığın şiddetine bağlı olmasıdır.

Spektral çözünürlük (Spectral Resolution), bir sensörün daha ince dalga boylarını ayırt etme yeteneğidir. Yani daha fazla ve daha dar bantlara sahip olmasıdır. Birçok sensör multispektral olarak kabul edilmektedir ve bu durum 3-10 banda sahip oldukları anlamına gelmektedir. Bazı sensörlerin yüzlerce hatta binlerce banda sahip olması ise hiperspektral olarak adlandırılmaktadır. Belirli bir bant için dalga boyu aralığı ne kadar dar olursa, spektral çözünürlük de o kadar ince olmaktadır. Örneğin, Havadan Görünür/Kızılötesi Görüntüleme Spektrometresi (AVIRIS) 224 spektral


kanalda bilgi toplamaktadır. Aşağıdaki küp, veri içindeki ayrıntıyı temsil etmektedir. Bu ayrıntı düzeyinde, kaya ve mineral türleri, bitki örtüsü türleri ve diğer özellikler arasında ayırım yapılabilir.



Şekil 2. 15. Spektral çözünürlük örneği (Kaynak: NASA JPL, 2019)

Küpte, görüntünün sağ köşesindeki küçük yüksek tepki bölgesi, görünür spektrumun kırmızı kısmındadır (yaklaşık 700 nanometre) ve buharlaşma havuzundaki 1 santimetre uzunluğundaki (yarım inç) kırmızı tuzlu su karidesinin varlığından kaynaklanmaktadır. Küpün üst kısmı, sağdaki su ve buharlaşma havuzlarındaki yapıyı vurgulamak için yapılmış sahte renkli bir görüntüdür. Küpün kenarları, AVIRIS spektral kanallarının 224'ünde de tepenin kenarlarını gösteren dilimlerdir. Kenarların üst kısımları spektrumun görünür kısmında (400 nanometre dalga boyu), alt kısımları ise kızılötesindedir (2.500 nanometre)²⁷.

²⁷ NASA Earth Observatory, 2019.




Şekil 2. 16. Elektromanyetik spektrum (Kaynak: UYDUSHOP, t.y.)

Spektral çözünürlük, cisimlerin yansıma, yayılma ve yutulma özelliklerinin farklı olmasından dolayı oldukça önemlidir. Bant/kanalın spektral çözünürlüğü ne kadar yüksekse, alım yapılan dalga boyu aralığı o kadar dardır²⁸. Yani bant aralığı azaldıkça spektral çözünürlük artmaktadır.

Zamansal çözünürlük (Temporal Resolution), bir uydunun bir yörüngeyi tamamlaması ve aynı gözlem alanını tekrar ziyaret etmesi için geçen süredir. Bu çözünürlük yörüngeye, sensörün özelliklerine ve alan genişliğine bağlıdır. Yer sabit uydular Dünya'nın dönme hızıyla eşleştiği için zamansal çözünürlük çok daha incedir. Kutupsal yörüngeli uydular 1 günden 16 güne kadar değişebilen bir zamansal çözünürlüğe sahiptir. Örneğin, NASA'nın Terra ve Aqua uydularında bulunan MODIS sensörü 1-2 günlük bir zamansal çözünürlüğe sahiptir ve sensörün Dünya'yı günden güne değiştirken görüntülemesini sağlar. Öte yandan, NASA/USGS Landsat 8 ortak uydusunda bulunan Operasyonel Arazi Görüntüleyicisi (OLI) daha dar bir alan genişliğine ve 16 günlük bir zamansal çözünürlüğe sahiptir; günlük değişiklikleri değil, iki aylık değişiklikleri gösterir²⁹.

²⁸ UYDUSHOP, "Hangi Proje İçin Hangi Çözünürlük?", Hangi Çözünürlük? - Uydu Shop, Erişim tarihi: 18.07.2024.

²⁹ NASA Earth Observatory, 2019.



Şekil 2. 17. Zamansal çözünürlüğün gösterimi [Kaynak: NASA Applied Remote Sensing Training (ARSET)]


Şekil 2.17’de MODIS’in yörünge alanı (mavi kutular) ile Landsat 8’deki OLI’nin yörünge alanı (kırmızı noktalı kutular) gösterilmektedir. Çok daha geniş görüntüleme alanı nedeniyle MODIS her 1-2 günde bir küresel kapsama sağılarken OLI için bu süre 16 gündür. Kırmızı noktalar her bir Landsat karesinin merkez noktasını göstermektedir. Kısacası zamansal çözünürlük, bir uydu algılayıcısı tarafından aynı bölgenin ne kadar sıklıkla görüntüsünün alındığı ile ilgilidir. Uzaktan algılama, doğal afetlerin etkilerinin hızlı bir şekilde tespit ve analiz edilmesini sağlamaktadır. Bu bağlamda zamansal çözünürlüğün yüksek olması, afet sonrası hasarın tespit edilmesini ve kurtarma faaliyetlerinin koordinasyonuna yardımcı olmaktadır³⁰.

2.1.1.3. Dijital görüntü işleme

Dijital görüntü işleme, dijital görüntünün dijital bir bilgisayar aracılığıyla işlenmesi anlamına gelmektedir. Diğer bir ifadeyle dijital görüntüleri işlemek ve analiz etmek için algoritmaların ve matematiksel modellerin kullanılmasıdır. Bu işlem birkaç adımdan gerçekleşmektedir. Bu adımlar sırasıyla; bir dijital kamera veya tarayıcı kullanarak bir görüntünün yakalanmasını veya mevcut bir görüntünün bir bilgisayara

³⁰ Buğçe Gökçe Gültekin, “Zamansal Çözünürlük Nedir?”, 15 Ağustos 2023, Zamansal Çözünürlük Nedir? - Uydu Shop, Erişim Tarihi: 18.07.2024.

aktarılmasına görüntü edinme, kontrastın artırılması, gürültünün azaltılması ve artefaktların kaldırılması gibi bir görüntünün görsel kalitesinin iyileştirilmesi görüntü iyileştirme, görüntüdeki bulanıklık, gürültü ve bozulma gibi bozulmaların giderilmesi görüntü restorasyonu, bir görüntünün bilgisayar tarafından analiz edilebilecek ve değiştirilebilecek bir şekilde temsil edilmesini ve görüntünün özelliklerinin kompakt ve anlamlı bir şekilde tanımlanması görüntü temsili ve açıklaması, nesneleri tanımak, desenleri tespit etmek ve özellikleri ölçmek gibi bir görüntüden bilgi çıkarmak için algoritmaların ve matematiksel modellerin kullanılması görüntü analizi, depolama ve iletim gereksinimlerini azaltmak için yeni görüntüler oluşturmayı veya mevcut görüntüleri sıkıştırma görüntü sentezi ve sıkıştırmadır. Bu aşamaların sonunda dijital görüntü işleme tamamlanmaktadır. Dijital görüntü işleme, tıbbi görüntüleme, uzaktan algılama, bilgisayarlı görme ve multimedya gibi çeşitli uygulamalarda yaygın olarak kullanılmaktadır³¹.



- a) Satranç tahtası segmentasyonu
- b) Dörtlü ağaç segmentasyonu

Şekil 2. 18. Segmentasyon (Sabuncu, 2018: 37)

Oluşturulan dijital görüntü ön işleme, görüntü zenginleştirme, spektral dönüşüm, mekânsal dönüşüm ve sınıflandırma gibi bilgisayar ortamında değişik algoritmalarla analizinde göz önüne alınan genel işleme adımlarına tabii tutulmaktadır³².

³¹ GeeksforGeeks, “Digital Image Processing Basics”, 22 Feb 2023, Dijital Görüntü İşleme Temelleri - GeeksforGeeks, Erişim Tarihi: 18.07.2024.

³² Sunar, Özkan ve Osmanoglu, 2011, 123.

2.1.2. Yapay zekâ (YZ) nedir?

Yapay zekâ (Artificial Intelligence/AI), bir bilgisayarın veya bilgisayar kontrollü bir robotun/makinenin, akıl yürütme yeteneği gibi insanların karakteristik zihinsel süreçleriyle yaygın olarak ilişkilendirilen görevleri yerine getirme yeteneğidir. Henüz daha geniş alanlarda veya günlük bilgi gerektiren görevlerde insan esnekliğini tam olarak yakalayabilen yapay zekâlar olmamasına rağmen, bazı yapay zekâlar belirli görevleri insanlar kadar -iyi- yerine getirmektedir. Yapay zekâ üzerine en erken teorik çalışma 1940’larda İngiliz matematikçi Alan Turing tarafından yapılmıştır³³.

1941 yılında Alan Turing, meslektaşı Gordon Welchman ile birlikte Almanya ve müttefikleri tarafından kullanılan ve halk arasında ENIGMA kodu olarak bilinen askeri kodları deşifre eden Bombe Makinesi’ni geliştirdi. “Enigma” bir tür şifreleme makinesiydi. ENIAC (Electronic Numerical Integrator and Computer), Birleşik Devletler Ordusu’nun Balistik Araştırma Laboratuvarı’nda, özellikle balistik yörüngeleri hesaplamak için geliştirilen ilk programlanabilir, elektronik, genel amaçlı dijital bilgisayardı. O zamanki maliyeti 500.000 ABD dolarından fazlaydı, bugünkü değerlerle 8 milyon dolara yakın. İlk yapay zekâ programları ise 1950’lerin başında geliştirilmiştir³⁴.

O zamandan bu yana işlem gücünün ve bilgisayar belleğinin istikrarlı bir şekilde artmasıyla, 21. yüzyılın başlarında yapay zekâ, programların görüntüleri sınıflandırabildiği (örneğin, PReLU-net), satranç gibi oyunlarda ustalaşabildiği (AlphaZero), sohbetleri sürdürebildiği (ChatGPT) ve bir metin isteminden bir görüntü oluşturabildiği (DALL-E) noktaya kadar ilerlemiştir. Yapay zekânın tıbbi teşhis, arama motorları, ses veya el yazısı tanıma ve sohbet robotları gibi belirli görevlerde insanlara yardımcı olduğu ve insan uzmanların ve profesyonellerin performans seviyelerine ulaştığı kanıtlanmıştır³⁵. Yapay zekâ kavramı sıklıkla akıl yürütme, anlam keşfetme, genelleme yapma veya geçmiş deneyimlerden öğrenme gibi insanlara özgü zihinsel süreçlerle donatılmış sistemler geliştirme projesine uygulanmaktadır³⁶.

³³ Erik Gregersen, “Artificial Intelligence (AI): At a Glance”, 22 May 2024, Artificial Intelligence (AI): At a Glance | Britannica, Erişim tarihi: 18.07.2024.

³⁴ Okyay Kaynak, The golden age of Artificial Intelligence, *Discover Artificial Intelligence*, volume 1, issue 1, 2021, pp. 1.

³⁵ Gregersen, 2024.

³⁶ B. Jack Copeland, “Artificial Intelligence”, 16 July 2024, Artificial intelligence (AI) | Definition, Examples, Types, Applications, Companies, & Facts | Britannica, Erişim tarihi: 18.07.2024.




Şekil 2. 19. Artificial Intelligence (Kaynak: CFI TEAM, t.y.)

Şekil 2.19’da de görüldüğü üzere doğal olan insan zekâsına karşılık olarak yine insan eliyle/zekâsıyla üretilmiş bir sistem olana yapay zekâ, bir makinenin harici girdilerden rasyonel davranış üretme kabiliyetine odaklanan geniş bir bilgisayar bilimi dalıdır. Yapay zekânın amacı, aksi takdirde insan zekâsı gerektirecek görevleri yerine getirebilecek sistemler yaratmaktır. Yapay zekâ, sanal asistanlar, arama tahmin teknolojisi ve hatta araç çağırma hizmetleri aracılığıyla günlük yaşamda kendini göstermektedir³⁷.

Yetmişli yılların başında ve seksenli yılların sonunda iki “kış” geçirdikten sonra, YZ ikinci milenyumun başında, ortaya çıkan devasa bilgi işlem gücü, devasa veri setlerinin toplanması (büyük veri olgusu) ve veri analitiğindeki ilerlemeler (tanımlayıcıdan tahmin ediciye, hatta kuralcıya) sayesinde görkemli bir geri dönüş yaptı. Yapay zekâyâ yapılan yatırım ve ilgi, makine öğreniminin (ML) akademi ve endüstrideki birçok soruna başarıyla uygulandığı yirmi birinci yüzyılın ilk on yıllarında patlama yapmıştır. Derin öğrenmenin (Deep Learning-DL) sağladığı fırsatlar bu patlamayı daha da yoğunlaştırmıştır. Bu nedenle, literatürde yayınlanan makale sayısında bir patlama yaşanması da şaşırtıcı değildir. Web of Knowledge’da (tüm veri

³⁷ CFI TEAM, “Artificial Intelligence (AI)”, Artificial Intelligence - Definition, Examples, Types (corporatefinanceinstitute.com), Erişim tarihi: 18.07.2024.

tabanları) “Artificial Intelligence” arama dizesiyle yapılan bir aramanın sonuçları Şekil 2.23’de gösterilmektedir³⁸.



Şekil 2. 20. Yıllık yayın sayısı (Kaynak: Kaynak, 2021:3)

Yukarıdaki şekilde de görüldüğü üzere her geçen yıl yapay zekâ konusuna literatürde daha fazla yer verilmektedir. Konu popülerliğini giderek artırmakta ve daha fazla ilgi odağı olmaya başlamaktadır. Özellikle yapay zekânın kullanım alanının çok geniş olması literatürdeki bu genel eğilimi açıklamaktadır.


19 Şubat 2020 tarihinde Avrupa Birliği tarafından yayınlanan “White Paper” başlıklı raporda yapay zekâ, insan merkezli, etik, sürdürülebilir olması ve temel hak ve değerlere saygı göstermesi koşuluyla vatandaşlar, şirketler ve bir bütün olarak toplum için birçok fayda sunan stratejik bir teknoloji olarak tanımlanmaktadır. Söz konusu raporda yapay zekânın, Avrupa endüstrisinin rekabet gücünü güçlendirebilecek ve vatandaşların refahını artırabilecek önemli verimlilik ve üretkenlik kazanımları sunacağı bildirilmektedir. Ayrıca rapor yapay zekânın, iklim değişikliği ve çevresel bozulma ile mücadele, sürdürülebilirlik ve demografik değişikliklerle bağlantılı zorluklar ve demokrasilerimizin korunması ve gerekli ve orantılı olduğu durumlarda suçla mücadele

³⁸ Kaynak, 2021, 3.

de dahil olmak üzere en acil toplumsal zorluklardan bazılarına çözüm bulunmasına katkıda bulunabileceğini belirtmektedir³⁹.

2.1.2.1. Makine öğrenimi (Machine learning)

Bugün Yapay zekâ hakkında konuşulduğunda çoğunlukla Makine Öğrenimini (Machine Learning-ML) kastedilmektedir. Yapay zekâ, potansiyel kararların sonuçlarını tahmin etmek için bilgilere göre hareket etmektedir. Yapay zekâyı kullanan kişi veya kuruluş, algoritmaların önyargılı kararları azaltmak için yeterli veri kümeleriyle beslenmesinden sorumludur. Yalnızca veri kümeleri değil, algoritmanın kendisi de önyargılı olabilir. En iyi koruma, çeşitli ve kapsayıcı programcı gruplarına sahip olmak ve elbette ürün veya sisteme entegrasyonu da dahil olmak üzere algoritmanın düzenli olarak denetlenmesidir (Henz, 2021: 4).



Şekil 2. 21. Artificial Intelligence Process (Kaynak: LİveHome3D, 2024)

1980’lerden itibaren makine öğreniminin gelişmeye başladığı görülmektedir. Bu sistem, yapılandırılmış verilerle istenen çıktıyı üretmek için insan müdahalesi olmadan kendini değiştirebilen algoritmaların oluşturulmasıyla ilgilenen bir yapay zekâ alt kümesidir. Makine öğrenimi, genellikle “büyük veri” olarak adlandırılan, ekonominin

³⁹ European Commission, White Paper on Artificial Intelligence- A European approach to excellence and trust”, COM(2020) 65 final, Brussels, pp. 25.

tüm sektörlerinden gelen büyük miktarda bilginin açığa çıkması ile mümkün hale gelmiştir. Burada yalnızca verileri yapılandırmak ve etiketlemek için insana ihtiyaç duyulmaktadır⁴⁰.

İnsanlar deneyimlerden öğrenirken bilgisayarlar da aynısını yapabilir mi? Cevap “evet” ve ihtiyacımız olan şey makine öğrenimi. Makine öğrenimi, hesaplamalı yöntemler aracılığıyla deneyimlerden öğrenerek sistem performansını artıran bir tekniktir. Bilgisayar sistemlerinde deneyim veri biçiminde mevcuttur ve makine öğreniminin asıl görevi verilerden modeller oluşturan öğrenme algoritmaları geliştirmektir. Öğrenme algoritmalarını deneyim verileriyle besleyerek yeni gözlemlere (örneğin kesilmemiş bir karpuz) ilişkin tahminler yapabilen (örneğin karpuzun olgunlaştığı) bir model elde ederiz. Bilgisayar bilimini algoritmaların konusu olarak düşünersek, makine öğrenimi de öğrenme algoritmalarının konusudur. Makine öğrenimini gerçekleştirmek için öncelikle verilere sahip olmak gereklidir. Diyelim ki bir dizi karpuz kaydı toplandı. Örneğin, (renk=koyu; kök=kıvrıcık; ses=boğuk), (renk=yeşil; kök=kıvrıcık; ses=donuk), (renk=açık; kök=düz; ses=net),..., burada her parantez çifti bir kaydı çevreler ve “=” işareti “değer alır” anlamına gelir. Toplu olarak kayıtlar, her kaydın bir olayın veya nesnenin, örneğin karpuzun tanımını içerdiği bir veri seti oluşturur. Örnek adlandırılan bir kayıt, olayın veya nesnenin bazı özelliklerini (örneğin karpuzun rengi, kökü ve sesi) açıklar. Bu açıklamalara genellikle nitelik veya özellik adı verilir ve bunların yeşil ve koyu gibi değerlerine “nitelik alanı, örnek uzay veya girdi alanı” adı verilir. Örneğin renk, kök ve sesi üç eksen olarak düşünersek, karpuzları tanımlayan üç boyutlu bir uzaya yayılırlar ve her karpuzu bu uzayın içerisine konumlandırabiliriz. Uzaydaki her nokta bir konum vektörüne karşılık geldiğinden, bir örneğe “özellik vektörü” de denmektedir. Verilerden modeller oluşturmak için makine öğrenimi algoritmalarını kullanma sürecine de “öğrenme veya eğitim” denilmektedir (Zhou, 2022: 3).

Öğrenme modelleri aynı zamanda örüntü (pattern recognition) tanımada, örneğin bir kamera tarafından çekilen görüntülerin tanınmasında veya bir mikrofon tarafından yakalanan konuşmanın tanınmasında da kullanılmaktadır. Bugünlerde, akıllı telefon kullanarak insan aktivitesinin tanınmasından arabalardaki sürüş destek sistemlerine kadar farklı türdeki uygulamalar için kullanılan farklı türde işletim sistemi sensörleri bulunmaktadır. İnternet devasa bir veri deposudur. Bu yüzden aranılan şeye kısa sürede

⁴⁰ Live Home 3D, “AI in Interior Design”, March 2024, AI in Interior Design – Live Home 3D, Erişim tarihi: 19.07.2024.

eriřim saęlanması iin akıllı algoritmalara ihtiya vardır. Bugn sahip olunan verilerin nemli bir zellięi, farklı yntemlerden yani multimedyaadan kaynaklanmaktadır. Metin, resim, video, ses kliplerini aynı nesne veya olayla ilgili bu farklı kaynaklardan gelen bilgileri birleřtirmek makine ęrenimindeki zorluklardan biridir. Bu haliyle makine ęrenimi istatistik ve bilgisayar bilimlerinin kesiřim noktasında yer almaktadır (Alpaydın, 2021: 15).

2.2. Literatr alıřmaları

Bu blmde arařtırma konusu ile ilgili literatr taraması yapılmıřtır. Yapay zek uzaktan algılama, hem yapay zek hem de uzaktan algılama ve Sentinel-2A uydusu ile ilgili alıřmaların yer aldıęı literatr taraması iki grupta ele alınmıřtır.

2.2.1. Uzaktan algılama yntemi ile ilgili literatr alıřmaları

Uzaktan algılama yntemlerinde dikkat edilmesi gereken nemli kriterler yer almaktadır. Bunlardan en nemlileri uydu znrlę ve bant kombinasyonlarıdır. Bu iki kriterin seiminde gsterilecek zen yapılan alıřmanın bařarısına olduka nemli katkı saęlamaktadır. Ateř ve Demir tarafından 2009 yılında ele alınan “Uzaktan Algılamada znrlęe Baęlı Veri Kazanımı Potansiyeli” bařlıklı alıřmada uzaktan algılama grntlerinin hangi znrlkte, hangi lekteki harita alıřmasına geometrik, planimetrik ve ekonomik veri saęlayabileceęi konusunda bir bakıř aısı oluřturulmaya alıřılmaktadır (Ateř ve Demir, 2009). Kavzoęlu, lkesen ve řahin (2013) tarafından yazılan, “Multispektral Uydu Grntleri iin En Uygun Bant Seiminin Sınıflandırma Doęruluęuna Etkilerinin ielenmesi” adlı alıřmada temel ama veri seti ierisinde istenilen bant sayısı dikkate alınarak tm olası kombinasyonlar ierisinden en yksek sınıflandırma doęruluęunu veren bant kombinasyonunun tespit edilmesidir.

Deprem sonrası hasarın tespit edilmesi ve derecelendirmenin doęru yapılarak kurtarma faaliyetleri koordinasyonunun hızlı bir řekilde saęlanması yařanacak kayıpların nne geilmesi aısından nemlidir. Uzaktan algılamaya ynelik artan bu ilgi deprem sonrası yrtlecek faaliyetlerde de kendisini hissettirmeye bařlamıř ve literatrde bu ynde yrtlen alıřmaların arttıęı gzlemlenmiřtir. Aydın, Avřar ve Akay (2018), “Uydu Grntlerinden Zamansal Deęiřim Analizi iin Matlab Tabanlı Bir Ara Yz Tasarımı”

başlıklı makalelerinde de iki farklı zamanda aynı mekâna ait uydu görüntülerinin ortofoto, tematik haritalar ve/veya dijital görüntüler için geliştirilen bir Matlab ara yüzü ile değişim haritalarının belirlenerek ara yüzün doğruluğunun uzaktan algılamada sıklıkla kullanılan ticari bir yazılım ile karşılaştırılması amaçlanmaktadır. Budak, Doğan ve Abdikan'ın 2022 yılında yayımladıkları “İHA Görüntülerinden Konvolüsyonel Sinir Ağları ile Bina Hasar Tespiti” başlıklı çalışmalarında Sint Maarten adasında 6 Eylül 2017 tarihinde meydana gelen Irma Kasırgası'nın sebep olduğu hasarın uzaktan algılama yöntemleriyle tespit edilmesi öngörülmektedir.

2.2.2. Hem yapay zekâ hem de uzaktan algılama ile ilgili literatür çalışmaları

Evrişimli sinir ağı (convolutional neural network – CNN), bir veya daha fazla evrişimli katmana sahip çoklu sınıflandırma kapsamında başta İHA görüntüleri gibi verilerde ve bunların işlenmesinde yüksek doğruluk elde edebilen bir yapay sinir ağıdır (Lecun and etc., 1989: 541-551). Çalışmanın da odak noktasını oluşturan uzaktan algılama üzerine Westen (2000: 1609-1617) çalışmış ve doğal afet yönetimi için uzaktan algılama ile bu süreçte tehlikeleri en aza indirmeyi sağlayacak mekânsal da olmak üzere gerekli tüm verilere ulaşılması konusuna eğilmiştir. Coğrafi Bilgi Sistemi (CBS) ve Yapay Zekâ (AI) tabanlı bir sistem geliştiren Tang ve Wen bu sistem ile deprem öncesinde, yapının ve altyapının eksik noktalarının tespit edilmesini hedeflemiştir (Tang and Wen, 2009: 871-879). Fujita vd., bir binanın yıkılıp yıkılmadığını anlamak için tsunami öncesi ve sonrası uydu görüntülerini karşılaştırmak amacıyla bu yöntemi kullanmıştır (Fujita and etc., 2017: 5-8). Min Ji, vd., Evrişimsel Sinir Ağını ve uydu görüntülerini kullanarak 2010 Haiti depreminde yıkılan binaları tespit etmeye çalışmış (Ji, Liu and Buchroithner, 2018: 1-20). Baltacıoğlu vd. yapay sinir ağlarını kullanarak deprem hasarlarının hızlı bir şekilde tespit edilmesi üzerine bir çalışma gerçekleştirmiştir. Çalışma ile geliştirilen sistem sayesinde bina hasar miktarının tahmini yapılabilmektedir (Baltacıoğlu vd., 2010: 22-27). Hoskere vd., Eylül 2017'deki Orta Meksika depreminden sonra inceledikleri ve niteliksel olarak hasarlı değerlendirilen bir binada veri toplama için insansız hava araçlarını (İHA/Unmanned Aerial Vehicle-UAV) kullanırken (Hoskere and etc., 2018). Kalantar vd., deprem öncesi ve sonrası ortofoto görüntülere dayalı bina hasar tespiti için Evrişimsel Sinir Ağı mimarilerini incelemiştir (Kalantar and etc., 2020: 1-22). Tarhan vd., görüntü işlemenin

entegre afet yönetiminde yapay zekâ yöntemi olarak kullanılabilirliğini araştırmıştır (Tarhan vd., 2022: e116-131).

Maraş ve Sarıyıldız tarafından yapılan “İHA ile Derin Öğrenme Algoritmaları Kullanılarak Hasarlı Yapıların Tespit Edilmesi” adlı çalışma, makine öğreniminin alt dalı olan derin öğrenme ile bina hasar tespiti yapılması üzerine odaklanmaktadır. Çalışma sonucunda elde edilen veriler de ise yüksek oranda doğruluk payı fark edilmiştir (Maraş ve Sarıyıldız, 2023: 427-437). Bektaş Ekici ve Ustaoglu da binalardaki fiziksel hasarın derin öğrenme ile tespit edilmesi konusunu ele almıştır. Çalışmanın sonucunda derin öğrenme modellerinin görüntü analiz tekniklerini kullanarak binalardaki fiziksel hasarı tespit etme potansiyeli ortaya koyulmuştur. Modellerin yüksek doğruluğu ve hassasiyeti, derin öğrenmenin çeşitli gerçek dünya senaryolarında bina hasarını tanımlamak için yararlı bir araç olabileceğini göstermektedir. Ayrıca bu çalışma, daha fazla hasarı önlemeye ve etkilenen binalarda yaşayanların güvenliğini sağlamaya yardımcı olabilecek otomatik bina hasarı tespit sistemlerinin geliştirilmesi için bir temel oluşturmaktadır (Bektaş Ekici ve Ustaoglu, 2023: 291-299).

Makine öğrenmesi, bina hasar tespitinde etkili bir yöntem olarak kullanılmaktadır. Özellikle derin öğrenme algoritmaları, depremin ardından hasar görmüş binaların tespitinde faydalı olmuştur. Örneğin, evrimsel sinir ağları, yapı hasarının belirlenmesi ve analizi için sıklıkla tercih edilen bir teknik haline gelmiştir.

Yapılan bu çalışma ile literatür kısmında bahsedilen çalışmalar arasında yöntem olarak farklılıklar bulunmaktadır. Diğer çalışmalarda yüksek mekânsal çözünürlüklü uydu görüntüleri kullanmıştır. Elde ettiği görüntü verilerini sayısal forma dönüştürmeden görüntü işleme yöntemleri ile analiz yapılmıştır. Bu çalışmada ise düşük mekânsal çözünürlüklü uydu görüntülerinin yansıma değerleri sayısal veri formatında düzenlenerek makine öğrenmesi yöntemleri uygulanacaktır. Düşük çözünürlüklü uydu görüntülerinin yansıma değerleri kullanılarak makine öğrenmesi yöntemleri ile başarılı sonuçların elde edilebileceği öngörülmektedir.

Uydu çözünürlüğü arttıkça kapsadığı alan azalmaktadır. Bu durum, çalışma alanının (afet bölgesi) tamamının çalışılmasına engel olabilmektedir. Bölgelere ayrılarak yapılan çalışmanın, süreci uzatabileceği öngörülmektedir. Bu çalışmada ise, düşük çözünürlüklü uydu görüntüleri üzerinden anlamlı veri sağlanması halinde daha kısa sürede daha büyük bir bölgenin analizi yapılabilecektir. Deprem sonrası süreçte en

önemli kavramın zaman olduđu düşünöldüğünde yapılan çalışma ile deprem sonrası sürece önemli katkı sağlanacağı değeriendirilmektedir.

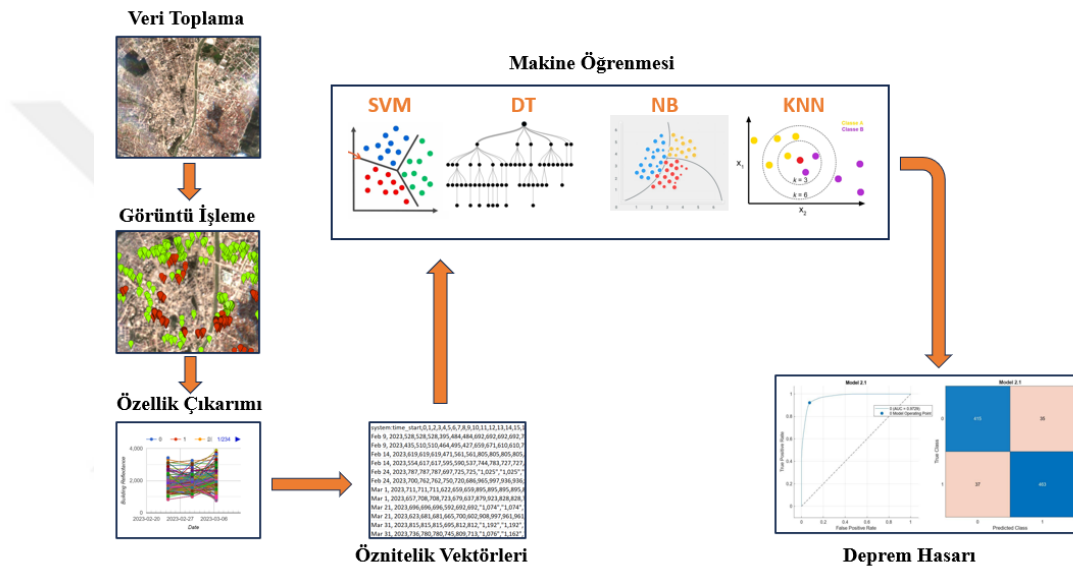


3. YÖNTEM

Bu bölümde önerilen sistem mimarisi, çalışma alanı, verilerin nasıl toplandığı ve verilerin nasıl çözümlendiği açıklanmıştır.

3.1. Önerilen Sistem Mimarisi

Çalışma kapsamında oluşturulan iş akış diyagramı Şekil 3.1’de yer almaktadır.




Şekil 3. 1. İş akış şeması

İş akış şeması aşağıdaki aşamalardan oluşmaktadır:

1. Uzaktan algılama yöntemi olarak Sentinel-2A uydusunun kullanılması
2. Bu uydu aracılığıyla deprem sonrası hasarlı bina alanlarının tespit edilmesi
3. Deprem alanından alınan verilerin işlenmesi
4. İşlenen verilerden özellik çıkarımının yapılması
5. Öznitelik vektörlerinin yani tarih aralığının belirlenmesi
6. Ulaşılan veri setlerine makine öğrenmesi yöntemlerinin uygulanması
7. Uygulanan yöntemler sonucunda bina hasar tespitlerinin yapılması

3.2. Çalışma Alanı

Çalışmada 6 Şubat 2023 ve 20 Şubat 2023 tarihlerinde meydana gelen toplamda üç büyük deprem (7.7; 7.6 ve 6.4) büyük oranda etkilenen Hatay ili seçilmiştir. En çok yıkımın olduğu ilçe ise Antakya olarak tespit edilmiştir. 6 Mart 2023 tarihinde T.C. Cumhurbaşkanlığı Strateji ve Bütçe Başkanlığı tarafından “2023 Kahramanmaraş ve Hatay Depremleri” başlığı ile yayınlanan rapora göre Adana’dan sonra en çok yıkımın yaşandığı il Hatay’dır. 2021 yılı TÜİK verilerine göre Hatay’da deprem öncesine ait toplam konut sayısı 847.380’dir ancak deprem sonrasında 406.849 binanın (357.467 mesken; 33.511 iş yeri; 10.382 kamu ve 5.489 diğer) hasar gördüğü tespit edilmiştir. Toplam acil+ağır+yıkık konut sayısı 215.255; orta hasarlı konut sayısı 25.957 ve az hasarlı konut sayısı ise 189.317 olarak belirlenmiştir (T.C. Cumhurbaşkanlığı Strateji ve Bütçe Başkanlığı, 2023: 26, 33 ve 36). Bu bölge üzerinde 9 Şubat 2023 tarihinde bina hasarlı bölgenin belirlenebilmesi için 1000 adet nokta seçilmiştir. Çalışma alanı Şekil 3.2.’de gösterilmiştir.



Şekil 3. 2. Çalışma alanı Google Earth uydu görüntüsü (sağ) ve geçmiş döneme ait deprem aktivitesi (sol) (Kaynak: AFAD, 2023: 3)

3.3. Verilerin Toplanması

Bu bölümde Google Earth Engine platformu üzerinden Antakya ilçesinde yer alan sağlam ve yıkık binaların deprem sonrası Sentinel-2 uydu görüntüsü kullanılmıştır.

Sentinel-2 uydusu görünür bantlarından elde edilen görüntüde, sağlam ve yıkık binalar işaretlenerek ilgili piksellerin yansıma değerleri grafik ve değer tablosu olarak platform üzerinden elde edilmiştir. Sentinel-2 uydu görüntüsü üzerinde 500 sağlam 500 yıkık olmak üzere toplam 1000 nokta işaretlenmiştir. Seçilen sağlam ve yıkık binalara ait uydu görüntüleri örnek olarak Şekil 3.3 ve Şekil 3.4'te gösterilmektedir.



Şekil 3. 3. Sağlam bina Google ve Sentinel-2 uydu görüntüleri (Kaynak: GEE Platformu, 2024)




Şekil 3. 4. Yıkılmış bina Google ve Sentinel-2 uydu görüntüleri (Kaynak: GEE Platformu, 2024)

3.3.1. Sentinel-2 uydusu özellikleri ve işleyişi

Sentinel-2 Multispektral 2A Uydusu, Avrupa Uzay Ajansı'nın Copernicus programı kapsamında yer alan bir kutup yörüngeli uydu olup, multispektral yüksek çözünürlüklü algılayıcılarla donatılmıştır. Uydunun ana misyonu tarımsal izleme, arazi örtüsü değişiklikleri, acil durum yönetimi gibi alanlarda görüntü elde etmektir. Sentinel-2A, Sentinel-2B ile birlikte çalışarak, 5 günde bir belirtilen enlem aralıklarında


görüntüler sunar ve bu görüntüler kullanıcılar için kolay ve ücretsiz erişim imkânı sağlamaktadır.



Şekil 3. 5. Sentinel-2 uyduları için spektral bantlar ve mekânsal çözünürlük (Kaynak: ESA, 2015)

Şekil 3.5'de bu uydudan 10 m, 20 m ve 60 m konumsal çözünürlüğü ile 13 spektral bant elde edildiği gösterilmektedir⁴¹. Sentinel-2, 13 spektral bandı 10 m'de dört bant, 20 m'de altı bant ve 60 m uzaysal çözünürlükte üç bant şeklinde örnekleyecek bir optik alet yükü taşımaktadır ve yörünge genişliği 290 km'dir. B4, B3 ve B2 doğal renk bandını göstermektedir. Çalışmada da bu bant kullanılmıştır.

⁴¹ European Space Agency (ESA), Sentinel-2 User Handbook, 2015, issue 1, rev. 2, pp. 51-52; düzenleyen Mehmet Ali Dereli, Sentinel-2A Uydu Görüntüleri ile Giresun İl Merkezi için Kısa Dönem Arazi Örtüsü Değişiminin Belirlenmesi, *Afyon Kocatepe Üniversitesi Fen ve Mühendislik Bilimleri Dergisi* AKÜ FEMÜBİD 19, 2019, 025501, ss. 361-368.



Şekil 3. 6. İkiz uydu Sentinel-2 yörünge konfigürasyonu (Kaynak: ESA, 2015: 9)

Sentinel-2'nin ikiz uyduları SPOT ve LANDSAT tipi görüntü verilerinin sürekliliğini sağlayarak, devam eden multispektral gözlemlere katkıda bulunmakta ve arazi yönetimi, tarım ve ormancılık, afet kontrolü, insani yardım operasyonları, risk haritalama ve güvenlik endişeleri gibi Copernicus hizmet ve uygulamalarına fayda sağlamaktadır⁴². Çalışmanın konusu kapsamında diğer çalışma alanlarından ziyade acil durum yönetimi başlığı altında yer alan afet kontrolü konusuna odaklanılmaktadır.

Sentinel-2'nin 10 m uzamsal çözünürlük bantları ve görevin yüksek tekrar ziyaret süresi, afet yardım çabalarını desteklemek için görüntülerin hızlı bir şekilde elde edilmesini ve teslim edilmesini desteklemektedir. Bu, daha önce deprem ve sel gibi doğal tehlikeler nedeniyle risk altında olduğu tespit edilen, tehdit altındaki binalar ve karmaşık yapılar da dahil olmak üzere kentsel alanların haritalanmasını içermektedir. Ayrıca, potansiyel yardım alanlarının ve ikmal yollarının durumunun belirlenmesine katkıda bulunmakta ve bunların olay öncesi ve sonrası görev planlamasında ve görev ömrü boyunca kontrolünde kullanılmasını sağlamaktadır. Copernicus Acil Durum Yönetim Hizmeti Haritalama Bileşeni (GIO EMS) 2012 yılında ilk faaliyetlerine başlamıştır. GIO EMS, uydu gözlem verilerini hızlı ve verimli bir şekilde sağlamakta ve mevcut yerinde veriler ve diğer veri kaynakları ile birlikte, doğal afetlere (örneğin seller, orman yangınları, toprak kaymaları, depremler ve volkanik patlamalar), insani

⁴² ESA, 2015: 9.

krizlere ve dünya çapında insan yapımı olaylara yönelik yardım çabalarının yönetimini desteklemektedir⁴³.

Sentinel-2 uydularının her biri yaklaşık 1.2 ton ağırlığında olup VEGA ve ROCKOT gibi küçük fırlatıcılarla uyumlu olacak şekilde tasarlanmıştır. Uydu ömrü 7.25 yıl olup, bu süreye 3 aylık yörüngede devreye alma aşaması da dahildir. Bataryalar ve itici yakıtlar, ömür sonu yörüngeden çıkarma manevraları da dahil olmak üzere 12 yıllık operasyonları karşılayacak şekilde sağlanmıştır. İki özdeş Sentinel-2 uydusu, ortalama 786 km yükseklikte güneşle eşzamanlı bir yörüngede, birbirlerine 180° fazlı olarak eşzamanlı çalışmaktadır. Her bir Sentinel-2 uydusunun yörüngesindeki konumu çift frekanslı bir Küresel Navigasyon Uydu Sistemi (GNSS) alıcısı tarafından ölçülmektedir⁴⁴.

Sentinel-2 uyduları 56° Güney'den (İsla Hornos, Horn Burnu, Güney Amerika) 83° Kuzey'e (Grönland'ın üstü) kadar uzanan bir enlem bandında kara ve kıyı bölgeleri üzerinde sistematik olarak veri toplamaktadır. Bu bölgedeki veri toplama çalışmaları şu alanları içermektedir: Yüzölçümü 100 km² den büyük adalar; Avrupa Birliği'ndeki adalar; kıyı şeridinde 20 km mesafedeki diğer tüm adalar; Akdeniz; tüm iç su kütleleri ve tüm kapalı denizler⁴⁵.

Potansiyel faaliyetlerle çekirdek X-bandı ve Ka-bandı istasyon ağını tamamlayan yerel/bölgesel istasyonlar Sentinel görev verisi toplama ve (NRT) üretimi sağlamaktadır: Sentinel-1 ve/veya Sentinel-2 için (NRT) veri işleme ve dağıtımı; belirli kapsama alanına/bölgeye, belirli hizmetlere vb. göre uyarlanmış (NRT) ürünlerinin detaylandırılması. Potansiyel olarak aşağıdakileri içeren belirli bölgesel veya tematik veri erişim düğümleri ve mekanizmaları Sentinel veri ürünlerinin yayılmasını ve verilere erişimi sağlamaktadır: Çekirdek yer segmentinden sistematik olarak alınan Sentinel ürünlerinin yeniden dağıtım hizmetleri, ek toplama noktaları (örn. ayna siteleri) haline gelmektedir; bölgesel çevrimiçi veri sunucuları ve belirli kullanıcı toplulukları için veri toplama noktaları ve diğerleridir⁴⁶.

Sentinel çekirdek yer segmenti tüm Sentinel verilerinin sistematik olarak elde edilmesini, işlenmesini ve dağıtılmasını sağlamaktadır. Sentinel uydularının izlenmesi ve kontrol edilmesi ve verilerin indirilmesi, işlenmesi ve kullanıcılara dağıtılması için unsurlar içermektedir. Ayrıca, veri ürünlerinin kalitesinin izlenmesi ve kontrol

⁴³ ESA, 2015, 14.

⁴⁴ ESA, 2015, 17.

⁴⁵ ESA, 2015: 18.


⁴⁶ ESA, 2015, 20-21.

edilmesinin yanı sıra veri arşivleme mekanizmalarına da sahiptir. Sentinel çekirdek yer segmentinin ana tesisleri şunlardır⁴⁷:

- Uçuş Operasyonları Bölümü (FOS)- izleme ve kontrol, tüm platform faaliyetlerinin yürütülmesi ve faydalı yük programlarının komuta edilmesi dahil olmak üzere Sentinel uydularının tüm uçuş operasyonlarından sorumludur.
- Çekirdek Yer İstasyonları-Sentinel verilerinin aşağı linklendiği ve ürünlerin neredeyse gerçek zamanlı olarak üretildiği yerdir. X-band yer istasyonları ağı tüm Sentinel verilerinin aşağı bağlantısına izin vermektedir. Bunlar, Sentinel verilerinin EDRS yer istasyonlarına ek aşağı bağlantısı için Avrupa Veri Aktarım Uydusu (EDRS) kullanımı ile tamamlanmaktadır.
- Görüntü Arşivleme ve İletişim Sistemleri (PACS), zaman açısından kritik olmayan sistematik veri işlemenin gerçekleştirildiği yerlerdir. Tüm veri ürünleri kullanıcıların çevrimiçi erişimi için arşivlenir ve bir PACS ağı, Sentinel verilerinin tüm işlemlerini ve arşivlenmesini destekler.
- Görev Performans Merkezleri (MPC) kalibrasyon, doğrulama, kalite kontrol ve uçtan uca sistem performans değerlendirmesinden sorumludur. MPC'ler belirli kalibrasyon/doğrulama, çevrim dışı kalite kontrol, algoritma düzeltme ve geliştirme faaliyetleri için uzman ekipler içermektedir.
- Sentinel Hassas Yörünge Belirleme (POD) tesisi veri ürünleri oluşturmak için gereken yörünge bilgilerini sağlamak üzere Sentinellerdeki GNSS alıcı verilerini kullanmaktadır.
- Copernicus Uzay Bileşeni Geniş Alan Ağı (CSC WAN), tüm ürünlerin ve yardımcı verilerin çeşitli yer segmenti tesisleri arasında taşınmasını ve veri ürünlerinin son kullanıcılara dağıtılmasını sağlamaktadır.

Google Earth Engine-Code Editor (GEE-CE) Platformu yardımıyla 9 Şubat 2023 tarihine ait B4, B3, B2 polarizasyonlu Sentinel-2A uydu görüntüleri kullanılmıştır. Çalışma alanını kapsayan Sentinel-2A B4, B3, B2 bant görüntüleri deprem öncesi ve sonrası olmak üzere sırasıyla Şekil 3.7 ve Şekil 3.8'de gösterilmektedir.

⁴⁷ ESA, 2015: 29.



Şekil 3. 7. Çalışma alanının Copernicus Sentinel 2 uydu görüntüsü 1 (Kaynak: ESA, 2023)

2 dünya gözlem uydusunun 25 Ocak 2023 tarihinde Antakya'ya ait çekmiş olduğu görüntü verilmektedir. Bu görüntü 6 ve 20 Şubat'ta meydana gelen depremlerden önce çekilmiştir⁴⁸.



Şekil 3. 8. Çalışma alanının Copernicus Sentinel 2 uydu görüntüsü 2 (Kaynak: ESA, 2023)

⁴⁸ The European Space Agency (ESA), "Destruction in Turkish city of Antakya", 20 Feb 2023, ESA - Sentinel-2, Erişim Tarihi: 23.07.2024.

Şekil 3.8’de Avrupa Uzay Ajansı (ESA) tarafından işletilen Copernicus Sentinel-2 dünya gözlem uydusunun 9 Şubat 2023 tarihinde Antakya’ya ait çekmiş olduğu görüntü verilmektedir. Bu görüntü 6 Şubat’ta meydana gelen depremden sonra çekilmiştir⁴⁹.

3.3.2. Google Earth Engine-Code Editor (GEE-CE) platform yapısı ve işleyişi

Google Earth Engine (GEE), kullanıcıların Google’ın altyapısı üzerinde coğrafi analiz yapmasına olanak tanıyan bir bilgi işlem platformudur. Kod düzenleyici, komut dosyalarını yazmak ve çalıştırmak için kullanılan web tabanlı bir IDE’dir. Explorer, veri kataloğunu keşfetmeye ve basit analizler yürütmeye yönelik bir web uygulamasıdır. İstemci Kitaplıkları, web API etrafında Python ve JavaScript (program dilleri) sarmalayıcıları sağlar⁵⁰. Python, veri analizi ve arka uç geliştirme gibi görevler için ideal olan okunabilirlik ve basitliği vurgularken, JavaScript öncelikle web geliştirme için kullanılır ve doğrudan web tarayıcılarında dinamik ve etkileşimli işlevsellik sunmaktadır⁵¹. Google, Landsat’ın verilerini arşivleyerek açık kaynak kullanımı için bulut bilişim motoruna bağlamıştır.

GEE, uydu görüntülerini, jeo-uzamsal veri kümelerini ve sağlam bir veri analiz araçları paketini birleştiren gezegen ölçeğinde jeo-uzamsal analiz için bulut tabanlı bir platformdur. Kullanıcıların büyük miktarda jeo-uzamsal veriyi işlemesine ve küresel ölçekte karmaşık analizler gerçekleştirmesine olanak tanıyarak araştırma, çevresel izleme ve haritalama uygulamaları için bir kaynak haline getirmektedir. GEE, Landsat arşivlerinin tamamı (1970’lerden itibaren), Sentinel’den optik ve radar verileri, dijital yükseklik modelleri (DEM’ler) ve Shuttle Radar Topography Mission (SRTM) ve Advanced Spaceborne Thermal Emission and Reflection Radiometer (ASTER) Global Digital Elevation Model (GDEM) dahil olmak üzere diğer yükseklik verileri dahil olmak üzere birkaç petabayt açık kaynaklı jeo-uzamsal veriye erişim sağlamaktadır. Geçtiğimiz birkaç yıl içinde GEE, Gridded Population of the World (GPW) ve Global Rural-Urban Mapping Project (GRUMP) gibi sosyal-ekonomik ve demografik verilere de erişim sağlamaya başlamıştır. Dolayısıyla, GEE’nin arazi kullanımı ve arazi örtüsü

⁴⁹ ESA, 2023.

⁵⁰ Google Earth Engine (GEE). “A Planetary-Scale Platform for Earth Science Data and Analysis”. Google Earth Engine, Erişim Tarihi: 19.06.2024.

⁵¹ GreeksForGreeks, “Difference Between Python ve JavaScript”, 20 Jun 2024, Difference between Python and JavaScript - GeeksforGeeks, Erişim Tarihi: 24.07.2024.

değişikliği, doğal kaynak yönetimi ve afet müdahalesi dahil olmak üzere çevresel izleme ve haritalama uygulamalarında da kullanılmaktadır. GEE, seller, orman yangınları ve depremler gibi doğal afetlerin kapsamını ve etkisini hızlı bir şekilde değerlendirmek ve tarımsal izlemeyi desteklemek (mahsul büyümesini izlemek, mahsul stresini tespit etmek ve mahsul verimini değerlendirmek) için de veri sağlamaktadır. Küresel ölçekteki bu detaylı mekansal-zamansal veri setleri sayesinde GEE, küresel ölçekte, ulusal ve alt ulusal ölçekte çevresel analizler için yaygın olarak kullanılan bir yöntemdir⁵². Bu çalışmada GEE-CE aracılığıyla JavaScript programla dili kullanılarak Sentinel-2 uydu verilerine erişilmiş ve bu veriler kullanılmıştır.

3.4. Verilerin Çözümlemesi için Uygulanan Makine Öğrenmesi Yöntemleri

Uzaktan algılama sistemlerinin gelişmesi uzaktan algılama verilerinin arttırmış ve bu veriler birçok farklı alanda kullanılmaya başlanmıştır. Bu alanlardan biri de deprem bölgeleridir. Nesne olarak seçilen bu deprem bölgelerinde bina hasar tespiti için sınıflandırmalar yapmak oldukça zordur. Bunun sebebi evlerin birbirlerine çok yakın inşa edilmesidir. Bu durum bina hasar tespitinde yanıltmaya neden olmaktadır. Dahası uydu görüntüsü ile yerden çekim görüntülerinin karşılaştırılması sonucunda farklı değerler ortaya çıkabilmektedir. Bu da deprem bölgesi için uydudan alınan bina hasar değerleriyle sınıflandırma yapabilme seçeneğine eğilimi sağlamaktadır. Çünkü uydu görüntüsü insan eli ile gerçekleştirilen yerden çekim görüntülerinden çok daha hızlı bir şekilde gerçekleşmektedir. Bu çalışmada nesne verilerinin özellik çıkarımı için GEE platformu aracılığıyla Sentinel-2 uydusu spektral bant parametleri (B4, B3, B2) kullanılmıştır.


B4 kırmızı, B3 yeşil ve B2 mavi kanalları kullanan doğal renk bandı kombinasyonudur ve bu parametreler 10 metrelik bir zemin örnekleme mesafesine sahiptir. Doğal renk bandı ile elde edilen görüntülerde dünya sağlıklı bir insan gözü dünyayı nasıl görüyorsa o şekilde resmetmektedir. Yani bitki örtüsü yeşil, kentler beyaz ve gridir. Su ise ne kadar temizse rengi ona bağlı olarak koyu mavi bir tondur⁵³.

Makine öğrenmesinin gözetimli/denetimli öğrenme (supervised learning), gözetimsiz/denetimsiz öğrenme (unsupervised learning) ve pekiştirmeli öğrenme

⁵² Earth Blox, “Everything You Need To Know About Google Earth Engine”, 6 Feb 2023, Everything you need to know about Google Earth Engine | Blog | Earth Blox, Erişim Tarihi: 24.07.2024.

⁵³ WebJeoloji, “Sentinel 2 Grupları ve Kombinasyonları”, 6 Eylül 2020, Sentinel 2 Grupları ve Kombinasyonları - WebJeoloji, Erişim Tarihi: 25.07.2024.

(reinforcement learning) olmak üzere üç çeşidi bulunmaktadır. Şekil 3.9'da makine öğrenimi çeşitleri ve bunların algoritmaları ile birlikte verilmiştir. Denetimli öğrenme de sınıflandırma ve regresyon olmak üzere ikiye ayrılmaktadır ve Lineer Regresyon, Lojistik Regresyon, CART, Naïve Bayes ve K-NN denetimli öğrenme modeline örnektir. Çalışma kapsamında da denetimli öğrenme modeli örnekleri kullanılmıştır.




Şekil 3. 9. Makine öğrenmesi türleri (Kaynak: Towards Datas Science, t.y.)

3.4.1. Destek vektör makinesi/DVM (Support vector machine-SVM)

Support Vector Machine (SVM), denetimli bir makine öğrenme algoritmasıdır ve verileri sınıflandırmak için optimal bir çizgi veya hiper düzlem bulma yöntemidir. Hem sınıflandırma hem de regresyon görevleri için kullanılabilir. Verileri analiz eden ve örüntüleri tanıyan ilişkili öğrenme algoritmalarına sahip en yaygın denetimli öğrenme modellerinden biridir. Hem regresyon hem de sınıflandırma problemlerini çözmek için kullanılmaktadır. DVM'ler ilk olarak 1992 yılında B.E. Boser ve arkadaşları tarafından tanıtılmış ve 1994 yılında el yazısı rakam tanımadaki başarısı nedeniyle popüler hale gelmiştir. XGBoost ve AdaBoost gibi boosting algoritmalarının ortaya çıkmasından önce DVM'ler yaygın olarak kullanılmaktaydı. Her biri iki kategoriden birine veya diğerine ait olarak işaretlenmiş bir dizi eğitim örneği verildiğinde, DVM eğitim algoritması yeni örnekleri bir kategoriye veya diğerine atayan bir model oluşturur ve bu da onu olasılıksal olmayan ikili doğrusal bir sınıflandırıcı yapar. DVM'leri uygulamanın amacı, uzayı sınıflara ayırmamıza yardımcı olmak için iki boyutta en iyi doğruyu veya ikiden fazla boyutta en iyi hiper düzlemi bulmaktır.

Hiper düzlem (çizgi), maksimum marj (her iki sınıfın veri noktaları arasındaki maksimum mesafe) aracılığıyla bulunur⁵⁴.



Şekil 3. 10. DVM yapısı (Kaynak: Akca, 2020)

Küçük ve orta ölçekteki karmaşık veri setleri için kullanılan DVM boyutu yüksek olan dizilerde oldukça etkili bir yöntemdir. Siyahlar ve beyazlar olmak üzere iki sınıfa ayrılan tabloda DVM gelecek olan verinin hangi sınıfa ait olduğunu belirlemektedir. Bunun için de bir doğru çizilir ve bu doğrunun ± 1 'i arasında kalan yeşil bölge ne kadar geniş ise sınıfsal ayrılma o kadar iyi yapılır. Bu bölgeye de “margin” adı verilmektedir⁵⁵.

3.4.2. Naive Bayes (NB) algoritması

⁵⁴ KDnuggets, “A Top Machine Learning Algorithm Explained: Support Vector Machines (SVM)”, 2 April 2020, A Top Machine Learning Algorithm Explained: Support Vector Machines (SVM) - KDnuggets, Erişim Tarihi: 24.07.2024.

⁵⁵ Mehmet Fatih Akca, “Nedir Bu Destek Vektör Makineleri? (Makine Öğrenmesi Serisi 2)

Naive Bayes algoritması, sınıflandırma problemleri için kullanılan denetimli bir makine öğrenimi algoritmasıdır. Özellikle metin sınıflandırma gibi görevlerde yaygın olarak kullanılır ve Bayes teoremine dayanır. Algoritma, bağımsızlık varsayımı altında özellikler arasındaki olasılık ilişkilerini değerlendirerek sınıflandırma yapmaktadır.

Bayes Kuralı olarak da bilinen bu teorem, koşullu olasılıkları “tersine çevirmemizi” sağlar. Koşullu olasılıklar, başka bir olayın gerçekleşmesi durumunda bir olayın olasılığını temsil eder ve aşağıdaki Bayes Kuralı formülü ile gösterilir⁵⁶:

$$P(Y|X) = \frac{P(X \text{ and } Y)}{P(X)} \quad (3.1)$$

Örneğin bir binanın hasarlı olup olmadığını tespit edebilmek için bir uydu görüntüsü alınmaktadır. Bina ağır hasarlı olma olasılığına %5 dersek bu durum öncelikli olasılık olacaktır. Ancak görüntü sonucunda binanın ağır hasarlı olduğu belirlenirse önceki olasılık bu ek bilgiyi hesaba katacak şekilde güncellenecek ve sonsal olasılık haline gelecektir. Bu örnek, Bayes Teoremi kullanılarak aşağıdaki denklemle gösterilebilir:

$$p(\text{ağır hasarlı} | \text{görüntü}) = \frac{p(+ \text{ görüntü} | \text{ağır hasarlı})p(\text{ağır hasarlı})}{P(+ \text{ görüntü} | \text{ağır hasarlı})p(\text{ağır hasarlı}) + p(+ \text{ görüntü} | \text{hasar yok})p(\text{hasar yok})} \quad (3.2)$$


Ancak, bina yaşı, zemin gibi diğer değişkenler göz önüne alındığında önceki olasılıklara ilişkin bilginin kesin olması mümkün olmadığından, genellikle rastgele örneklerden elde edilen olasılık dağılımlarından yararlanılmaktadır ve denklem $P(Y|X) = P(X|Y)P(Y) / P(X)$ şeklinde basitleştirilmektedir.

3.4.3. Karar ağacı algoritması (Decision tree algorithm)

Karar ağacı algoritması, hem sınıflandırma hem de regresyon görevlerinde kullanılan, hiyerarşik bir yapıya sahip olan bir denetimli öğrenme yöntemidir. Bu algoritma, karar veya testlerin temsil edildiği düğümlerden oluşan bir akış diyagramı

⁵⁶ IBM, “What are Naïve Bayes classifiers?”, What Are Naïve Bayes Classifiers? | IBM, Erişim Tarihi: 24.07.2024.

gibi bir yapı kullanarak kararlar almak veya tahminlerde bulunmak için kullanılır. İç düğümlerin bir veri kümesinin özelliklerini, dalların karar kurallarını ve her yaprak düğümünün sonucu temsil ettiği ağaç yapılı bir sınıflandırıcıdır. Bir Karar ağacında, Karar Düğümü ve Yaprak Düğümü olmak üzere iki düğüm vardır. Karar düğümleri herhangi bir karar vermek için kullanılır ve birden fazla dala sahiptir. Yaprak düğümleri ise bu kararların çıktısıdır ve başka dal içermez. Kararlar veya test, verilen veri kümesinin özellikleri temelinde gerçekleştirilir. Verilen koşullara dayalı olarak bir soruna/karara yönelik tüm olası çözümleri elde etmek için kullanılan grafiksel bir gösterimdir. Karar ağacı olarak adlandırılır, çünkü bir ağaca benzer şekilde kök düğümlerle başlar, daha fazla dala genişler ve ağaç benzeri bir yapı oluşturur. Bir ağaç oluşturmak için, Sınıflandırma ve Regresyon Ağacı algoritması anlamına gelen CART algoritmasını kullanıyoruz. Bir karar ağacı basitçe bir soru sorar ve cevaba göre (Evet/Hayır) ağacı alt ağaçlara böler. Şekil 3.9'da karar ağacının genel yapısı verilmiştir⁵⁷:



Şekil 3. 11. Karar ağacının genel yapısı

Karar Ağaçları genellikle bir karar verirken insanın düşünme yeteneğini taklit eder, bu nedenle anlaşılması kolaydır. Karar ağacının arkasındaki mantık kolayca anlaşılabilir çünkü ağaç benzeri bir yapı gösterir. Bir karar ağacında, verilen veri kümesinin sınıfını tahmin etmek için algoritma ağacın kök düğümünden başlar. Bu algoritma, kök özneliğin değerlerini kayıt (gerçek veri kümesi) özneliğiyle

⁵⁷ Javat Point, “Decision Tree Classification Algorithm”, Decision Tree Algorithm in Machine Learning - Javatpoint, Erişim Tarihi: 24.07.2024.

karşılaştırır ve karşılaştırmaya dayanarak dalı takip eder ve bir sonraki düğüme atlar. Bir sonraki düğüm için algoritma yine öznitelik değerini diğer alt düğümlerle karşılaştırır ve daha ileri gider. Ağacın yaprak düğümüne ulaşıncaya kadar işleme devam eder. Karar ağacı algoritmasının avantajları: Bir insanın gerçek hayatta herhangi bir karar verirken izlediği süreci takip ettiği için anlaşılması kolaydır; Kararla ilgili problemleri çözmek için çok faydalı olabilir; Bir sorun için tüm olası sonuçları düşünmek yardımcı olur ve diğer algoritmalara kıyasla daha az veri temizleme gereksinimi vardır. Algoritmanın dezavantajlarına bakacak olursak: Karar ağacı çok sayıda katman içerir ve bu da onu karmaşık hale getirir; Rastgele Orman algoritması kullanılarak çözülebilecek bir aşırı uyum sorunu olabilir ve daha fazla sınıf etiketi için karar ağacının hesaplama karmaşıklığı artabilir⁵⁸.


3.4.4. K-En yakın komşuluk (k-Nearest neighbours-kNN)

K-En Yakın Komşular (k-NN) algoritması basit bir prensiple çalışmaktadır. Yeni bir veri noktasını, özellik uzayında “k” en yakın noktanın baskın kategorisine (sınıflandırma görevlerinde) veya ortalama sonucuna (regresyon görevlerinde) göre sınıflandırır. “k” kullanıcı tarafından tanımlanan bir sabittir ve yakınlık genellikle Öklid, Manhattan veya Hamming mesafesi gibi bir mesafe metriği ile belirlenmektedir. “k” seçimi ve mesafe metriğinin türü algoritmanın performansını önemli ölçüde etkilemektedir. K-NN, eğitim verilerinin genelleştirilmesinin bir sorgu yapılana kadar ertelendiği bir tür örnek tabanlı öğrenme veya tembel öğrenmedir ki bu da onu uygulama açısından en basit makine öğrenimi algoritmalarından biri yapmaktadır. Ancak her sorgu örneğinden tüm eğitim örneklerine olan mesafenin hesaplanmasını içerdiğinden test sırasında potansiyel olarak hesaplama açısından pahalıdır⁵⁹. K-En Yakın Komşular (k-NN) algoritması, parametrik olmayan bir yöntemdir. Yani altta yatan veri dağılımı hakkında herhangi bir varsayımda bulunmaz. Bunun yerine, girdi özelliklerinin eğitim verilerine benzerliğine dayalı tahminler yapar⁶⁰.

⁵⁸ Javat Point, 2024.

⁵⁹ Envisioning, “k-NN (K Nearest Neighbors)”, Envisioning | k-NN (k-Nearest Neighbors), Erişim Tarihi: 24.07.2024.

⁶⁰ Muhammad Bilal Ijaz, “Understanding the k-Nearest Neighbors (k-NN) Algorithm”, 24 Mart 2024, Understanding the k-Nearest Neighbors (k-NN) Algorithm | by Muhammad Bilal Ijaz | Medium, Erişim Tarihi: 24.07.2024.



Şekil 3. 12. K-NN algoritmasının çalışması (Kaynak: Anand, 2023)

K parametresi, bir tahmin yapmak için kullanılan komşu sayısını kontrol eden bir hiperparametredir. K değeri çapraz doğrulama kullanılarak seçilebilir. Örneğin Şekil 3.12'ye göre, yeni veri noktası bir çiçekse ve k en yakın komşularının hepsi papatya çiçeğiye, yeni veri noktası büyük olasılıkla bir papatya çiçeğidir. K-NN algoritması, çeşitli problemleri çözmek için kullanılabilen çok yönlü bir algoritmadır. Genellikle spam filtreleme, dolandırıcılık tespiti ve görüntü sınıflandırma gibi sınıflandırma problemleri için kullanılmaktadır⁶¹.

K-NN algoritması temel olarak, bir veriyi sınıflandırmak veya bir değer tahmin etmek için o veriye en yakın k komşuyu bulma prensibine dayanmaktadır. K-NN algoritmasının nasıl çalıştığının adımları aşağıda yer almaktadır:

- 1. Veri Seti ve Özellikler:** İlk olarak, bir eğitim veri setine ihtiyaç vardır. Bu veri seti, farklı özelliklere (özellikler, değişkenler) ve her bir verinin ait olduğu sınıfa (sınıf etiketleri) sahip örneklerden oluşmaktadır.
- 2. Mesafe Ölçümü:** Algoritma, verilerin arasındaki benzerliği ölçmek için bir mesafe ölçüm yöntemi kullanır. En yaygın kullanılan mesafe ölçümleri arasında Euclidean mesafesi, Manhattan mesafesi ve Minkowski mesafesi bulunmaktadır.
- 3. K Değerinin Belirlenmesi:** Kullanıcı, k değerini (en yakın komşu sayısını) belirlemektedir. Bu değer genellikle tek bir sayı olarak seçilir ve komşu sayısı ile eşleşen en yakın örnekleri dikkate alır. K değerinin büyüklüğü, model performansını etkileyebilir.

⁶¹ Divey Anand, "Introduction to the KNN", 7 Sep. 2023, KNN Machine Learning Algorithm: A Beginner's Guide (linkedin.com), Erişim Tarihi: 25.07.2024.

4. Sınıflandırma veya Regresyon:

- **Sınıflandırma:** Yeni bir veri noktası geldiğinde, eğitim setindeki tüm noktalarla mesafeleri hesaplanır ve en yakın k nokta bulunur. Bu k noktanın sınıf etiketleri göz önünde bulundurularak, en sık görülen sınıf etiketi, yeni veri noktasının sınıf etiketi olarak atanır (veya ağırlıklı ortalama gibi yöntemlerle de sınıflandırma yapılabilir).
- **Regresyon:** Eğer k -NN bir regresyon problemi için kullanılıyorsa, en yakın k komşunun hedef değerlerinin ortalaması (veya medyanı) alınarak yeni veri noktasının tahmin edilen değeri belirlenir.

5. Sonuçların Değerlendirilmesi:

Algoritmanın performansı, genellikle k -Fold çapraz doğrulama gibi teknikler kullanılarak test edilir. Bu süreç, k -NN modelinin nasıl bir doğrulukla çalıştığını anlamaya yardımcı olmaktadır.

Basit ve kolay uygulanabilir olması, sınıflandırma veya regresyon için esneklik sağlaması k -NN algoritmasının avantajıyken bellek kullanımı ve hesaplama süresi gereksiniminin özellikle büyük veri setlerinde yüksek olabilmesi ayrıca uygun k değerinin seçilmesi, yüksek boyutlu verilere (curse of dimensionality) duyarlı olması gibi sorunlar da dezavantajıdır. k -NN algoritması, birçok gerçek dünya uygulamasında etkili bir şekilde kullanılmakta ve veri analizi, öneri sistemleri ve daha birçok alanda yaygın olarak tercih edilmektedir⁶².

3.4.5. Ensemble sınıflandırma algoritması

Ensemble classifiers, birden fazla makine öğrenmesi modelinin bir araya getirilmesiyle oluşturulan sistemlerdir. Amaç, tek bir modelin yapabileceğinden daha iyi tahminler yapmaktır. Bu yöntemlerle her modelin eksik yönleri dengelenir.

Bagging: Bootstrap Aggregation, farklı veri örneklemeleri üzerinden birden fazla model eğitilmesini sağlar ve sonuçları ortalama alarak veya oylayarak birleştirir. Örneğin, Random Forest algoritması.


Boosting: Modeller sıralı olarak eğitilir ve her model, bir öncekinin hatalarını düzeltmeye çalışır. Bu, modellerin birikimli olarak daha iyi performans göstermesini sağlar. Örneğin, AdaBoost ve Gradient Boosting.

⁶² k -NN algoritması ile ilgili daha fazla bilgi için bkz. Jaime Salvador-Meneses, Zoila Ruiz-Chavez and Jose Garcia-Rodriguez, Compressed k NN: K-Nearest Neighbors with Data Compression, *Entropy* volume 21, issue 3, 2019, pp. 234-254.

Stacking: Farklı türdeki modellerin tahminlerini bir araya getirir ve bir meta-model, bu tahminleri kullanarak nihai tahmini yapar.

3.5. Konfüzyon Matrisi

Konfüzyon matrisi, bir veri kümesi için öngörülen değerleri gerçek değerlerle karşılaştırarak makine öğreniminde sınıflandırma modeli performansını değerlendirmeye yardımcı olur. Konfüzyon matrisi (veya hata matrisi), sınıflandırıcı algoritma sonuçları için bir görselleştirme yöntemidir. Daha spesifik olarak, belirli bir sınıfın temel gerçek örneklerinin sayısını öngörülen sınıf örneklerinin sayısına göre ayıran bir tablodur. Konfüzyon matrisleri, bir sınıflandırma modelinin performansını ölçen çeşitli değerlendirme ölçütlerinden biridir. Diğerlerinin yanı sıra hassasiyet ve geri çağırma gibi bir dizi başka model performans ölçütünü hesaplamak için kullanılabilirler.⁶³



Şekil 3. 13. Konfüzyon matris düzeni (Kaynak: ibm, 2024)

Konfüzyon matrisinde, sütunlar belirli bir sınıfın tahmin edilen değerlerini temsil ederken, satırlar belirli bir sınıfın gerçek değerlerini (yani temel gerçeği) temsil eder. Bu ızgara yapısı, tüm sınıflar için doğru tahmin ve yanlış tahmin sayısını yan yana görüntüleyerek model sınıflandırma doğruluğunu görselleştirmek için kullanışlı bir araçtır. TP; pozitif sınıf için doğru tahminlerin sayısını, FP; pozitif sınıf için yanlış

⁶³ IBM, “Confusion Matrix”, 19 Ocak 2024, What is a confusion matrix?

tahminlerin sayısını, FN; negatif sınıf için yanlış değerlerin sayısını, TN; negatif sınıf için doğru değerlerin sayısını temsil etmektedir. Bu değerlerin her birini toplamak, modelin toplam tahmin sayısını verecektir.

Sınıflandırıcı tahmin sonuçlarının kolayca erişilebilir görselleştirmesi göz önüne alındığında, konfüzyon matrisi diğer model değerlendirme metriklerini hesaplamak için yararlıdır. Değerler matristen basitçe çekilebilir ve model performansını ölçmek için bir dizi denkleme yerleştirilebilir.

3.5.1. Doğruluk

Bir konfüzyon matrisin doğruluk oranı, her sınıf için doğru tahmin edilen veri sayısı toplamının toplam veri sayısına oranıdır. Modelin ne kadar sağlıklı sınıflandırma yaptığının göstergesidir. Başarı durumu modelin özelliğine göre bu değer üzerinden değerlendirilebilir.

$$\text{Doğruluk(Accuracy)} = \frac{TP + TN}{\text{TOPLAM}} \quad (3.3)$$

3.5.2. Hata oranı

Konfüzyon matrisin hata oranı, her sınıf için yanlış tahmin edilen veri sayısı toplamının toplam veri sayısına oranıdır. Aynı zamanda 1'den doğruluk oranının çıkarılması ile hesaplanır.

$$\text{Hata Oranı(Error Rate)} = \frac{FP + FN}{\text{TOPLAM}} \quad (3.4)$$

$$\text{Hata Oranı} = 1 - \text{Kesinlik} \quad (3.5)$$

3.5.3. Hassasiyet

Hassasiyet, pozitif sınıf tahminlerinin gerçekten söz konusu sınıfa ait olma oranıdır. Kesinliği anlamının bir başka yolu da, rastgele seçilen bir örneğin belirli bir sınıfa ait olma olasılığını ölçmesidir.

$$\text{Hassasiyet(Precision)} = \frac{TP}{TP+FP} \quad (3.6)$$

3.5.4. Duyarlılık

Gerçek pozitif örneklerin ne kadarının pozitif olarak sınıflandırıldığını gösterir.⁶⁴

$$\text{Duyarlılık(Recall)} = \frac{TP}{TP+FN} \quad (3.7)$$

3.5.5. F1 skor

F1 Skor ise Hassasiyet (Precision) ve Duyarlılık (Recall) skorlarının harmonik ortalamasıdır.


$$\text{F1 Skor} = 2 * ((\text{Precision} * \text{Recall}) / (\text{Precision} + \text{Recall})) \quad (3.8)$$

3.6. ROC Eğrisi

Alıcı çalışma karakteristikleri (ROC) eğrileri, gerçek pozitif oranı ve yanlış pozitif oranını çizerek sınıflandırıcıların performansını gösteren grafiklerdir. ROC eğrisinin altındaki alan (AUC), makine öğrenimi algoritmalarının performansını ölçer.

⁶⁴ MEDIUM, 2023, Nisan 14, “Makine Öğrenmesi Sınıflandırma Modelleri”, [online], “Makine Öğrenmesi Sınıflandırma Modelleri: Accuracy, Precision, Recall, F1-score, Log Loss and Micro-Macro-Weighted Avg”, [Erişim Tarihi: 21.10.2024].

ROC eğrileri, sınıflandırıcı seçiminin istatistiksel doğruluğunu görsel olarak tasvir eder.⁶⁵



Şekil 3. 14. ROC eğrisi (Kaynak: Google, 2024)

ROC eğrisinin x ekseninde yanlış pozitif oran (FPR), y ekseninde doğru pozitif oran yer almaktadır. Eğrinin altında kalan alan (AUC) arttıkça sınıfların birbirinden ayrılma performansı da artmaktadır. En iyi ROC eğrisini oluşturabilmek için sınıflar arası ayırt edici en iyi threshold değerini bulmamız gerekir. Örneğin hasta olan ve hasta olmayan kullanıcıların olduğu bir veri setinde bir sınıflandırma problemi çalıştığımızı düşünelim. Yapılan tahminler sonucunda her bir veri için skorlar atanır. Farklı threshold değerlerini deneyerek en iyi F1 değerini elde ettiğimizde en iyi ROC eğrisini de oluşturmuş oluruz. AUC Modelin sınıfları ne kadar başarılı ayırt edebildiğini anlatır. AUC arttıkça, model 0'ları 0 ve 1'leri 1 olarak tahmin etmede daha iyidir. Örneğin hasta olan ve olmayan kullanıcıların olduğu bir veri setinde AUC ne kadar yüksekse, model hastalığı olan ve olmayan hastaları ayırt etmekte daha iyi performans gösterir.⁶⁶

⁶⁵ Coursera, 2024, Mart 19, “What Is ROC Curve in Machine Learning?”, [online], “Learn how the ROC curve helps you analyze classification algorithms in machine learning”, [Erişim Tarihi: 22.10.2024].

⁶⁶ Medium, 2020, Haziran 12, “ROC and AUC”, [online], “ROC and AUC”, [Erişim Tarihi: 22.10.2024].


3.6. Cross Validation (Çapraz Doğrulama)

Cross-validation, makine öğrenmesi modellerinin performansını değerlendirmek için kullanılan bir yöntemdir. Amacı, modelin genelleme yeteneğini test etmek ve modelin aşırı öğrenmeden (overfitting) kaçınmasını sağlamaktır. En yaygın kullanılan yöntemlerden biri K-Fold Cross-Validation'dır. Bu yöntemde, veri seti K eşit parçaya bölünür. Model, her defasında K-1 parçayla eğitilir ve kalan 1 parça üzerinde test edilir. Bu işlem, her parça bir kez test verisi olarak kullanılmış olacak şekilde K kez tekrarlanır. Sonuçlar, her bir katmanın (fold) hata oranlarının ortalaması alınarak değerlendirilir.

Leave-One-Out Cross-Validation (LOOCV) ise, K-Fold Cross-Validation'un özel bir türüdür. Bu yöntemde, veri集中的 her bir örnek sırasıyla test verisi olarak kullanılır ve kalan tüm örnekler modelin eğitimi için kullanılır.

4. BULGULAR VE TARTIŞMA

Çalışmada örnek alan olarak kısa sürede üç büyük depremden etkilenmesinden dolayı Hatay ili seçilmiştir. Daha sonra en fazla yıkımın olduğu yerler manuel olarak tespit edilmiştir. 6 ve 20 Şubat depremleri ardından Hatay genelinde toplamda 37 bin 813 bina incelenmiş ve 8 bin 268 bina acil yıkılacak, ağır hasarlı, yıkık bina olarak açıklanmıştır. Antakya ise 5 bin 382 binadan 2 bin 619'u acil yıkılacak, ağır hasarlı, yıkık olarak Hatay'ın depremden en çok etkilenen ilçesi olmuştur⁶⁷.



Şekil 4. 1. Kandilli Rasathanesi-Büyükçat-Samandağ-Hatay (M=6.4) depreminin lokasyon haritası (Kaynak: tmmob, 2023: 4)


Şekil 4.1’de 20 Şubat 2023 tarihinde Hatay’da meydana gelen depreme ait lokasyon haritası verilmiştir. TMMOB tarafından yapılan çalışmada 12 Şubat 2023 itibariyle, kentin bazı bölgelerinde henüz çalışma yapılmadığı, kırsal alanlara arama kurtarma ve müdahale ekiplerinin geç ulaştığı, bölgeye gönderilen yardımların, kurtarma çalışmalarının ve yapısal hasarın boyutlarına ilişkin sağlıklı bilgilerin alınamadığı, su ve elektrik dağıtımının yapılamadığı, hijyen koşulları sağlanamadığı için salgın hastalık riskinin artması, pistteki kırıklar nedeniyle uçuşların yapılamaması

⁶⁷ TRT Haber, “Depremin Ardından En Çok Hasarlı İlçeler Belli Oldu”, 14 Şubat 2023, Depremin ardından en çok hasarlı ilçeler belli oldu - Son Dakika Haberleri (trthaber.com), Erişim Tarihi: 25.07.2024.

rapor edilmiştir⁶⁸. Bu durum deprem sonrası hasar tespitinin hızlı ve doğru bir şekilde yapılması gerektiğini ortaya çıkarmıştır.

Çalışma bölgesinde en fazla yıkımın Antakya’da olmasından dolayı bu bölge üzerinde manuel olarak 1000 adet nokta işaretlenmiştir. Yıkımın yoğun olduğu tarihte (9 Şubat), seçilen bu noktaların konumları GPS ile kaydedilmiş ve bu konumlar Sentinel-2 uydusuna aktarılmıştır. Veri setini oluşturmak için Sentinel-2 uydusu spektral band parametreleri (B4, B3, B2) kullanılarak her bir nokta için yansıma değerlerine ulaşılmıştır. Amaç B4, B3, B2 bantları kullanılarak bölgedeki binaların hasarlı olup olmadığını otomatik olarak tespit etmektir. Bu doğrultuda yansıma değerlerinin bulunduğu veri setlerine, hasarın otomatik olarak belirlenebilmesi için makine öğrenmesi modelleri uygulanmıştır.


Aşağıda yer alan Şekil 4.2 ve Şekil 4.3’de, x ekseni uydu görüntüsünün tarih bilgisini, y ekseni seçilen noktalara ait yansıma değerlerini temsil etmektedir. Grafikte her bir noktaya ait iki yansıma değeri olup bu iki değer bir doğru ile birleştirilmiştir. Her bir nokta farklı renk ile temsil edilmiştir. Grafik incelendiğinde doğruların genelde yatay şekilde olduğu görülmektedir. Bu durumun nedeni, gün içerisinde aynı noktadan geçen Sentinel-2 A-B uyduları tarafından birbirine yakın yansıma değerlerinin ölçülmesidir. Aynı zamanda bu durum elde edilen verinin tutarlılığını göstermektedir.



Şekil 4. 2. Hasarsız binaların sentinel-2 msı uydusu spektral bant

Çalışma bölgesinde işaretlenen hasarsız bina noktalarına ait 9 Şubat tarihindeki Sentinel-2 MSI uydusunun görünür bantlarındaki yansıma değerleri GEE platformu üzerinden elde edilmiştir.

⁶⁸ TMMOB, 2023, 13-14.



Şekil 4. 3. Hasarlı/Yıkık binaların sentinel-2 msı uydusu spektral bant

Çalışma bölgesinde işaretlenen hasarlı/yıkık bina noktalarına ait 9 Şubat tarihindeki Sentinel-2 MSI uydusunun görünür bantlarındaki yansımaya değerleri GEE platformu üzerinden elde edilmiştir. Araştırma bulguları ve tartışma bölümünü yazmaya buradan başlayınız.


4.1. Doğal Renk Bandına Ait Sonuçlar (B4, B3, B2)

Bu bölümde doğal renk bandına ait veri setine uygulanan makine öğrenmesi yönteminin sonuçları aktarılmıştır.

4.1.1. Makine öğrenmesi ile elde edilen sonuçlar


Veri seti, K-Fold Cross Validation (Çapraz doğrulama) yöntemi ile alt veri gruplarına ayrılmıştır. K değeri değiştirilerek sistemin maksimum başarısı elde edilmeye çalışılmıştır. Elde edilen sonuçlar incelendiğinde K değerinin değiştirilmesinin sistem performansını çok etkilemediği görülmüştür. Çalışmada K değeri 10 seçilerek, veri seti farklı makine öğrenmesi modellerini eğitmek için kullanılmıştır. Çalışmada yaygın olarak kullanılan makine öğrenmesi yöntemleri uygulanmış olup bu yöntemler içerisinde en çok tercih edilen Destek Vektör Makineleri, Navie Bayes, Karar Ağaçları, K- En Yakın Komşuluk ve Birleştirilmiş (Ensebmle) makine öğrenme yöntemleri ile elde edilen sonuçlar ayrıntılı olarak açıklanmıştır. Makine öğrenmesi modelleri parametre ayarlarına göre alt gruplarda çeşitlendirilmiştir. Elde edilen sonuçlar

incelendiğinde Karar Ağaçları, K-En Yakın Komşuluk (K-NN) ve Ensemble (Birleştirilmiş) makine öğrenme yöntemlerinin diğer yöntemlere göre daha başarılı olduğu gözlemlenmiştir. Bu modeller arasındaki başarı da kullanılan parametre ayarına göre farklılık göstermektedir. Örneğin, K-NN makine öğrenmesi yönteminin en başarılı modeli %85.1 başarı ile Weighted K-NN modelidir. Uygulanan makine öğrenmesi yöntemlerinin doğruluk oranları Şekil 4.4’de verilmiştir.




Şekil 4. 4. Veri setine uygulanan makine öğrenmesi modelleri ve elde edilen doğruluk oranları

Destek vektör makinesi sınıflandırma yöntemleri büyük boyutlu verilerde daha başarılı olduğu bilinmekte olup özellik seçimi ve parametre ayarlarının düzenlenmesi ile başarı oranı değişebilmektedir. DVM aynı zamanda aşırı öğrenmeye de maruz kalabilmektedir. Veri seti ile yapılan çalışma incelendiğinde, elde edilen en yüksek başarı oranı %62.1 ile Fine Gaussian SVM modeli olmuştur. Bu durumun nedeni veri boyutunun az olması (öznitelik bilgi çeşitliliği) ve modelin aşırı öğrenmeye maruz kalması olarak değerlendirilmektedir. Sonuçları içeren konfüzyon matrisi ve ROC eğrisi Şekil 4.5’de verilmiştir.



Şekil 4. 5. DVM sınıflandırma algoritması ROC eğrisi (sol) ve konfüzyon matrisi (sağ)


Navie Bayes sınıflandırma algoritması öznitelik bilgilerini birbirinden bağımsız olarak değerlendirmekte olup az sayıda veri noktasının olması yanlış tahminleme yapmasına neden olabilmektedir. Veri seti ile yapılan çalışmada elde edilen sonuçlar incelendiğinde bu durumun etkili olduğu değerlendirilmektedir. Navie Bayes sınıflandırma algoritması alt modelleri içerisinde en yüksek başarı %66.8 ile Kernel Navie Bayes modeli ile elde edilmiştir. Kernel NB modeli, Gaussian NB modeline göre doğrusal olmayan veri setlerinde daha başarılı sonuçlar elde etmektedir. Sonuçları içeren konfüzyon matrisi ve ROC eğrisi Şekil 4.6’da verilmiştir.



Şekil 4. 6. Navie Bayes sınıflandırma algoritması ROC eğrisi (sol) ve konfüzyon matrisi (sağ)


K-En Yakın Komşuluk (KNN) modeli uygulanırken en önemli girdilerden biri komşuluk değeridir. Bu değer manuel olarak el ile girilmektedir. Doğal renk bandları için bu komşuluk değeri optimum başarı sağlandığı için 10 olarak seçilerek

uygulanmıştır. Elde edilen %85.1 başarı oranı, veri setimizin içerdiği değerlerin birbirinden kolay ayırt edilebileceğini göstermektedir. Sonuçları içeren konfüzyon matrisi ve ROC eğrisi Şekil 4.7’de verilmiştir.



Şekil 4. 7. KNN sınıflandırma algoritması ROC eğrisi (sol) ve konfüzyon matrisi (sağ)


Karar Ağaçları (Decision Tree-DT) uygulanırken maksimum dallanma 100 olarak seçilmiştir. Bu dallanma sayısı ile en yüksek başarı fine tree modelinde elde edilmiştir. Uygulanan DT yöntemi için sistemin başarısı %81.6 olarak elde edilmiştir. Sonuçları içeren konfüzyon matrisi ve ROC eğrisi Şekil 4.8’de verilmiştir.



Şekil 4. 8. Karar ağaçları sınıflandırma algoritması ROC eğrisi (sol) ve konfüzyon matrisi (sağ)

Bagged tree modeli, birden fazla karar ağacının bir araya getirilmesiyle oluşturulan bir ensemble yöntemidir. Bu yöntemde, her bir karar ağacı, aynı veri

setinden bootstrap örnekleme yöntemiyle oluşturulan farklı veri alt kümeleri üzerinde eğitilir. Daha sonra bu ağaçların tahminleri birleştirilir ve ortalama alınır veya çoğunluk oylaması ile nihai tahmin yapılır. Bagging, modelin varyansını azaltarak daha stabil ve genel geçer sonuçlar elde etmeyi hedefler. Örneğin, bir karar ağacının tek başına yapabileceği hatalar, bagged tree modeli ile minimize edilebilir. Yapılan çalışmada Bagged Tree algoritması, Karar Ağacı Algoritmasından daha başarılı sonuç vermiştir. Uygulanan BT yöntemi için sistemin başarısı %86 olarak elde edilmiştir. Sonuçları içeren konfüzyon matrisi ve ROC eğrisi Şekil 4.9’da verilmiştir.



Şekil 4. 9. Bagged Trees sınıflandırma algoritması ROC eğrisi (sol) ve konfüzyon matrisi (sağ)

Uygulanan makine öğrenmesi yöntemlerinin performansını değerlendirmek için göz önünde bulundurulması gereken değerler Çizelge 4.1’de verilmiştir.

Çizelge 4. 1. Makine öğrenmesi yöntemleri ile elde edilen performans parametre değerleri

Sınıflandırma Yöntemi	Alt Model	Accuracy % (Doğruluk)	Precision % (Hassasiyet)	Recall % (Duyarlılık)	F1 Score % (F1 Skor)
Tree (Karar Ağaçları)	Fine Tree	81.6	82	81.6	82
Naive Bayes	Kernel Naive Bayes	66.8	68	66.8	66
SVM (Destek Vektör Matrisleri)	Fine Gaussian SVM	62.1	63	62.1	61
KNN	Weighted KNN	85.1	85	85.1	85
Ensemble	Bagged Trees	86	86	86	86

Doğal renk bandına ait olarak makine öğrenmesi yöntemleri ile elde edilen sonuçlar yüksek oranlara sahiptir. Bu sonuçlar çalışmanın amacının net bir şekilde ortaya koyulmasını sağlayarak çalışmanın önemine uygun verilerin elde edilmesine katkı sunmuştur. Çalışma sayesinde deprem sonrası bina hasar tespitlerinin hız kazanarak deprem bölgesindeki iyileştirme çabalarına ivedilikle müdahale edilebileceği sonucuna ulaşılmaktadır.

Uydu görüntülerinin kullanılarak deprem bölgelerinin analiz edildiği ve öncesi-sonrası karşılaştırılmasının yapıldığı literatür çalışmaları Çizelge 4.2’de verilmiştir. Bu çalışmalarda da deprem bölgesi incelemesinin yapılmasının barınma ihtiyaçlarının karşılanması ve yardım faaliyetlerinin bölgeye hızlı bir şekilde ulaştırılmasına yardımcı olması açısından önemi vurgulanmaktadır. Ancak tablodan da görüleceği üzere doğruluk oranı çoğu çalışma için hesaplanmamıştır. Bu konuyla ilgili daha detaylı bilgilerin ve sayısal verilerin yer aldığı çalışmalara ihtiyaç vardır. Yapılan çalışma ile bu durum ele alınmıştır. Aynı zamanda literatürde yüksek çözünürlüklü uydu görüntüleri kullanılarak daha dar alanlar üzerinde yapılan çalışmalar ağırlıklıdır. Çalışmamız daha düşük çözünürlükte geniş alanı kapsayacak şekilde tasarlanmış ve diğer çalışmalara yakın sonuçlar elde edilmiştir.

Çizelge 4. 2. Makine öğrenmesi yöntemleri ile elde edilen performans parametre değerleri

Veri Seti Aracı	Deney Alanı	Doğruluk	Metot	Referans
LANDSAT 7+ (Enhanced Thematic Mapper)	17 Ağustos 1999 Gölcük Depremi	15 metre konumsal çözünürlükte yüksek doğruluk oranı.	Pankromatik Band	(Aksu, Erdoğan ve Yılmaz., 2001)
MISR	26 Ocak 2001 Gujarat Depremi	Yüzey deformasyonları tespit edilmiştir.	InSAR Tekniği	Pinty et al., 2003)
LANDSAT 7 ETM+ uydu görüntüleri	23 Ekim 2011 Van Depremi	Deprem öncesi ve sonrasına ait çizgisellik hızı tespit edilmiştir.	PCI LINE modülü (Geomatica yazılımı)	(Arslan ve Akyürek, 2015)
UltraCam-X sayısal hava kamerası	23 Ekim 2011 Van Depremi	Yıkılmış binalar %91.42 oranında tespit edilmiştir.	Sayısal Yüzey Modeli ve “Alan\Çevre” yaklaşımı	(Kayı, Erdoğan ve Yılmaz, 2015)

Pleiades ve WorldView-2 (WV-2)	30 Ekim 2020 İzmir Depremi	Yıkılan binaların büyük oranda tespit edilmesi.	Işınlama yöntemi (optik uzaktan algılama), radar interferometrisi (InSAR), ve coğrafi bilgi sistemleri (CBS)	(İTÜ UHUZAM, 2020)
Wildfire Havadan Sensör Platformu (WASP)	12 Ocak 2010 Haiti Depremi	Yüksek çözünürlüklü (kırmızı, yeşil ve mavi) görüntülerin elde edilmesi.	IR bantları	(Amerika Birleşik Devletleri Jeolojik Araştırması (USGS))
5 cm ve 7 cm çözünürlüğe sahip insansız hava aracı görüntü	12 Ocak 2010 Haiti Depremi	%95.12 genel doğruluk oranıyla sınıflandırılma yapılmıştır.	Mask Region-based Convolutional Neural Network (Mask R-CNN)	Maraş ve Sarıyıldız, 2023).
QB2 uydu Görüntüsü	23 Ekim 2011 Van Depremi	Homojen bölgede QB2 uydu verisinin doğruluklarının (%70 ve %77), aynı bölgelerin ortogörüntü doğruluklarına (%92 ve %96) nazaran daha düşük çıktığı sonucuna ulaşılmıştır.	Coğrafi Bilgi Sistemleri (CBS)	(Sabuncu, 2011)
Sentinel-1	6-7 Şubat Kahramanmaraş Depremleri	Yer kabuğunda kaymalar tespit edilmiştir.	InSAR Tekniği	(Bayraktar vd., 2023)

5. SONUÇLAR VE ÖNERİLER

Bu bölümde çalışmada ulaşılan sonuçlara yer verilmiş olup araştırma ile ilgili öneriler aktarılmıştır.

5.1 Sonuçlar

Çalışmanın çıkış noktası olarak belirlenen “Uzaktan algılama yöntemi ile deprem sonrası süreçte hasar tespiti noktasında yapay zekâ kullanılabilir mi?” araştırma sorusuna çalışma sonucunda deprem sonrası bina hasar çalışmalarının uzaktan algılama yöntemleri ve yapay zekâ kullanılarak kısa sürede gerçekleştirilebileceği sonucuna ulaşılmıştır. Uzaktan algılama yöntemleri günümüzde giderek daha da popüler hale geliyorken bir yandan da ilgi yapay zekâ üzerinde artmaya başlamıştır. Yapay zekânın günden güne artan ünü onun kullanım alanlarını da genişletmiştir. Çalışmada ise deprem sonrası bina hasar tespitinin hızlı bir şekilde gerçekleştirilmesi noktasında uzaktan algılama yöntemleri ile yapay zekânın kullanımı üzerinde durulmuştur.

Çalışmanın giriş kısmında araştırma hakkında genel bilgilere yer verilmiştir. Çalışmanın ikinci kısmında ise araştırma konusu ile ilgili olarak literatür taraması yapılmıştır. Bu bölümde konu çerçevesinde yapılan çalışmalara değinilirken diğer yandan da literatürdeki boşluk tespit edilmiştir. Ayrıca çalışmanın ana kısmı olan çalışmanın temel mantığının anlaşılması adına teorik kısma yer verilmiştir. Bu kısımda özellikle kavram tanımlamaları aktarılmıştır. Özellikle de uzaktan algılamanın ve yapay zekânın ne olduğu bu bölümde aktarılmıştır. Üçüncü bölümde çalışmada kullanılan metot ve yöntemlerden bahsedilmiştir. Veri setinin oluşturulması için Google Earth Engine sitesi ve Sentinel-2A uydusu kullanıldığından bu site ve uydu hakkında detaylı bilgilere yer verilmiştir. Verilerin çözülmesi için ise makine öğrenmesi yöntemleri kullanılmıştır. Doğal renk uydu bantları B4, B3 ve B2’nin kullanılması ile Sentinel-2A uydusundan elde edilen uydu görüntüleri makine öğrenmesi yöntemleri ile analiz edilmiştir.

Çalışma bölgesi, 6 ve 20 Şubat 2023 tarihlerinde meydana gelen üç depremden derin bir şekilde etkilenmiş olmasından dolayı Hatay ili olarak seçilmiş olup en ağır yıkımın yaşandığı ilçe ise Antakya olarak belirlenmiştir. 2021 TÜİK verilerine göre Hatay’daki toplam konut sayısı 847.380’dir. Depremden sonra ise ağır+orta hasarlı+az

hasarlı olmak üzere toplamda 406.849 bina depremde etkilenmiştir. Hatay’da toplam bina sayısının yarısına yakını depremde dolayı zarar görmüştür. Bu oldukça yüksek bir sayıdır. Bu durum depremde etkilenen insan sayısını da artırmaktadır. Bu yüzden çalışma bu bölgede yaşayan ve depremde etkilenen insanları da kapsamaktadır. Çalışmanın amacı bina hasar tespitinin hızlı bir şekilde yapılmasıdır. Ancak depremde etkilenen insanların sosyal hayatlarına da ivedilikle yeniden uyum sağlanmasına da katkı sağlayacağından örneklem olarak deprem halkı da seçilmiştir.

Hipotez 1 bağlamında uzaktan algılama sonucunda elde edilen görüntülerin yapay zekâ ile analiz edilmesi sonucunda verilere ulaşılmış ve hipotez 2 doğrultusunda ise bu verilerin doğruluğu kontrol edilmiştir. Hipotez 3 ile de yapay zekâ verilerinin doğruluk oranının yüksek çıkması ihtimali üzerinde durulmuş ve elde edilen oranlar bu hipotezin de işlevselliğinin ortaya çıkmasını sağlamıştır.

K-En Yakın Komşuluk (KNN) modeli, doğal renk bandları için bu komşuluk değeri optimum başarı sağlandığı için 10 olarak seçilmiş ve elde edilen %85,1 başarı oranı veri setinin içerdiği değerlerin birbirinden kolay ayırt edilebileceğini göstermiştir. Karar Ağaçları (Decision Tree-DT) uygulanırken maksimum derinlik 2 olarak seçilmiş ve sistemin başarısı %81.6 olarak elde edilmiştir. Bagged Tree modelinde, en yüksek başarı oranı olarak %86 kaydedilmiştir

“Yüksek Mekânsal Çözünürlüklü Uydu/Uçak Platformlu Görüntüler ve CBS Teknolojisi Kullanılarak Van-Erciş Depremi Sonrası Bina Hasar Tespiti” başlıklı doktora tezi çalışmasında Aslı Sabuncu, 23 Ekim 2011 tarihinde Van’da meydana gelen 7.2 büyüklüğündeki Van-Erciş depremini çalışma alanı olarak seçmiş ve yüksek mekânsal çözünürlüklü uydu görüntüleri ve ortogörüntüler ile, deprem sonrası yıkılmış ve/veya ağır hasar görmüş binaların sınıflandırma yöntemleri yardımıyla tespit edilmesini, deprem sonrası bölgeye ait değişimin izlenmesini ve Coğrafi Bilgi Sistemi (CBS) tabanlı 3-boyutlu interaktif veritabanı oluşturularak farklı mekânsal sorgulamaların yapılabilmesini amaçlamıştır. Çalışmada yer alan deprem sonrası veri setine ait doğruluk analizlerine göre, QB2 uydu görüntüsünün ve ortogörüntünün (HGK) heterojen dokudaki bölgelerde birbirine yakın (%65) çıktığı ancak her iki homojen bölgede de QB2 uydu verisinin doğruluklarının (%70 ve %77), aynı bölgelerin ortogörüntü doğruluklarına (%92 ve %96) nazaran daha düşük çıktığı sonucuna ulaşılmıştır. Alansal olarak toplam değişim, ortogörüntülerde yapılan analiz sonrası heterojen bölgelerde 11140 m², homojen bölgelerde ise 2011 m² olarak belirlenirken yüksek mekânsal çözünürlüklü uydu verileri ile yapılan değişim saptama analizinde ise

heterojen bölgelerdeki toplam değişim, 11039 m²; homojen bölgelerde de 2158 m² olarak saptanmıştır. Heterojen dokudaki bölgeler ile ilgili bu farklılığın yüksek mekânsal çözünürlüklü verilerde yıkılmış bina sınıflarında yapılan yanlış sınıflandırma hatasından kaynaklandığı; homojen bölgelerde ise yıkılmış bina ile yol sınıflarının karışması gibi bazı sınıfsal karışımlar sonucunda bu hatanın meydana geldiği aktarılmıştır. Ancak çalışma sonucunda uzaktan algılama ve CBS teknolojilerinin afet sonrasında meydana gelen hasarı tespit etme sürecinde oldukça önemli bir role sahip oldukları ortaya çıkmıştır.

İki çalışma arasında yöntem olarak farklılıklar bulunmaktadır. Sabuncu çalışmasında yüksek mekânsal çözünürlüklü uydu görüntüleri kullanmıştır. Elde ettiği görüntü verilerini sayısal forma dönüştürmeden görüntü işleme yöntemleri ile analiz yapmıştır. Bu çalışmada ise düşük mekânsal çözünürlüklü uydu görüntülerinin yansıma değerleri sayısal veri formatında düzenlenerek makine öğrenmesi yöntemleri uygulanmıştır. Sonuç olarak, Sabuncu'nun çalışmasında da ulaşıldığı gibi uzaktan algılama ve ek olarak yapay zekâ yöntemlerinin afet sonrası süreçte kullanılmasının olumlu olduğu sonucuna varılmıştır.

5.2 Öneriler

Bu tez çalışmasında depremin insan yaşamı üzerindeki etkileri ve deprem sonrasındaki sürecin işleyişi açıklanmıştır. Depremin olumsuz etkilerini kısa zamanda analiz etmek ve afet sonrası süreci yönetmek için birçok yöntem geliştirilebilir. Bu çalışmada önerilen yöntem ile düşük mekânsal çözünürlüklü uydu görüntüleri üzerinde makine öğrenmesi yöntemlerinin kullanılabilirliğini sunmaktır. Önerilen çalışmada Şubat 2023 tarihinde Hatay'da meydana gelen deprem sonrası uydu görüntüleri kullanılmıştır. Bu veriler optik uydu bantlarına sahip Sentinel-2 uydusu kullanılarak elde edilmiştir. Pasif algılama ile çalışan uydu güneşten saçılan ışığın yeryüzü üzerindeki yansımalarını toplayarak bu sinyallerin geri saçılım değerlerini sayısal olarak vermektedir.

GEE-CE(Google Earth Engine-Code Editor) platformu aracılığıyla elde edilen veri setleri excel formatında alınarak veri düzenlemesi yapılmış ve makine öğrenmesi modelleri için uygun veri seti haline dönüştürülmüştür. Çalışmada üç farklı makine öğrenmesi yöntemi ile başarılı sonuçlar elde edilmiştir.

Yüksek orana sahip bir şekilde elde edilen veriler çalışmanın amacı ve önemini ortaya koymaktadır. Makine öğrenmesi ile ulaşılan oranlar deprem sonrası bina hasar tespitinin hızlı bir şekilde yapılmasını sağlayarak yardım faaliyetlerinin koordinasyonuna hizmet edebilecektir. Kurtarma operasyonları ne kadar hızlı olursa depremten etkilenen insan sayısı da o kadar azalacak ve deprem sonrası iyileştirme çalışmaları da bir o kadar olumlu sonuçlar verecektir.

Uzaktan algılama yöntemleri kullanılarak elde edilen uydu görüntülerinin yapay zekâ metotları ile analizi neticesinde ulaşılan veriler başta AFAD olmak üzere ilgili kurumlara iletildiğinde kurum hızlı bir şekilde harekete geçebilecektir. Ayrıca hasar tespitinin hızlı olması deprem bölgesine olan ulaşım yollarının tespiti ile de alternatif yol seçeneklerini ortaya çıkaracaktır. Böylece bölgeye ulaşım noktasında zaman kaybı en aza indirilecektir.

Çalışma bu öneriler doğrultusunda benzer çalışmalardan ayrılarak ön plana çıkmaktadır. Deprem bölgesi daha önceden düşük çözünürlüklü uydu görüntülerinin piksel yansıma değerleri kullanılarak makine öğrenmesi yöntemleri ile analiz edilmemiştir. Çalışma sonucunda elde edilen yüksek orana sahip veriler araştırmanın doğruluk payını artırmakta ve çalışmanın amacını net bir şekilde ortaya koymaktadır.

Sonuç olarak bu çalışmayla makine öğrenmesi modelleri kullanılarak hasarlı bina alanı tespiti yapılabilir ve bunun sonucunda da müdahale noktasında hızlı bir şekilde hareket edilerek çevreye ve depremten etkilenen insanlara olan olası ciddi zararlar, görüntü kirliliği, ulaşımın aksaması gibi sorunlar engellenebilir.

KAYNAKLAR

- Afet ve Acil Durum Yönetimi Başkanlığı (AFAD), (Şubat, 25, 2023), 20 Şubat 2023 Yayladağı (Hatay) MW 6.4 Depremine İlişkin Ön Değerlendirme Raporu, Deprem Dairesi Başkanlığı, ss. 3.
- Akca, M.F. 2020, Ağustos 25, Nedir bu destek vektör makineleri? (Makine Öğrenmesi Serisi-2). Medium: <https://medium.com/deep-learning-turkiye/nedirbu-destek-vektör-makineleri-makine-öğrenmesi-serisi-2-94e576e4223e> [Erişim Tarihi: 17 Temmuz 2023].
- Amerika Birleşik Devletleri Jeolojik Araştırması (USGS), 2010, “Explore Search: Haiti”, Search | U.S. Geological Survey, [Erişim Tarihi: 16.11.2024].
- Alpaydın, E., 2021, *Machine learning*, The MIT Press: Massachusetts, pp. 15. Anand, D., 2023, September 7, “Introduction to the KNN”, [online], KNN Machine Learning Algorithm: A Beginner's Guide (linkedin.com), [Erişim Tarihi: 25.07.2024].
- Arama Kurtarma Derneği (AKUT), “Deprem nedir?”, [online], Deprem Nedir? | Deprem Önlemleri | AKUT Arama Kurtarma Derneği, [Erişim Tarihi: 15.07.2024].
- Arslan, O., Akyürek, Ö., 2015, LANDSAT 7 ETM+ Görüntüleri Üzerinden Çizgiselliklerin Otomatik Çıkarımı ve Analizi: Van Depremi Örneği, 10-12 June 2015, 5th International Earthquake Symposium, pp. 1-12, Kocaeli, Türkiye.
- Ateş, S., Demir, E., 2009, Uzaktan algılamada çözünürlüğe bağlı veri kazanımı potansiyeli, *TMMOB Harita ve Kadastro Mühendisleri Odası 12. Türkiye Harita Bilimsel ve Teknik Kurultayı*, 11-15 Mayıs 2009, Ankara.
- AXA Sigorta, 11.07.2023, “Revize deprem, artçı deprem ve öncü deprem nedir?”, [online], Revize Deprem, Artçı Deprem ve Öncü Deprem Nedir? (axasigorta.com.tr), [Erişim Tarihi: 15.07.2024].
- Aydın, G., Avşar, E.Ö., Akçay, Ö., 2018, Uydu görüntülerinden zamansal değişim analizi için Matlab tabanlı bir ara yüz tasarımı, *VII. UZAKTAN ALGILAMA-CBS SEMPOZYUMU (UZAL-CBS 2018)*, 18-21 Eylül 2018, Eskişehir.
- Baltacıoğlu, A.K., vd., 2010, Deprem hasarlarının hızlı tespitinde yapay sinir ağları yaklaşımı, *Mühendislik Bilimleri ve Tasarım Dergisi*, 1 (1), s.22-27.
- Başarsoft, “Uzaktan algılama”, [online], Uzaktan Algılama Nedir? - Kullanım Alanları | Başarsoft (basarsoft.com.tr), [Erişim Tarihi: 16.07.2024].
- Bayraktar, C., vd., 2023, Geomorphological Observations, GIS, Remote Sensing, and Web-Based Mapping in the Areas Affected by the February 6, 2023 Kahramanmaraş Earthquakes. Deprem Araştırmaları Sanal Konferansı, pp.32-33, Ankara, Türkiye.

- Budak, G.Y., Doğan, M.S., Abdikan, S., 2022, İHA görüntülerinden konvolüsyonel Sinir ağları ile bina hasar tespiti, *VIII. UZAKTAN ALGILAMA-CBS SEMPOZYUMU (UZAL-CBS 2022)*, 17-19 Kasım 2022, Ankara.
- Campbell M., Jovanovic, M., 2021, Conversational artificial intelligence: Changing tomorrow's health care today, *The IEEE Computer Society*, 54 (8), 89-93.
- Carter, W.N., 2008, *Disaster Management A Disaster Manager's Handbook*. Asian Development Bank.
- CFI TEAM, "Artificial intelligence (AI)", Artificial Intelligence - Definition, Examples, Types (corporatefinanceinstitute.com), [Erişim tarihi: 18.07.2024].
- Copeland, B.J., 2024, July 16, "Artificial intelligence", [online], Artificial intelligence (AI) | Definition, Examples, Types, Applications, Companies, & Facts | Britannica, [Erişim tarihi: 18.07.2024].
- Corbane, C., Carrion, D., Lemoine, G., Broglia, M., 2011, Comparison of damage assessment maps derived from very high spatial resolution satellite and Aerial imagery produced for the Haiti 2010 Earthquake, *Earthquake Spectra*, 27, 205-207.
- Depremle İlgili Teknik Bilgiler, "Deprem nedir?", Deprem Nedir? (boun.edu.tr), [Erişim Tarihi: 15.07.2024].
- Coursera, 2024, Mart 19, "What Is ROC Curve in Machine Learning?", [online], "Learn how the ROC curve helps you analyze classification algorithms in machine learning", [Erişim Tarihi: 22.10.2024].
- Dereli, M.A., 2019, Sentinel-2A uydu görüntüleri ile Giresun il merkezi için kısa dönem arazi örtüsü Değişiminin Belirlenmesi, *Afyon Kocatepe Üniversitesi Fen ve Mühendislik Bilimleri Dergisi AKÜ FEMÜBİD* 19, 2019, 025501, ss. 361-368.
- Earth Blox, 2023, February 6, "Everything You Need To Know About Google Earth Engine", [online], Everything you need to know about Google Earth Engine | Blog | Earth Blox, [Erişim Tarihi: 24.07.2024].
- Ekici, B.B., Ustaoglu, S.T., 2023, Binalarda fiziksel hasar tespiti için derin öğrenme: transfer öğrenme yöntemlerinin karşılaştırılması, *Turkish Journal of Science and Technology*, 18 (2), 291-299.
- Envisioning, "k-NN (K Nearest Neighbors)", [online], Envisioning | k-NN (k-Nearest Neighbors), [Erişim Tarihi: 24.07.2024].
- Erbay, A.Y. 2005, *Uydu görüntüleri rehber kitapçığı*, NİK Sistem: İstanbul, ss. 19.
- Ergünay, O., 2008, Afet yönetiminde kurumsal yapılanma ve mevzuat nedir? Nasıl olmalıdır?, İstanbul depremini beklerken sorunlar ve çözümler bildiriler kitabı, 20 Eylül 2008 CHP İstanbul Deprem Sempozyumu, İstanbul, 1-2.
- European Commission, White Paper on Artificial Intelligence- A European approach to excellence and trust", COM(2020) 65 final, Brussels, pp. 25.

- European Space Agency (ESA), 2015, Sentinel-2 User Handbook, 1 (2), 51-52.
- Fujita, A., etc., 2017, Damage detection from aerial images via convolutional neural networks. 15th IAPR International Conference on Machine Vision Applications (MVA) Nagoya University, Nagoya, Japan, May 8-12, 5-8.
- GeeksforGeeks, 2023, February 22, “Digital Image Processing Basics”, [online], Dijital Görüntü İşleme Temelleri - GeeksforGeeks, [Erişim Tarihi: 18.07.2024].
- GreeksForGreeks, 2024, June 20, “Difference Between Python ve JavaScript”, [online], Difference between Python and JavaScript - GeeksforGeeks, [Erişim Tarihi: 24.07.2024].
- Google Earth Engine (GEE), “A Planetary-Scale platform for Earth science data and analysis”, [online], Google Earth Engine, [Erişim Tarihi: 19.06.2024].
- Google for Developers, 2024, Eylül 03, “Sınıflandırma: ROC ve AUC”, [online], “Sınıflandırma: ROC ve AUC” [Erişim Tarihi: 22.10.2024].
- Gökçe, B., 2022, Eylül 24, “Uzaktan algılama nedir?”, [online], Uzaktan Algılama Nedir? | ATAY (ataymuhendislik.com), [Erişim Tarihi: 16.07.2024].
- Gregersen, E., 2024, May 22, “Artificial Intelligence (AI): At a Glance”, [online], Artificial Intelligence (AI): At a Glance | Britannica, [Erişim tarihi: 18.07.2024].
- Gültekin, B.G., 2023, Ağustos 22, “Mekânsal çözünürlük nedir?”, [online], Mekânsal Çözünürlük Nedir? - Uydu Shop, [Erişim Tarihi: 17.07.2024].
- Gültekin, B.G., 2023, Ağustos 15, “Zamansal çözünürlük nedir?”, [online], Zamansal Çözünürlük Nedir? - Uydu Shop, [Erişim Tarihi: 18.07.2024].
- Henz, P., 2021, Ethical and legal responsibility for Artificial Intelligence, *Discover Artificial Intelligence*, 1 (2), 1-5.
- Hoskere, V., etc., 2018, Towards automated post-earthquake inspections with deep learning-based condition-aware models. The 7th World Conference on Structural Control and Monitoring, 7WCSCM, July 22-25, 2018, Qingdao, China.
- Huang, M.H., Rust R.T., Maksimovic, V., 2019, The Feeling Economy: Managing in the Next Generation of Artificial Intelligence (AI), *California Management Review*, 61 (4), 43-65.
- IBM, “What are Naïve Bayes classifiers?”, [online], What Are Naïve Bayes Classifiers? | IBM, [Erişim Tarihi: 24.07.2024].
- IBM, 2024, Ocak 19, “Confusion Matrix?”, [online], “What is a confusion matrix?”, [Erişim Tarihi: 16.10.2024].

- Ijaz, M.B., 2024, March 24, “Understanding the k-Nearest Neighbors (k-NN) Algorithm”, [online], Understanding the k-Nearest Neighbors (k-NN) Algorithm | by Muhammad Bilal Ijaz | Medium, [Eriřim Tarihi: 24.07.2024].
- İřçi, C., 2008, Deprem nedir ve nasıl korunuruz?, *Journal of Yasar University*, 3 (9), 959-983.
- Ji, M., Liu, L., Buchroithner, M., 2018, Identifying collapsed buildings using post-earthquake satellite imagery and convolutional neural networks: a case study of the 2010 haiti earthquake, *Remote Sensing*, 10 (11), 1-20.
- Kalantar, B., etc., 2020, Assessment of convolutional neural network architectures for earthquake-induced building damage detection based on pre – and post-event orthophoto images, *Remote Sensing*, 12 (21), 1-22.
- Kavzoęlu, T., ölkesen, İ., řahin, E.K., 2013, Multispektral uydu görüntüleri için en uygun bant seçiminin sınıflandırma doğruluęuna etkilerinin incelenmesi, *Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birlięi VII. Teknik Sempozyumu (TUFUAB’2013)*, 23-25 Mayıs 2013, KTÜ, Trabzon.
- Kayı, A., Erdoğan, M. ve Yılmaz, A., 2015, Depremde Hasar Gören Binaların Uzaktan Algılama Yöntemleriyle Tespiti, *TUFUAB VIII. Teknik Sempozyumu* 21-23 Mayıs 2015, Konya, Türkiye.
- Kaynak, O., 2021, The golden age of Artificial Intelligence, *Discover Artificial Intelligence*, 1 (1), 1.
- KDnuggets, 2020, April 2, “A Top Machine Learning Algorithm Explained: Support Vector Machines (SVM)”, [online], A Top Machine Learning Algorithm Explained: Support Vector Machines (SVM) - KDnuggets, [Eriřim Tarihi: 24.07.2024].
- Kumar, U., Kumar Gupta, K., 2021, Artificial intelligence and biotechnology: The golden age of medical research, *Biotechnology in the Modern Medicinal System*, Edited by Rajesh K. Kesharwani and Krishna Misra, 195-232.
- LeCun, Y., etc., 1989, Backpropagation applied to handwritten zip code recognition, *Neural Computation*, 1 (4), 541–551.
- Live Home 3D, 2024 March, “AI in Interior Design”, [online], AI in Interior Design – Live Home 3D, [Eriřim tarihi: 19.07.2024].
- Marař, E.E., Sarıyıldız, H.İ., 2023, İHA ile derin öğrenme algoritmaları kullanılarak hasarlı yapıların tespit edilmesi, *Afyon Kocatepe University Journal of Science and Engineering*, AKÜ FEMÜBİD 23 (2023) 025504 (427-437).
- Medium, 2020, Haziran 12, “ROC and AUC”, [online], “ROC and AUC”, [Eriřim Tarihi: 22.10.2024].

- Medium, 2023, Nisan 14, “Makine Öğrenmesi Sınıflandırma Modelleri”, [online], “Makine Öğrenmesi Sınıflandırma Modelleri: Accuracy, Precision, Recall, F1-score, Log Loss and Micro-Macro-Weighted Avg”, [Erişim Tarihi: 21.10.2024].
- Mohankumar, A., Akhila S.R., Anantapur, R., 2021, Artificial Intelligence: A Modern Approach In Agricultural Entomology, *Agriculture and Food: E-News Letter*, 3 (2), 126-128.
- Oktay, A., Erdoğan, M. ve Altan, Y., 2001, LANDSAT Uydu Görüntüleri 17 Ağustos 1999 Gölcük Depreminden Zarar Gören Alanların Otomatik Olarak Tespitinde Kullanımı, *Turkish-German Joint Geodetic Days*, pp. 35-48, Berlin-2001.
- Narin, Ö.G., Delen, A., Abdikan, S., 2018, Sentinel-2A Verisi Kullanarak Tarımsal Ürün Deseninin Belirlenmesi, VII. UZAKTAN ALGILAMA-CBS SEMPOZYUMU (UZAL-CBS 2018), 18-21 Eylül 2018, Eskişehir.
- NASA, 2023, April 7, “Dark nights in Antakya”, [online], NASA SVS | Dark Nights in Antakya, [Erişim Tarihi: 17.07.2024].
- NASA Earth Observatory, 2019, “What is remote sensing?”, [online], <https://www.earthdata.nasa.gov/learn/backgrounders/remote-sensing#resolution>, [Erişim Tarihi: 17.07.2024].
- Overgoor, G., etc., 2019, Letting the Computers Take Over: Using AI to Solve Marketing Problems, *California Management Review*, 61 (4), 1-30.
- Öztürk, D., 2020, “Uzaktan algılama ders notları”, Samsun, [online], https://avys.omu.edu.tr/storage/app/public/dozturk/71478/dozturk_ua_ders4.pptx, [Erişim tarihi: 17.07.2024].
- Pinty, J. et al., 2003, Observing Earthquake-Related Dewatering Using MISR/Terra Satellite Data, *Eos Transactions American Geophysical Union* 84: 37-48.
- Point, J. “Decision tree classification algorithm”, Decision Tree Algorithm in Machine Learning - Javatpoint, [Erişim Tarihi: 24.07.2024].
- Robertson, B.W., etc., 2019, Using a combination of human insights and ‘deep learning’ for real-time disaster communication, *Progress in Disaster Science*, 2, 1-11.
- Sabuncu, A., 2018, Yüksek mekânsal çözünürlüklü uydu/uçak platformlu görüntüler ve Cbs teknolojisi kullanılarak Van-Erciş depremi sonrası bina hasar tespiti, Doktora Tezi, *İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü*, İstanbul.
- Salvador-Meneses, J., Ruiz-Chavez, Z., Garcia-Rodriguez, J., 2019, Compressed kNN: K-Nearest neighbors with data compression, *Entropy*, 21 (3), 234-254.
- Saylan, İ. H., ve Çömert, R., 2019, Sentinel-2A ürünlerinin yanmış orman alanlarının haritalanmasındaki başarının araştırılması. *Türkiye Uzaktan Algılama Dergisi*, 1(1), 8-15.

- Schweier, C., Markus, M., 2006, Classification of collapsed buildings for fast damage and loss assessment. *Bulletin of Earthquake Engineering*, 4 (2), 177-192.
- Sunar, A.F., Özkan, C., Osmanoğlu, B., 2011, *Uzaktan algılama*, Anadolu Üniversitesi Yayınları, Eskişehir, ss. 2.
- Sunar, A.F., Dervişoğlu, A., Yağmur, N., 2023, Sentinel-2 Uydu Görüntüleri ile Klorofil-a Parametresi Tahmininde Güneş Parıltısının Etkisi, *Harita Dergisi*, 169: 1-12.
- Şahin, N., 2009, Afet yönetimi ve acil yardım planları, TMMOB İzmir Kent Sempozyumu, İzmir, ss. 132.
- Tang, A., Wen, A., 2009, An intelligent simulation system for earthquake disaster assessment, *Computers and Geosciences*, 35, 871– 879.
- Tarhan, Ç., vd., 2022, Görüntü işleme entegre afet yönetiminde yapay zekâ yöntemi olarak kullanılabilir mi? *Journal of Research in Business*, 7 (1), e116-131.
- T.C. Cumhurbaşkanlığı Strateji ve Bütçe Başkanlığı, 2023, 2023 Kahramanmaraş ve Hatay Depremleri Raporu, [online], 2023 Kahramanmaraş ve Hatay Depremleri Raporu - T.C. Cumhurbaşkanlığı Strateji ve Bütçe Başkanlığı - SBB, [Erişim Tarihi: 16.07.2024].
- T.C. İçişleri Bakanlığı Afet ve Acil Durum Yönetimi Başkanlığı, “Deprem nedir?”, [online], [deprem_nedir.pdf](https://www.afad.gov.tr/deprem-nedir.pdf) (afad.gov.tr), [Erişim Tarihi: 15.07.2024].
- T.C. İmranlı Kaymakamlığı, “Deprem nedir?”, [online], Deprem Nedir? Deprem Klavuzu (imranli.gov.tr), [Erişim Tarihi: 15.07.2024].
- The European Space Agency (ESA), 2023, February 20, “Destruction in Turkish city of Antakya”, [online], ESA - Sentinel-2, [Erişim Tarihi: 23.07.2024].
- TMMOB Mimarlar Odası, 2023, Şubat 23, “6 Şubat 2023 depremleri tespit ve değerlendirme raporu”, [online], [mo06022023depremtespit.pdf](https://www.tmmob.org.tr/mo06022023depremtespit.pdf) (tmmob.org.tr), [Erişim Tarihi: 25.07.2024].
- Torunlar, H., Tugac, M.G., Duyan, K., (2021). Nesne tabanlı sınıflandırma yönteminde Sentinel-2A uydu görüntüleri kullanılarak tarımsal ürün desenlerinin belirlenmesi; Konya- Karapınar örneği. *Türkiye Uzaktan Algılama Dergisi*, 3(2), 36-46.
- Towards Datas Science, “Machine learning”, [online], Medium (towardsdatascience.com), [Erişim Tarihi: 24.07.2024].
- TRT Haber, 2023, Şubat 14, “Depremin Ardından En Çok Hasarlı İlçeler Belli Oldu”, [online], Depremin ardından en çok hasarlı ilçeler belli oldu - Son Dakika Haberleri (trthaber.com), [Erişim Tarihi: 25.07.2024].
- TRTHABER, 2023, Haziran 30, “Hatay’da depremin yıkıcı etkisi uydu görüntülerine yansdı”, [online], Hatay’da depremin yıkıcı etkisi uydu görüntülerine yansdı - Son Dakika Haberleri (trthaber.com), [Erişim Tarihi: 16.07.2024].

- Türk Mühendis ve Mimar Odaları Birliği (TMMOB), 2024, 6 Şubat 2023 depremlerinin birinci yılı değerlendirmesi, 06.02.2024, Ankara, 5-8.
- UHUZAM, 2020, “İzmir Depreminin Yol Açtığı Yıkım Uzaydan Görüntülendi”, İzmir Depreminin Yol Açtığı Yıkım Uzaydan Görüntülendi - 05.11.2020 - UHUZAM, [Erişim Tarihi: 16.11.2024].
- Ulusal Açık Ders Malzemeleri Konsorsiyumu, “Uzaktan algılamaya giriş”, [online], Microsoft PowerPoint - Unit1_Uzaktan_Algılamaya_Giris.pptx (ktu.edu.tr), [Erişim Tarihi: 16.07.2024].
- UYDUSHOP, “Hangi proje için hangi çözünürlük?”, [online], Hangi Çözünürlük? - Uydu Shop, [Erişim tarihi: 18.07.2024].
- WebJeoloji, 2020, Eylül 6, “Sentinel 2 Grupları ve Kombinasyonları”, [online], Sentinel 2 Grupları ve Kombinasyonları - WebJeoloji, [Erişim Tarihi: 25.07.2024].
- Weebly, “Deprem Çeşitleri”, [online], Deprem Çeşitleri - DEPREMLER (weebly.com), [Erişim Tarihi: 15.07.2024].
- Westen, C.V., 2000, Remote sensing for natural disaster management, *International Archives of Photogrammetry and Remote Sensing*, XXXIII (B7), 1609-1617.
- Wikimedia Commons, 2012, December 5, “Decreasing radiometric resolution from L7 15m panchromatic.svg”, [online], File:Decreasing radiometric resolution from L7 15m panchromatic.svg - Wikimedia Commons, [Erişim Tarihi: 18.07.2024].
- Wikipedia, “Remote sensing”, [online], Remote sensing - Wikipedia, [Erişim Tarihi: 16.07.2024].
- Yiğit, A, Kaya, Y., 2020, Sentinel-2A uydu verileri kullanılarak sel alanlarının incelenmesi: Düzce örneği. *Türkiye Uzaktan Algılama Dergisi*, 2 (1), 1-9 .
- Zabcı, C., 2021, Çok bantlı Landsat 8-OLI ve Sentinel-2A MSI uydu görüntülerinin karşılaştırmalı jeoloji uygulaması: Örnek çalışma alanı olarak Doğu Anadolu Fayı boyunca Palu – Hazar Gölü bölgesi (Elazığ, Türkiye). *Geomatik*, 6(3), 238-246.
- Zhou, Z.H., 2022, *Machine learning*, Springer Nature Singapur Pte.: Singapur, 2021, translated by Shaowu Liu, Tsinghua University Press e-book, 2022, pp. 3.