



**DEPREMDEN YIKILAN BİNALARIN
TESPİTİNDE MAKİNE ÖĞRENME
YÖNTEMLERİNİN DEĞERLENDİRİLMESİ**

Yüksek Lisans Tezi

Faruk ÖZARSLAN

ESKİŞEHİR 2025

**DEPREMDEN YIKILAN BİNALARIN TESPİTİNDE MAKİNE ÖĞRENME
YÖNTEMLERİNİN DEĞERLENDİRİLMESİ**

Faruk ÖZARSLAN

Yüksek Lisans Tezi

Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Anabilim Dalı

Danışman: Doç. Dr. Dilek KÜÇÜK MATCI

Eskişehir

Eskişehir Teknik Üniversitesi

Lisansüstü Eğitim Enstitüsü

Mayıs 2025

JÜRİ VE ENSTİTÜ ONAYI

Faruk ÖZARSLAN'nın DEPREMDEN YIKILAN BİNALARIN TESPİTİNDE MAKİNE ÖĞRENME YÖNTEMLERİNİN DEĞERLENDİRİLMESİ başlıklı çalışması 23/05/2025 tarihinde aşağıdaki jüri tarafından değerlendirilerek "Eskişehir Teknik Üniversitesi Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliği"nin ilgili maddeleri uyarınca, Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Anabilim dalında Yüksek Lisans Tezi olarak kabul edilmiştir.

Jüri Üyeleri

Unvan Adı Soyadı

İmza

Üye

: Doç.Dr.Dilek Küçük MATCI

Üye

: Prof.Dr.Uğur AVDAN

Üye

: Doç.Dr.Merve ERSOY

Prof. Dr. Harun BÖCÜK

Lisansüstü Eğitim Enstitüsü Müdürü

23/05/2025

DANIřMAN ONAYI

Daniřmanlıđını yrttđm Yksek Lisans đrencisi Faruk ZARSLAN, DEPREMDEN YIKILAN BİNALARIN TESPİTİNDE MAKİNE đRENME YNTEMLERİNİN DEđERLENDİRİLMESİ bařlıklı tez alıřmasını tamamlamıřtır. Hazırlamıř olduđu tez tarafımda incelenmiř ve đrencinin tez savunma sınavına alınması bilimsel ve etik aıdan uygun grlmřtır.

Tez Daniřmanı

Do. Dr. Dilek KK MATCI

ÖZET

DEPREMDEN YIKILAN BİNALARIN TESPİTİNDE MAKİNE ÖĞRENME YÖNTEMLERİNİN DEĞERLENDİRİLMESİ

Faruk ÖZARSLAN

Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Anabilim Dalı

Eskişehir Teknik Üniversitesi, Lisansüstü Eğitim Enstitüsü, Mayıs 2025

Danışman: Doç. Dr. Dilek KÜÇÜK MATCI

Bu tez çalışması, 2023 Kahramanmaraş depremleri sonrasında Hatay Antakya bölgesindeki hasarlı ve yıkılmış yapıların tespiti için yüksek çözünürlüklü insansız hava aracı(İHA) görüntülerinin analizine odaklanmaktadır. Çalışmada, nesne tabanlı görüntü analizi desteğiyle farklı makine öğrenimi(ML) yöntemleri kullanılarak detaylı bir değerlendirme yapılmıştır. Deprem sonrası Antakya' da elde edilen insansız hava aracı (İHA) görüntüleri üzerinde çoklu çözünürlüklü segmentasyon işlemi (MRS) uygulanmıştır. Segmentasyon parametrelerinin optimizasyonu kapsamında, ölçek, şekil ve yoğunluk değerleri sistematik olarak test edilmiştir. Bu süreçte, her parametre kombinasyonu için görsel kontrol ve istatistiksel analizler yapılmıştır. Nesnelerden çıkarılan spektral, dokusal ve şekil özellikleri, Rastgele Orman (RF), Destek Vektör Makineleri (SVM) ve K-En Yakın Komşuluk (KNN) algoritmalarıyla analiz edilmiştir. Performans değerlendirmesinde kullanılan genel doğruluk (OA), üretici doğruluğu (PA) ve kullanıcı doğruluğu (UA) metrikleri, algoritmaların karşılaştırılmasında objektif bir temel sağlamıştır. Sonuçlar, K-NN algoritmasının genel doğruluk anlamında diğer yöntemlere göre daha başarılı olduğunu göstermiştir.

Çalışmanın bulguları, afet sonrası hızlı değerlendirme çalışmalarında makine öğrenmesi tabanlı yöntemlerin pratik faydalarını ortaya koymaktadır. Bu çalışma, İnsansız Hava Aracı ve yüksek çözünürlüklü uydu görüntüsü aracılığı ile enkaz tespitinde başarı oranının arttırmıştır. Özellikle kentsel alanlarda yıkım tespiti için bu tür analizlerin etkin bir şekilde kullanılabileceği anlaşılmaktadır. Ancak, mevcut yöntemlerin sınırlılıklarının aşılması için daha gelişmiş segmentasyon tekniklerinin geliştirilmesi ve farklı veri kaynaklarının entegre edilmesi gerektiği sonucuna varılmıştır.

Anahtar Sözcükler: Yıkılmış bina sınıflandırması, Makine öğrenimi, Segmentasyon, İnsansız hava aracı görüntüleri.

ABSTRACT

EVALUATION OF MACHINE LEARNING METHODS IN DETECTING BUILDINGS DESTROYED BY EARTHQUAKE

Faruk ÖZARSLAN

Department of Remote Sensing and Geographic Information Systems

Programme in Lütfen doldurunuz

Eskişehir Technical University, Institute of Graduate Programs, May 2025

Supervisor: Assoc. Prof. Dr. Dilek KÜÇÜK MATCI

This thesis study focuses on the analysis of high-resolution unmanned aerial vehicle (UAV) imagery for detecting damaged and collapsed structures in the Hatay Antakya region following the 2023 Kahramanmaraş earthquakes. The study employs object-based image analysis supported by various machine learning (ML) methods to conduct a detailed evaluation. Multi-resolution segmentation (MRS) was applied to Unmanned Aerial Vehicles (UAV) imagery collected in Antakya after the earthquake. Scale, shape, and compactness values were systematically tested to optimize the segmentation parameters. Each parameter combination was subjected to visual inspection and statistical analysis during this process. The spectral, textural, and shape features extracted from the objects were analyzed using Random Forest (RF), Support Vector Machines (SVM), and K-Nearest Neighbors (KNN) algorithms. The overall accuracy (OA), producer's accuracy (PA), and user's accuracy (UA) metrics, used for performance evaluation, provided an objective basis for comparing the algorithms. The results indicate that the K-NN algorithm outperformed the other methods in terms of overall accuracy.

The findings of this study highlight the practical benefits of machine learning-based methods in rapid assessment efforts following disasters. This study has increased the success rate of debris detection through the use of Unmanned Aerial Vehicles and high-resolution satellite imagery. It is evident that such analyses can be effectively utilized for damage detection in urban areas. However, it has been concluded that overcoming the limitations of the current methods requires the development of more advanced segmentation techniques and the integration of diverse data sources.

Keywords: Collapsed building classification, Machine learning, Segmentation, Unmanned aerial imagery.

TEŞEKKÜR

Lisansüstü eğitim aşamasında bilgi birikimi, sabrı ve yol göstericiliğiyle bana ilham veren kıymetli danışmanım Doç.Dr.Dilek Küçük MATCI'ya en içten teşekkürlerimi sunarım. Bilimsel yaklaşımı ve desteğiyle yalnızca bu tezde değil, akademik gelişimimde de büyük katkısı olmuştur. Değerli büyüğüm ve meslektaşım Burak GÜÇLÜ'ye de desteklerinden dolayı minnettarım.

Beni büyütüp bu yaşlara getiren babam Nusret ÖZARSLAN'a ve annem Fadime ÖZARSLAN'a sonsuz sevgilerimi sunarım. Bu süreçte beni asla yalnız bırakmayan, en yoğun zamanlarda bile anlayışını ve desteğini esirgemeyen sevgili eşim Kadriye ÖZARSLAN'a ve oğlum Alparslan ÖZARSLAN'a gönülden teşekkür ederim. Varlığınız, bu süreci daha güçlü ve anlamlı kıldı.

Faruk ÖZARSLAN

ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ

Bu tezin bana ait, özgün bir çalışma olduğunu; çalışmamın hazırlık, veri toplama, analiz ve bilgilerin sunumu olmak üzere tüm aşamalarında bilimsel etik ve kurallara uygun davrandığımı; bu çalışma kapsamında elde edilen tüm veri ve bilgiler için kaynak gösterdiğimi ve bu kaynaklara kaynakçada yer verdiğimi; bu çalışmanın Eskişehir Teknik Üniversitesi tarafından kullanılan “bilimsel intihal tespit programı”yla tarandığını ve hiçbir şekilde “intihal içermediğini” beyan ederim. Herhangi bir zamanda, çalışmamla ilgili yaptığım bu beyana aykırı bir durumun saptanması durumunda, ortaya çıkacak tüm ahlaki ve hukuki sonuçları kabul ettiğimi bildiririm.

Faruk ÖZARSLAN

İÇİNDEKİLER

Sayfa

BAŞLIK SAYFASI	I
JÜRİ VE ENSTİTÜ ONAYI	II
DANIŞMAN ONAYI	III
ÖZET	IV
ABSTRACT	V
TEŞEKKÜR	VI
ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ	VII
İÇİNDEKİLER	VIII
TABLolar DİZİNİ	X
ŞEKİLLER DİZİNİ	XI
SİMGELER VE KISALTMALAR DİZİNİ	XIII
1. GİRİŞ	1
1.1. Çalışmanın Amacı ve Önemi	3
1.2. Çalışmanın Kapsamı	4
1.3. Literatür Özeti	5
2. TEMEL KAVRAMLAR	11
2.1. Uzaktan Algılama	11
2.2. Elektromanyetik Enerji / Elektromanyetik Spektrum	16
2.3. Enerji-Atmosfer Etkileşimi	17
2.4. Enerji-Yeryüzü Nesneleri Etkileşimi	18
2.5. Görüntü İşleme	19
2.6. Sobel Filtresi	20
2.7. Segmentasyon	21
2.8. Çoklu Çözünürlüklü Segmentasyon (MRS)	22
2.9. Yapay Zeka (YZ)	23
2.10. Makine Öğrenim Algoritmaları (ML)	24
2.11. Sınıflandırma	25

3. ÇALIŞMA ALANI VE KULLANILAN VERİ SETİ	28
3.1. Çalışma Alanı	28
3.2. Kullanılan Veri Seti	29
4. YÖNTEM.....	31
4.1. Veri Toplama.....	32
4.2. DEM Oluşturma	40
4.3. Segmentasyon	42
4.4. Model Eğitimi	43
4.5. Sınıflandırma Adımı.....	44
4.5.1. K- en yakın komşuluk (KNN).....	44
4.5.2. Rastgele orman(RF)	46
4.5.3. Destek vektör makineleri (SVM)	47
4.6. Hasar Tanımlaması	49
4.7. Doğruluk Analizi	50
5. BULGULAR VE TARTIŞMA	53
5.1. Segmentasyon Parametreleri Optimizasyonu.....	53
5.2. Sınıflandırma Sonuçları	55
6. SONUÇLAR VE ÖNERİLER.....	72
KAYNAKÇA	74
ÖZGEÇMİŞ	

TABLÖLAR DİZİNİ

Sayfa

Tablo 4.1. İHA teknik özellikleri (http-2).	33
Tablo 4.2. Kamera teknik özellikleri (http-3).....	34
Tablo 4.3. Alan-1 için toplanan eğitim verileri.	43
Tablo 4.4. Alan-2 için toplanan eğitim verileri.	44
Tablo 4.5. Yapılarda meydana gelen hasarın sınıflandırılması (Grunthal, 1998).....	50
Tablo 5.1. Alan-1'e ait doğruluk analizi sonuçları.....	61
Tablo 5.2. Alan-2'ye ait doğruluk analizi sonuçları.....	68

ŞEKİLLER DİZİNİ

Sayfa

Şekil 2.1.	Uzaktan algılama sistemleri (Campos-Taberner, 2017).....	12
Şekil 2.2.	Yer bazlı platformlar (Zheng vd., 2022)	13
Şekil 2.3.	Uydu ve hava uzaktan algılama platformları (Xiang, Xia ve Zhang, 2019).....	14
Şekil 2.4.	Elektromanyetik spektrum (Sunar, 2019)	17
Şekil 3.1.	Çalışma alanı	29
Şekil 3.2.	İHA ile elde edilen görüntü	30
Şekil 4.1.	Çalışmada uygulanan yöntem.....	31
Şekil 4.2.	İHA görseli (http-2)	32
Şekil 4.3.	Çalışmada kullanılan görüntülerin çekimini gerçekleştiren kamera görseli (http-3).....	34
Şekil 4.4.	Kameranın konumu ve hata tahmini	36
Şekil 4.5.	Kamera konumları ve görüntü örtüşmesi	37
Şekil 4.6.	Yer kontrol noktaları	39
Şekil 4.7.	Uçuş planı.....	39
Şekil 4.8.	Oluşturulan DEM.....	41
Şekil 4.9.	Oluşturulan katmanlar a) Sobel b) Eğim katmanı	42
Şekil 4.10.	KNN algoritması	45
Şekil 4.11.	RF Algoritması	46
Şekil 4.12.	SVM Algoritması.....	48
Şekil 4.13.	Doğruluk analizi için oluşturulan noktaların görüntüsü a) Alan-1 b) Alan-2	52
Şekil 5.1.	a)Ölçek 30, Şekil 0.3, Yoğunluk 0.7 b) Ölçek 30, Şekil 0.9, Yoğunluk 0.1	53
Şekil 5.2.	a)Ölçek 35, Şekil 0.2, Yoğunluk 0.7 b)Ölçek 35, Şekil 0.9, Yoğunluk 0.1	54
Şekil 5.3.	Segmentasyon sonuçları a) Alan-1 b) Alan-2	55
Şekil 5.4.	Alan-1 de KNN yöntemi ile elde edilen sonuç haritası.....	56
Şekil 5.5.	Alan-1 de RF yöntemi ile elde edilen sonuç haritası	57
Şekil 5.6.	Alan-1 de SVM yöntemi ile elde edilen sonuç haritası.....	58
Şekil 5.7.	Alan-1 de belirlenen enkaz alanları ve Humdata karşılaştırılması.....	59

Şekil 5.8. Alan-1 de belirlenen enkaz alanları ve yıkılmış bina ayak izleri karşılaştırılması.....	60
Şekil 5.9. Yol ve beton çatı alanlarına ait histogram grafikleri.....	62
Şekil 5.10. Alan-2 'de KNN yöntemi ile elde edilen sonuç haritası.....	63
Şekil 5.11. Alan-2 'de RF yöntemi ile elde edilen sonuç haritası.....	64
Şekil 5.12. Alan-2 'de SVM yöntemi ile elde edilen sonuç haritası.....	65
Şekil 5.13. Alan-2 de belirlenen enkaz alanları ve Humdata karşılaştırılması.....	66
Şekil 5.14. Alan-2 de belirlenen enkaz alanları ve yıkılmış bina ayak izleri karşılaştırılması.....	67
Şekil 5.15. Su ve yeşil alanlara ait histogram grafikleri	70
Şekil 5.16. Karşılaşılan problemler	71

SİMGELER VE KISALTMALAR DİZİNİ

KNN	: K-Nearest Neighbors (K-En Yakın Komşuluk)
MRS	: Multiresolution Segmentation (Çoklu Çözünürlüklü Segmentasyon)
ML	: Machine Learning (Makine Öğrenimi)
OA	: Overall Accuracy (Genel Doğruluk)
PA	: Producer's Accuracy(Üretici Doğruluğu)
RF	: Random Forest (Rastgele Orman)
SVM	: Support Vector Machines (Destek Vektör Makineleri)
UA	: User's Accuracy(Kullanıcı Doğruluğu)
YZ	: Yapay Zeka

1. GİRİŞ

Türkiye, aktif tektonik kuşaklar üzerinde yer alması nedeniyle dünyanın en yüksek deprem riski taşıyan ülkelerinden biridir. Anadolu Yarımadası, kuzeyde Kuzey Anadolu Fay Hattı (KAF), doğuda Doğu Anadolu Fay Hattı (DAF) ve batıda Ege Bölgesi'ndeki genişleme rejimi gibi büyük aktif fay sistemleri ile çevrilidir. Bu fay hatları, tarih boyunca çok sayıda yıkıcı depreme yol açmış ve ülke genelinde önemli can ve mal kayıplarına neden olmuştur. Türkiye'nin jeolojik yapısı gereği, ülke topraklarının yaklaşık %92'si deprem riski altındadır ve nüfusunun %95 aktif fay hatlarına yakın yerleşim bölgelerinde yaşamaktadır (http-1). Özellikle 1939 Erzincan Depremi, 1999 Marmara Depremi ve son olarak on ilimizi derinden etkileyen 06 Şubat 2023 Kahramanmaraş merkezli depremler, Türkiye'nin deprem gerçeğini bir kez daha acı bir şekilde gözler önüne sermiştir. Özellikle şehir merkezlerinde meydana gelen depremlerde, bina yoğunluğunun kırsal bölgelere göre fazla olmasından dolayı çok sayıda bina ya tamamen yıkılmakta ya da ağır hasar almaktadır. Bu durum yoğunlukla can ve mal kayıplarına neden olmaktadır. Meydana gelen bu yıkımlarda zaman hayati bir öneme sahip olmasından dolayı zarar görmüş binaların tespiti hızlı ve doğru şekilde yapılmalıdır. Geleneksel yöntemlerle hasar tespiti saha çalışmaları yoluyla yürütülmekteydi. Ancak bu yöntem zaman alıcı, yoğun iş gücü gerektiren ve afet sonrası kriz ortamında etkin kullanımı güçtür. Bu nedenle, hasar tespit çalışmalarında hızlı ve güvenilir teknolojilere ihtiyaç duyulmaktadır.

Yapılmış birçok çalışmada farklı veri tipleriyle ve deprem sonrası hasarlı veya yıkılmış binalar tespit edilmeye çalışılmaktadır. Deprem sonrasında hasarlı veya yıkılmış binaların belirlenmesine bağlı olarak yapılan çalışmalarda, teknolojinin sürekli gelişimiyle fotogrametrik ve uzaktan algılama teknikleri yoluyla elde edilen ürünlerin çeşitlenmesi ve bu verilere erişimin daha kolay olması sonucunda kapsamlı, hızlı ve güvenilirliği daha yüksek sonuçlar elde edilebilmektedir (Canözü, 2022).

Günümüzde özellikle afet yönetimi süreçlerinde veri temelli yaklaşımlar ön plana çıkmakta, uzaktan algılama teknolojileri bu süreçlerde etkin bir rol oynamaktadır. Uydu ve İnsansız Hava Aracı görüntülerinin yüksek çözünürlüklü olarak temin edilebilmesi, geniş alanlardaki yapısal değişimlerin hızlı ve maliyet etkin bir şekilde analiz edilmesini mümkün kılmaktadır. Elde edilen bu görüntülerin analizinde, klasik piksel tabanlı yöntemlerin ötesine geçilerek nesne tabanlı sınıflandırma yaklaşımları tercih edilmektedir. Bu yöntemler, sadece spektral bilgileri değil; aynı zamanda nesnelerin şekil, doku ve mekânsal bağlam gibi özniteliklerini de dikkate alarak daha anlamlı ve

doğru sınıflandırmalar gerçekleştirmektedir. Sınıflandırma sürecinde, karmaşık verilerin işlenmesi ve sınıf ayrımının optimize edilmesi için Makine Öğrenim(ML) algoritmalarından da yararlanılmaktadır. Bu algoritmalar, verilerdeki örüntüleri öğrenerek, deprem gibi afet durumlarında yıkılan binaların mekânsal dağılımını otomatik ve yüksek doğrulukla haritalandırılmasına olanak tanımaktadır. Ayrıca nesne tabanlı sınıflandırma yöntemi kullanımı hasar tespiti ve analizinde sıklıkla tercih edilen bir yöntem olarak karşımıza çıkmaktadır (Çömert, Matcı ve Avdan, 2017).

Son yıllarda uzaktan algılanmış görüntülerin analizinde makina öğrenme yöntemlerinin kullanımı artmıştır. Geleneksel yöntemlerin aksine ML algoritmaları görüntülerden karmaşık desenleri ve özellikleri otomatik olarak öğrenip çıkarabilir ve bu sayede manuel müdahaleye olan ihtiyaç büyük ölçüde azalır. Ayrıca, yeterli ve çeşitli veriyle eğitildiklerinde ML modelleri nesne tespiti, arazi örtüsü sınıflandırması ve anomali tespiti gibi görevlerde yüksek doğruluk ve sağlamlık sağlar. ML yöntemleri, büyük hacimli İHA verilerini ölçeklenebilir şekilde işleyebilir, bu da geniş coğrafi alanların izlenmesini mümkün kılar. Farklı görevler veya çevresel koşullar için kolayca uyarlanabilen bu modeller, çeşitli çözünürlük ve sensör tipleriyle çalışabilir. Gelişen bilişim teknolojileri sayesinde bazı ML algoritmaları, İHA'lar üzerinde gerçek zamanlı çalıştırılabilir ve bu da tarım, afet yönetimi gibi uygulamalarda hızlı karar alma olanağı sunar (Lary vd., 2016).

Bu çalışmada hasarlı ve yıkılmış binaların tespiti amacıyla ML yöntemlerinin başarısı karşılaştırılmıştır. ML, İHA görüntüleri gibi karmaşık veri kümelerinin otomatik ve hızlı bir şekilde analiz edilmesini sağlar. Bu durum, yoğun nüfuslu kentsel alanlarda deprem hasarının zamanında değerlendirilmesi için gereklidir. Çünkü manuel yöntemler çok yavaş ve emek yoğun olacaktır. İkinci olarak; ML algoritmaları, uzmanlar tarafından kolayca fark edilemeyen yüksek boyutlu verilerdeki desenleri ve özellikleri tanımlayabilir, böylece bina hasarını tespit etme ve sınıflandırma doğruluğunu artırır. Üçüncüsü; birden fazla ML algoritmasının karşılaştırmalı analizi, hasar tespiti için en etkili yaklaşımın belirlenmesine olanak tanır ve hem hassasiyeti hem de verimliliği optimize eder.

Yoğun nüfuslu kentsel alanlarda acil durum müdahale süreçlerinin yönetimi giderek karmaşık hale gelmekte olup, bu bağlamda acil müdahale ekiplerine etkilenen bölgeler hakkında anlık ve kapsamlı bir anlayış sunmak kritik bir öneme sahiptir. Bu çalışma, özellikle bu tür alanlarda deprem sonrası hasar değerlendirmesine duyulan acil

ihtiyacı ele almaktadır. İHA görüntüleme teknolojileri ve ML gibi ileri metodolojilerin entegrasyonu yoluyla, depremler sonrasında bina hasarlarının tespiti ve değerlendirilmesinde doğruluk ve etkinliğin artırılması hedeflenmektedir. Araştırma, deprem sonrası hasar değerlendirmesi için birden fazla ML algoritmasının karşılaştırmalı bir analizini sunmayı amaçlamaktadır.

1.1. Çalışmanın Amacı ve Önemi

Türkiye, aktif fay hatları üzerinde bulunan coğrafi konumu nedeniyle dünyada deprem riski en yüksek ülkeler arasında yer almaktadır. Tarihsel süreçte meydana gelen yıkıcı depremlerin yol açtığı ağır can ve mal kayıpları, bu doğal afetin etkilerini açıkça ortaya koymaktadır. Özellikle kentsel alanlardaki yüksek yapı yoğunluğu, karmaşık yerleşim dokusu ve heterojen arazi koşulları dikkate alındığında, afet sonrası hasar tespiti ve değerlendirmesi için otomatik sistemlerin geliştirilmesi büyük önem taşımaktadır. Bu tür sistemler, hızlı ve doğru müdahale süreçlerinin planlanmasına katkı sağlayarak olası kayıpların azaltılmasında kritik bir rol oynamaktadır.

Bu çalışmanın temel amacı, İHA aracılığıyla elde edilen yüksek çözünürlüklü görüntüler üzerinde farklı ML algoritmalarını karşılaştırmalı olarak inceleyerek, deprem sonrası kentsel alanlarda hasar görmüş ya da tamamen yıkılmış binaların tespiti ve sınıflandırılması için etkili bir yöntemi belirlemektir. Bu doğrultuda, araştırma İHA teknolojisinin sunduğu ayrıntılı verilerin, gelişmiş ML yaklaşımlarıyla birleştirilmesi sayesinde, afet sonrası hasar değerlendirme süreçlerinin hem hızını artırmayı hem de daha güvenilir hale getirilmesini amaçlamaktadır.

Çalışma kapsamında, K-En Yakın Komşuluk(K-NN), Rastgele Orman(RF) ve Destek Vektör Makineleri(SVM) gibi farklı ML algoritmalarının İHA verileriyle entegrasyonu incelenmiş, bu yöntemlerin hasar tespiti konusundaki başarıları karşılaştırmalı olarak değerlendirilmiştir. Yapılan analizler sayesinde, çökmüş yapıların sağlam binalardan en yüksek doğrulukla ayrılmasını sağlayan algoritmalar belirlenmiş ve bu yöntemler afet sonrası hızlı müdahaleye uygun şekilde optimize edilmiştir. Tez kapsamında yapılan bu çalışmanın çıktıları ile hasarlı bölgelerin haritalanmasının daha kısa sürede tamamlanabileceği ve acil müdahale ekiplerine zamanında, doğru bilgiler sağlanabileceği öngörülmektedir. Bu durum, arama kurtarma faaliyetlerinin planlanmasında ve kaynakların etkili bir şekilde yönlendirilmesinde önemli bir kolaylık sağlayacaktır.

Çalışmada elde edilen sonuçların, özellikle manuel değerlendirme süreçlerinin zaman alıcı ve hata yapmaya açık doğası karşısında, önemli bir alternatif sunduğu düşünülmektedir. Otomatik tespit sistemleri hem hız hem de doğruluk açısından afet yönetimi uygulamalarında önemli kazanımlar sağlayabilir. Ayrıca, uygulanan yöntemin farklı afet türlerine ve coğrafi koşullara uyarlanabilecek esneklikte olması, gelecekte yapılacak çalışmalar için geniş bir uygulama alanı oluşturma potansiyeli taşımaktadır. Sonuç olarak bu çalışma, teknolojik araçlardan faydalanarak afet sonrası hasar analizlerinin daha etkin bir biçimde gerçekleştirilmesine katkı sağlamayı ve kriz yönetimi süreçlerinde karar vericilere pratik çözümler sunmayı hedeflemektedir.

1.2. Çalışmanın Kapsamı

Bu çalışma, 2023 yılında Hatay bölgesinde meydana gelen yıkıcı depremin ardından, İHA ile toplanan yüksek çözünürlüklü görüntülerin nesne tabanlı görüntü analizi (OBIA) ve çeşitli makine öğrenimi (ML) algoritmaları kullanılarak deprem sonrası bina hasarlarının değerlendirilmesine odaklanmaktadır. Araştırma, afet sonrası hızlı ve güvenilir hasar tespitine yönelik yenilikçi bir metodoloji sunmayı amaçlamakta olup, bu süreçte OBIA yaklaşımı ve denetimli öğrenme algoritmalarının entegrasyonuna dayanmaktadır. Çalışma, afet yönetimi ve acil müdahale süreçlerini optimize etmek, zaman ve kaynak kullanımını iyileştirmek ve veri odaklı karar destek sistemlerinin geliştirilmesine katkıda bulunmak için tasarlanmıştır.

Çalışmanın temel veri kaynağını, Hatay bölgesinde 2023 depremi sonrasında İHA'larla toplanan yüksek çözünürlüklü optik görüntüler oluşturmaktadır. Bu görüntüler, afet bölgesindeki binaların ve çevresel unsurların detaylı bir şekilde belgelenmesini sağlamış, yüksek mekansal çözünürlükleriyle (santimetre ölçeğinde) hasar analizine uygun bir veri seti sunmuştur. Görüntülerin ön işleme aşamasında, geometrik ve radyometrik düzeltmeler yapılmış, böylece veri kalitesi artırılmıştır. OBIA yaklaşımı benimsenerek, geleneksel piksel tabanlı analiz yerine nesne tabanlı segmentasyon gerçekleştirilmiştir. Bu süreçte, binalar, yollar, yeşil alanlar ve diğer arazi örtüsü unsurları, piksellerden ziyade anlamlı nesneler olarak tanımlanmış ve ayrıştırılmıştır. Segmentasyon, çok ölçekli segmentasyon algoritmaları kullanılarak optimize edilmiş; ölçek, şekil ve kompaktlık parametreleri, nesnelerin doğru bir şekilde tanımlanmasını sağlamak için dikkatle ayarlanmıştır. Segmentasyon sonucunda elde edilen nesnelerden, hasar tespitine yönelik eğitim verileri çıkarılmıştır. Çalışmada, denetimli öğrenme

algoritmalarından RF, KNN ve SVM seçilmiştir. Bu algoritmalar, yıkılmış ve sağlam binaları ayırt etme performansları açısından sistematik bir şekilde karşılaştırılmıştır.

Bu çalışma, deprem sonrası hızlı ve güvenilir hasar tespiti için en uygun makine öğrenimi yaklaşımını belirlemeyi hedeflemektedir. OBIA ve ML algoritmalarının entegrasyonu, geleneksel yöntemlere kıyasla daha hassas ve bağlamsal analizler sunarak afet yönetiminde yenilikçi bir çerçeve önermektedir. Bunun yanında, İHA tabanlı görüntülerin OBIA ve ML algoritmalarıyla işlenmesinin, deprem sonrası hasar tespitinde yüksek doğruluk ve etkinlik sağladığını ortaya koymaktadır. Elde edilen bulgular, afet sonrası müdahale süreçlerinde zaman ve kaynak kullanımını optimize ederek kurtarma operasyonlarının etkinliğini artırmayı hedeflemektedir. Ayrıca çalışma, gelecekteki afetlere hazırlık stratejileri için veri odaklı bir temel sunmaktadır. Gelecekteki çalışmalar, farklı afet türleri (sel, yangın) için metodolojinin uyarlanmasını, daha geniş veri setleriyle algoritma performansının test edilmesini ve derin öğrenme gibi ileri tekniklerin entegrasyonunu içerebilir. Bu tür geliştirmeler, afet yönetiminde daha esnek ve ölçeklenebilir çözümler üretilmesine katkı sağlayacaktır.

1.3. Literatür Özeti

Depremler, insanlık tarihindeki en yıkıcı doğal afetlerden biri olarak kabul edilmekte ve küresel ölçekte ciddi sonuçlar doğurmaktadır. Her yıl dünya genelinde bir milyondan fazla depremin gerçekleştiğini ve bunun dakikada yaklaşık iki depreme karşılık geldiğini belirterek, bu olayların sıklığını ve yaygınlığını vurgulamıştır (Bartels and VanRooyen, 2012).

Bu depremler, özellikle yoğun nüfuslu bölgelerde hem insan hayatını hem de altyapıyı tehdit eden geniş çaplı hasarlara yol açmaktadır.

Literatür incelendiğinde uzaktan algılama ile depremler sonucunda binalarda meydana gelen hasarların tespiti üzerine birçok çalışma olduğu görülmektedir. Bu çalışmalarda, uzaktan algılanmış verilerin çeşitli yöntemlerle analiz edilmesini hedeflenmiştir. Bu doğrultuda kullanılan yaklaşımlardan biri piksel tabanlı sınıflandırma yöntemidir. Bu yönetime dayalı çalışmalarda, deprem öncesi ve sonrası elde edilen görüntüler arasındaki spektral farklar hesaplanarak değişiklikler tespit edilmeye çalışılmıştır. Deprem sonrası kentsel alanlardaki hasarları belirlemeye yönelik olarak, çok zamanlı uydu ve hava görüntüleri kullanılan bir çalışmada görüntü değişim tespiti (change detection) teknikleri uygulanmıştır (Bitelli vd., 2004).

Başka bir çalışmada, depremten sonra hasar gören binaları otomatik bir şekilde tespit etmek için, deprem öncesi ve sonrası çekilmiş stereo hava fotoğraflarından Sayısal Yükseklik Modelleri (DEM) oluşturarak bir yöntem geliştirilmiştir. Araştırmacılar, 1999 İzmit depreminin etkilediği bir bölgede yaptıkları incelemelerde, bina yüksekliklerinde meydana gelen değişiklikleri analiz ederek yıkılmış ya da hasarlı yapıları tespit etmeyi başarmışlardır (Turker and Cetinkaya, 2005). Bu kapsamda yapılan bir başka çalışmada, 2008 Wenchuan depremi sonrasında oluşan bina hasarlarını tespit etmek amacıyla, deprem öncesi ve sonrası elde edilen yüksek çözünürlüklü uydu stereo görüntülerini kullanılmıştır. Araştırmacılar, bu görüntülerden elde ettikleri bilgileri analiz ederek, binada hasar seviyelerini belirlemişlerdir (Tong vd., 2012).

Bir başka çalışmada deprem öncesi ve sonrası uydu görüntüleri kullanılarak hasar tespiti yapılmıştır. Çalışmada, görüntüdeki farklar üzerinden analizler gerçekleştirilmiş ve bu farklara dayalı olarak hasarlı alanlar belirlenmiştir (Korkmaz and Abualkibash, 2018).

2018 yılında yapılan bir çalışmada, deprem öncesi ve sonrası yüksek çözünürlüklü uydu görüntüleri ile DSM verileri analiz edilmiş, yükseklik ve görüntü farkları üzerinden hasarlı binalar belirlenmiştir (Erdogan and Yılmaz, 2019).

Deprem sonrası hasar tespiti için farklı çalışmalarda, ML teknikleri kullanılarak pikseller sınıflandırılmıştır. Bu çalışmalardan birinde 2010 yılında Haiti'nin Port-au-Prince kentinde meydana gelen depremin yol açtığı hasarın tespitinde farklı ML yöntemlerinin kullanımı incelenmiştir (Cooner, Shao and Campbell, 2016).

Başka bir çalışmada 2016 Kumamoto depremi sonrası hava fotoğraflarını kullanarak ML yaklaşımıyla hasarlı binalar tespit edilmiştir. Araştırmacılar, farklı hasar düzeylerine sahip binaları sınıflandırmak amacıyla, görsel özellikleri içeren verileri kullanarak bir sınıflandırma modeli oluşturmuştur. Model, özellikle hasarlı ve yıkılmış binaları güvenilir şekilde ayırt edebilmiş ve saha verileriyle karşılaştırıldığında yüksek doğruluk oranı sağlamıştır (Naito vd., 2020).

2020 yılında yapılan bir çalışmada, ML tekniklerini kullanarak depremten etkilenen binaların hasarını sınıflandırmayı amaçlamıştır. Çalışmada, farklı ML modellerini uygulayarak bina hasar seviyelerini çıkarmada en iyi performans veren yöntem belirlenmiştir. Bu yaklaşım, deprem hasar değerlendirmesinde etkili bir yöntem olarak öne çıkmıştır (Mangalathu vd., 2020).

Bir başka çalışmada 2016 Kumamoto depremi için ALOS-2/PALSAR-2 sentetik açıklıklı radar (SAR) görüntülerini kullanarak ML temelli bina hasar haritalama yöntemi kullanılmıştır. Araştırmada, yalnızca deprem sonrası SAR görüntüleri ile çok zamanlı SAR görüntülerinin performansları karşılaştırılmış, sonuçlar %64,5 genel doğruluk oranına ulaşmıştır (Bai vd., 2017).

Bir başka çalışmada, deprem hasar tahmini için çeşitli makine öğrenmesi algoritmalarının etkinliğini karşılaştırmalı olarak incelenmiştir. Çalışmada, Random Forest, Decision Tree, SVM, KNN ve Naive Bayes gibi ML algoritmaları kullanılarak, belirlenen bir veri seti üzerinde performans değerlendirmeleri yapılmıştır. Bu algoritmaların doğruluk değerlendirmesi sonucunda, algoritmaların deprem hasar tahmininde yüksek doğruluk ve kararlılık sağladığı belirlenmiştir (Bhandiya and Pandey, 2024).

Deprem sonrası hasarlı bina tespiti amacıyla kullanılan yöntemlerden biri de derin öğrenmedir. Derin öğrenme, insan beyninin öğrenme mekanizmasını taklit eden yapay sinir ağlarına dayalı bir ML yöntemidir. Deprem sonrası hasarlı bina tespiti için, öncesi ve sonrası uydu görüntüleri derin öğrenme modelleriyle analiz edilerek binaların hasar durumu otomatik olarak sınıflandırılır, bu da geniş alanlarda hızlı ve doğru değerlendirme sağlayabilmektedir. Bu doğrultuda yapılan çalışmalardan birinde, çok yüksek çözünürlüklü uzaktan algılama görüntülerinde deprem nedeniyle hasar görmüş binaların tespiti için nesne bağlamı (object context) ve sınır geliştirilmiş kayıp fonksiyonu (boundary enhanced loss) tabanlı bir derin öğrenme yöntemi önerilmiştir. Bu yaklaşım, bina sınırlarını daha doğru tespit ederek sınıflandırma doğruluğunu artırmayı hedeflemiş ve başarılı sonuçlar elde etmiştir (Wang vd., 2021).

İran'da 2017 yılında meydana gelen deprem sonrası hasar tespiti için yapılan bir çalışmada İHA verileriyle kullanılan bir derin öğrenme yöntemi önermiştir. Yöntemde 250 adet İHA görüntüsü işlenerek ortofoto ve dijital yüzey modelleri üretilmiş, sonuç olarak bu verilerle hasar seviyeleri belirlenmiştir (Takhtkeshha, Mohammadzadeh and Salehi, 2022).

Çin'in Yangbi bölgesi için yapılan çalışmada ise deprem sonrası hasarlı binaların otomatik tespiti için geliştirdikleri bir YOLOv5 modeli üzerine yaptıkları çalışmada, temel nesne tespit algoritmasına Convolutional Block Attention Module (CBAM) ekleyerek modelin performansını artırmayı başarmışlardır. Yüksek çözünürlüklü İHA görüntüleri kullanılarak oluşturulan veri seti üzerinde eğitilen bu geliştirilmiş model,

geleneksel YOLOv5'e kıyasla hasarlı bina tespitinde daha yüksek doğruluk oranları elde etmiş ve özellikle karmaşık enkaz alanlarında bile etkili sonuçlar vermiştir (Jing vd., 2022).

Bir başka çalışmada deprem afet değerlendirmesi için derin öğrenme teknikleri incelenmiştir. Çalışma, nesne tiplerini, veri kaynaklarını, modelleri, aşamaları, zorlukları ve fırsatları ele alarak uzaktan algılama ile deprem hasar tespiti için derin öğrenmenin potansiyeli değerlendirilmiştir (Jia and Ye, 2023).

2024 yılında yapılan bir çalışmada, 2023 Türkiye depremleri sonrasında uydu görüntülerini kullanarak büyük ölçekli hızlı hasar değerlendirmesi yapmak için derin öğrenme tabanlı bir topluluk modeli sunulmuştur. Elde edilen sonuçlar incelendiğinde topluluk modelinin tekli modellere göre daha yüksek doğruluk sağladığı belirlenmiştir (Soleimani-Babakamali vd., 2025).

Deprem sonrası hasar tespiti üzerine kullanılan yaklaşımlardan bir diğeri de nesne tabanlı sınıflandırma (OBIA) yöntemidir. OBIA, spektral, dokusal, mekansal ve topolojik özellikler kullanarak segmentleri sınıflara ayırmak amacıyla kullanılmaktadır. Bu yaklaşımla gerçekleştirilen bir çalışmada, 2004 İran depremi için yüksek çözünürlüklü uydu görüntülerini kullanılarak nesne tabanlı görüntü analizi (OBIA) ve Adaptif Ağ Tabanlı Bulanık Çıkarım Sistemi (ANFIS) ile bina hasar tespiti yapılmıştır. OBIA ile görüntü segmentasyonu ve ANFIS ile bir sınıflandırma işlemi gerçekleştirilerek hasarlı binalar başarıyla belirlenmiştir. Çalışma, bu yöntemlerin deprem hasar değerlendirmesinde etkili olduğunu ortaya koymuştur (Janalipour and Mohammadzadeh, 2015).

Başka bir çalışmada yüksek çözünürlüklü optik görüntüler (örn. UAV/WorldView) kullanarak deprem hasarlı binaları OBIA ve ML ile tespit edilmiştir. Nesne tabanlı sınıflandırmanın, binalar ve diğer yapılar gibi nesneleri bir bütün olarak inceleyerek, daha doğru hasar tespiti yapılmasını sağladığı belirtilmiştir (Bialas vd., 2016).

L'Aquila depremi (2009) sonrası bina değişikliklerini tespit etmek için uydu görüntülerinin OBIA ile analizi gerçekleştirilmiştir. Araştırmada, yüksek çözünürlüklü uydu görüntüleri kullanılarak binalardaki değişiklikler analiz edilmiştir. Çalışma, bu yaklaşımın deprem sonrası hasar haritalarının oluşturulmasında etkili olduğunu ve gelecekteki mühendislik kararları için değerli veriler sunduğunu ortaya koymuştur (Kersten vd., 2017).

Başka bir çalışmada İHA verilerinden çökmüş binaları tespit etmek için OBIA yöntemini kullanmıştır. Çalışmada, OBIA'nın İHA verileriyle hasar tespitinde etkili bir yöntem olduğu belirtilmiştir (Çömert, Matcı and Avdan , 2018).

2017 yılında yapılan başka bir çalışmada 23 Ekim 2011 tarihinde Van-Erciş'te meydana gelen depremde yıkılmış ve ağır hasar görmüş binaların tespitinde Nesne tabanlı sınıflandırma yöntemi kullanılarak eğitilmiş ve eğitimsiz sınıflandırma seçilen homojen ve heterojen bölge üzerinde gerçekleştirilmiştir. Elde edilen sonuçlar %66 ve üstü doğrulukla hasar gören bölgeler çıkarılmıştır (Sabuncu ve Sunar, 2017).

Bir başka çalışmada İran' da meydana gelen depremin ardından, WorldView-2 uydu görüntüleri kullanarak çok yüksek çözünürlüklü verilerle hasar tespiti gerçekleştirmiştir. Çalışmada, nesne tabanlı yarı otomatik bir görüntü analiz yöntemi uygulanmış ve bu yaklaşım, deprem temelli oluşan hasar haritalarının üretiminde etkili sonuçlar vermiştir (Omarzadeh vd., 2021).

2024 yılında gerçekleştirilen bir çalışmada deprem sonrası bina hasarlarını değerlendirmek için uydu görüntüleri ve nesne tabanlı sınıflandırma yaklaşımı kullanılmıştır. Çalışma, yaklaşımın afet sonrası hızlı hasar değerlendirmesindeki potansiyelini ortaya koymuştur (Kaya, 2024).

Deprem sonrası hasar değerlendirmede kullanılan piksel tabanlı yöntemlerin en belirgin eksikliği, görüntüdeki pikselleri tek tek inceleyerek aralarındaki mekânsal ilişkiyi dikkate almamasıdır. Bu durum, binaların sınır çizgileri gibi yapısal bütünlüğün önem taşıdığı alanlarda hatalı sonuçlara neden olabilmektedir. Görüntülerde karşılaşılan gölgelenme, parlaklık değişimleri ve yansımalar gibi doğal etkenler, analiz sürecinde gürültü olarak ortaya çıkmakta ve değerlendirme hatalarını artırmaktadır. Diğer yandan, hasar görmüş ve sağlam yapıların görüntü özelliklerinin birbirine benzemesi, bu yöntemlerin doğru ayırım yapmasını zorlaştıran bir diğer etkendir. Teknik olarak, yüksek çözünürlüklü uydu veya hava fotoğraflarında her bir pikselin ayrı ayrı işlenmesi ihtiyacı hem sistem kaynaklarını zorlamakta hem de analiz süresini önemli ölçüde uzatmaktadır. Bu durum, özellikle geniş alanları kapsayan afet bölgelerinde zamanında müdahale açısından pratikte sorun oluşturabilmektedir (Matin and Pradhana, 2022).

Derin öğrenme yöntemleri, deprem sonrası hasar tespitinde umut vaat etse de uygulamada karşılaşılan bazı temel engeller bu teknolojinin yaygın kullanımını sınırlamaktadır. En önemli sorunlardan biri veriyle ilgili yaşanan sıkıntılardır. Etkili bir model geliştirebilmek için çok sayıda etiketlenmiş görüntüye ihtiyaç duyulması, farklı

bölgelerdeki yapı karakteristiklerinin çeşitlilik göstermesi ve özellikle deprem öncesi yüksek çözünürlüklü görüntülerin eksikliği, araştırmacıların karşısına çıkan başlıca problemlerdir (Buda, Maki and Mazurowski, 2018).

Teknik açıdan bakıldığında, derin öğrenme modellerinin "kara kutu" olarak nitelendirilen yapısı, bu sistemlerin nasıl karar verdiğini tam olarak anlamamızı engellemektedir. Ayrıca, modellerin eğitim verilerine çok fazla uyum sağlayarak (overfitting) gerçek dünya verilerinde düşük performans gösterme riski de önemli bir handikap oluşturmaktadır. Hesaplama kaynakları açısından ise, özellikle derin sinir ağlarının eğitimi için gerekli olan yüksek işlem gücü ve büyük ölçekli veri depolama gereksinimleri, bu yöntemlerin uygulanabilirliğini zorlaştıran diğer faktörler arasında yer almaktadır. Tüm bu teknik zorluklar, sahada uygulama yapmayı karmaşık hale getirmekte ve pratik kullanımı sınırlandırabilmektedir (Reichstein vd., 2019).

Gerçek zamanlı veri işleme söz konusu olduğunda ise, büyük miktardaki görsel verinin işlenmesi sırasında yaşanan gecikmeler ve internet bağlantısına olan bağımlılıklar, acil müdahale durumlarında kritik dezavantajlar yaratabilmektedir (Jia and Ye, 2023).

Literatürde deprem sonrası meydana gelen hasarların belirlenmesinde geniş bir yer bulan nesne tabanlı analiz yöntemleri, mekânsal bağlamı koruma avantajıyla dikkat çekmektedir. Bu yaklaşımlar, piksel tabanlı yöntemlerin aksine, görüntüdeki yapıları (örneğin binalar, yollar veya köprüler) bir bütün olarak ele alır. Böylece, özellikle yapısal bütünlük açısından önemli olan çatı çökmesi veya duvar yıkımı gibi bileşenler arasındaki ilişkiler daha sağlıklı bir şekilde değerlendirilebilir. Nesne tabanlı sınıflandırmalar, görüntüdeki parazitlerden (gölge, yansıma gibi) daha az etkilenir; çünkü yalnızca tek tek piksellere değil, şekil, doku ve boyut gibi nesne özelliklerine odaklanır. Bu sayede, hasar düzeylerinin (örneğin hafif ya da ağır hasar) daha doğru sınıflandırılması mümkün hale gelir. Ayrıca bu yöntemler, işlem açısından da avantaj sunar. Diğer yöntemlere göre daha az veri işleyerek geniş alanlarda daha hızlı sonuç üretilebilir (Bialas vd., 2016).

Bu çalışmada, literatürde yapılan araştırmalar sonucunda, deprem sonrası hasar değerlendirme süreçlerinde karşılaşılan mekânsal bağlam kaybı, gürültü duyarlılığı ve sınıf dengesizliği gibi temel kısıtlamaları aşmak amacıyla, nesne tabanlı analiz yaklaşımı ile desteklenerek makine öğrenmesi yöntemlerinin karşılaştırılması hedeflenmiştir. Yüksek çözünürlüklü İHA görüntüleri üzerinde uygulanan farklı makine öğrenmesi algoritmalarının performansları, OA, PA ve UA metrikleriyle karşılaştırmalı olarak

değerlendirilmiştir. Çalışmanın temel amacı, nesne tabanlı yaklaşımın sağladığı bağlamsal avantajlarla birlikte makine öğrenmesi yöntemlerinin, bina ölçeğinde hasar tespiti ve sınıflandırmadaki etkinliğini nicel olarak ortaya koymaktır. Elde edilen bulgular, yüksek çözünürlüklü İHA görüntülerinin deprem hasar değerlendirme çalışmalarında ne ölçüde başarılı sonuçlar verebileceğini ve hangi algoritmaların daha uygun olduğunu sistematik bir şekilde sunmaktadır.

2. TEMEL KAVRAMLAR

Bu bölümde, tez kapsamında faydalanan sistemler, veri analiz araçları ve deprem felaketleri sonrası yıkılan binaların tespitine yönelik uygulanan yöntemler ayrıntılı bir şekilde açıklanmıştır.

2.1. Uzaktan Algılama

Uzaktan algılama, yeryüzü ve atmosfer hakkında bilgi toplamak için kullanılan bir yöntemdir ve doğrudan fiziksel temas gerektirmez. Özellikle geniş alanların düzenli bir şekilde gözlemlenmesi gerektiğinde oldukça faydalıdır. Bu yöntem, temel olarak elektromanyetik radyasyonun (EMR) farklı dalga boylarında algılanması ve değerlendirilmesi prensibine dayanır (Şekil 2.1). Bu işlem, genellikle hava araçları, uydular ya da İHA gibi platformlara monte edilmiş özel sensörler aracılığıyla yapılır. Sensörler, güneş ışığı gibi doğal kaynaklardan gelen veya cihaz tarafından üretilen elektromanyetik enerjiyi kullanarak yeryüzündeki nesnelerle olan etkileşimleri ölçer. Toprak, su, bitki örtüsü ve yapılar gibi yüzey unsurları, bu radyasyonu farklı şekillerde yansıtır ya da soğurur. Bu farklılıklar sensörler tarafından kaydedilip sayısal verilere çevrilir. Elde edilen veriler, daha sonra çeşitli analiz yöntemleriyle işlenerek yüzey özelliklerini belirlemek, değişimleri izlemek veya afet sonrası değerlendirmeler yapmak gibi birçok alanda kullanılabilir hale getirilir (Lillesand and Kiefer, 1981).



Şekil 2.1. Uzaktan algılama sistemleri (Campos-Taberner, 2017)

Uzaktan algılama teknolojisi, kökenlerini 19. yüzyılda fotoğraf tekniklerinin gelişimine borçludur. Ancak bu Alan asıl büyük sıçramasını, 1957 yılında Sovyetler Birliği'nin SPUTNIK-1 uydusunu ve 1972 yılında ABD'nin LANDSAT uydusunu yörüngeye yerleştirmesiyle yapmıştır (Campbell and Wynne, 2011).

İlk zamanlarda daha çok askeri keşif ve istihbarat toplama gibi sınırlı amaçlarla kullanılan bu teknoloji, zamanla çok farklı disiplinlerde kendine yer bulmuş ve geniş bir uygulama alanına yayılmıştır. Bugün uzaktan algılama, küresel ölçekte çevresel değişimlerin ve dinamiklerin takip edilmesinden, doğal ya da insan kaynaklı risk faktörlerinin ayrıntılı bir şekilde analiz edilmesine kadar pek çok kritik alanda kullanılmaktadır. Örneğin, afet yönetim süreçlerinin her aşamasında veri sağlanması, kaynakların daha verimli yönetilmesi için ekonomik çözümler üretilmesi gibi konularda bu teknoloji önemli bir rol oynamaktadır. Ayrıca, tropikal ormanlardaki bitki örtüsü çeşitliliğinin haritalanması gibi özel çalışmalarda da yüksek çözünürlüklü görüntüleme spektroskopisi ile başarılı sonuçlar elde edilmiştir (Féret and Asner, 2014).

Bu teknolojinin en büyük avantajlarından biri, zamansal çözünürlüğünün yüksek olmasıdır. Yani, belirli bir bölgedeki değişiklikleri sık aralıklarla ve sürekli olarak izlemek mümkün hale gelmiştir. Geleneksel yöntemlerle karşılaştırıldığında, uzaktan algılama hem daha ekonomik bir çözüm sunar hem de elde edilen verilerin doğruluğu açısından oldukça güvenilirdir. Bu özellikleriyle, çevresel izlemeden afet yönetimine, tarımsal planlamadan şehir gelişimine kadar pek çok alanda önemli bir araç haline gelmiştir.

Uzaktan algılama sistemlerinin temel taşlarından biri olan platformlar ve sensörler, Dünya yüzeyi ile atmosferine dair bilgileri uzaktan toplamak için önemli araçlar sunmaktadır. Bu platformlardan biri olan yer bazlı platformlar, uzaktan algılama sistemlerinde kullanılan temel platform türlerinden biridir ve Dünya yüzeyine yerleştirilmiş sabit ya da mobil sensör sistemlerini kapsar (Şekil 2.2). Bu platformlar, çevresel verilerin toplanması, analiz edilmesi ve çeşitli bilimsel araştırmalarda kullanılması amacıyla tasarlanmıştır. Yer bazlı platformlar, genellikle doğrudan temas gerektirmeyen ölçüm teknikleriyle veri toplama imkânı sunar ve bu özellikleri sayesinde uzaktan algılama uygulamalarında önemli bir yer edinmiştir. Bu sistemler, özellikle yerel ölçekte yüksek çözünürlüklü ve hassas veri toplama ihtiyacı duyulan alanlarda tercih edilir (Toth and Joźkow, 2016).



Şekil 2.2. Yer bazlı platformlar (Zheng vd., 2022).

İHA'lar, pilotun fiziksel olarak bulunmadığı, uzaktan kontrol ya da önceden programlanmış uçuş planlarıyla görevlerini yerine getiren hava araçlarıdır (Şekil 2.3). İlk olarak askeri amaçlarla, özellikle keşif ve gözetleme görevleri için geliştirilen İHA'lar günümüzde çok daha geniş bir uygulama alanına sahiptir. Bu araçlar, genellikle küçük ve hafif yapılarıyla dikkat çeker; ancak teknolojik gelişmelerle birlikte farklı büyüklük ve kapasitelerde modeller üretilmektedir. İHA'ların temel bileşenleri arasında uçuş kontrol sistemleri, sensörler, iletişim modülleri ve enerji kaynakları yer alır. Bu bileşenler, araçların otonom ya da yarı otonom bir şekilde çalışmasını sağlayarak, zorlu arazi koşullarında veya tehlikeli bölgelerde insan hayatını riske atmadan veri toplama imkânı sunar (Toth and Joźkow, 2016).



Şekil 2.3. Uydu ve hava uzaktan algılama platformları (Xiang, Xia and Zhang, 2019).

Uydu tabanlı platformlar, uzaktan algılama teknolojisinin en yaygın örneklerinden biridir ve Dünya'nın yüzeyini ve atmosferini incelemek için özel olarak tasarlanmış yörünge araçlarıyla donatılmıştır (Şekil 3). Bu platformlar arasında jeostatik uydular öne çıkar. Bunlar, Ekvator' un üstünde yüksek irtifalarda sabit bir yörünge izleyerek belirli bir bölgenin kesintisiz gözlemini mümkün kılar. Genelde meteorolojik gözlemler, hava durumu tahminleri ve iklim analizleri gibi alanlarda sıkça tercih edilirler. Öte yandan, kutupsal yörüngeli uydular daha alçak irtifalarda hareket eder ve her turda Dünya yüzeyinin farklı kesimlerini tarar. Bu tür uydular, arazi örtüsü haritalama çalışmaları, çevresel değişimlerin takibi ve afet yönetim süreçlerinde oldukça etkilidir (Zhang vd., 2022).

Uzaktan algılama sistemleriyle elde edilmiş olan veriler, dünya yüzeyini ve atmosferini fiziksel temas olmadan incelememizi sağlayan çeşitli bilgi kaynaklarını kapsamaktadır (Richards, 2005). Bu verilerden biri olan optik veriler, uzaktan algılama uygulamalarında sıkça kullanılan temel veri türlerinden biridir. Bu veriler, elektromanyetik spektrumun görünür (mavi, yeşil, kırmızı) ve yakın kızılötesi (NIR) gibi bantlarda, güneş ışığını kaynak olarak kullanan pasif sensörler aracılığıyla elde edilir. Yüzeyden yansıyan güneş ışığı, sensörler tarafından kaydedilerek farklı yüzey özelliklerinin ayırt edilmesini sağlar. Her yüzey tipi, örneğin bitki örtüsü, su kütleleri, çıplak toprak ya da yapay yapılar farklı dalga boylarında karakteristik yansıma davranışlarına sahiptir. Bu spektral özellikler sayesinde arazi örtüsü sınıflandırması, bitki sağlığı analizi, su varlıklarının izlenmesi ve kentsel alan haritalama gibi birçok uygulama

gerçekleştirilebilir. Optik veriler hem orta hem de yüksek mekânsal çözünürlükte sunulabildiğinden geniş alanları kapsayan bölgesel analizlerden ayrıntılı kentsel yapı haritalamalarına kadar farklı ölçeklerde değerlendirme yapılmasına olanak tanır. Uydu görüntüleri bu kapsamda yaygın olarak kullanılırken İHA ile elde edilen görüntüler afet sonrası analizlerde ve detaylı yapı tespiti gibi özel uygulamalarda öne çıkar. Ancak optik sistemlerin en büyük kısıtlarından biri, atmosferik koşullardan etkilenmeleridir. Özellikle bulutluluk, gölgeler ve düşük güneş açısı gibi durumlar veri kalitesini olumsuz etkileyebilir. Bu nedenle, veri toplama süreçlerinde uygun zamanlama ve ön işleme yöntemleri büyük önem taşır (Prasad vd., 2011).

Termal veriler, uzaktan algılamada yeryüzü yüzeylerini ve nesnelerin yaydığı termal radyasyonu ölçerek toplanan bir veri türüdür. Elektromanyetik spektrumun genellikle 3-14 mikrometre dalga boyu aralığında elde edilen bu veriler yüzey sıcaklıklarını analiz etmek için kullanılır. Nesnelerin sıcaklığına bağlı olarak yaydığı termal radyasyon, sayısal verilere dönüştürülerek çeşitli uygulamalarda değerlendirilir. Yüksek hassasiyet, termal verilerin bir diğer kritik özelliğidir. Termal sensörler, yüzey sıcaklıklarında 0.1°C gibi küçük değişiklikleri algılayabilir. Bu hassasiyet, tarımda bitki stresini izlemek, yeraltı su kaynaklarını belirlemek veya volkanik aktiviteleri takip etmek gibi uygulamalarda büyük önem taşır. Ayrıca, termal verilerin mekansal çözünürlüğü, kullanılan platforma bağlı olarak değişir. Örneğin, MODIS uydusu 250 m-1 km çözünürlükte veriler sağlarken, İHA'lara monte edilmiş termal kameralar santimetre ölçeğinde yüksek çözünürlüklü veriler üretebilir. Termal veriler, çok çeşitli uygulama alanlarına sahiptir. Afet yönetiminde yangın veya deprem sonrası analizler, çevre izlemede su kütlelerinin sıcaklık değişimlerinin takibi, kentsel planlamada ısı adalarının haritalanması ve tarımda sulama ihtiyaçlarının belirlenmesi gibi alanlarda yaygın olarak kullanılır. Örnek platformlar arasında Landsat 8/9 TIRS (100 m çözünürlük), Sentinel-3 SLSTR ve MODIS uyduları yer alır. Bu platformlar, termal verilerin geniş ölçekli analizlerde etkin bir şekilde kullanılmasını sağlar (Wang, Xu and Guo, 2024).

Radar verileri ise uzaktan algılamanın hava koşullarına takılmadan veri toplamamızı sağlayan bir çözümdür. Mikrodalga dalgalarıyla çalışan bu sistem, bulutlu havada veya gece bile kesintisiz bilgi toplama imkanı sunar. Sentinel-1 uydusundan aldığımız SAR verileri, deprem sonrası binalarda oluşan hasarı tespit etmede veya yeryüzündeki şekil değişikliklerini izlemede oldukça işe yarar. Bu özelliği sayesinde, radar verileri afet yönetimi gibi acil durumlarda vazgeçilmez bir araç haline gelir. LiDAR


verileri lazer teknolojisiyle elde edilir ve yüksek detaylı veriler oluşturmamızı sağlar. Bu veriler, ormanların ne kadar yoğun olduğunu anlamaktan binaların yüksekliklerini belirlemeye kadar geniş bir alanda kullanılır. Özellikle detaylı coğrafi haritalama ve yapı analizi gerektiren çalışmalarda tercih edilen LiDAR, uzaktan algılamanın en gelişmiş araçlarından biridir. Her biri kendine has avantajları olan bu veri türleri, çevremizi izlemek, afetleri yönetmek ve tarımımızı planlamak gibi konularda bilim insanlarına ve karar vericilere önemli yardımlar sunmaktadır (Liu, 2015).

2.2. Elektromanyetik Enerji / Elektromanyetik Spektrum

Elektromanyetik (EM) enerji, atomlardan elektromanyetik dalga ya da parçacık (foton) biçiminde yayılan bir enerji türüdür ve temel fiziksel özellikleri bakımından salınımlı elektrik ve manyetik alanların birleşiminden oluşur. Bu enerji, uzayda ışık hızıyla yaklaşık 3×10^8 m/s hızla hareket eder (Aggarwal, 2004). Elektromanyetik enerji, doğada hem dalga hem de parçacık özellikleri sergileyen bir yapıya sahiptir ve bu özelliği, uzaktan algılama, iletişim sistemleri, tıp ve enerji transferi gibi pek çok alanda kullanımını mümkün kılar. Özellikle uzaktan algılama teknolojilerinde, Dünya yüzeyinden ya da atmosferden yansıyan veya yayılan elektromanyetik enerji, sensörler aracılığıyla toplanarak analiz edilir ve bu sayede çevresel değişimlerin izlenmesi, arazi örtüsü haritalama veya afet yönetimi gibi uygulamalar gerçekleştirilir.

Elektromanyetik Spektrum, elektromanyetik enerjinin dalga boyu (λ) ve frekansı (ν) temel alınarak düzenlenmiş bir sınıflandırmadır (Şekil 2.4). Spektrum, enerjinin düzeyine ve madde ile etkileşim biçimlerine göre çeşitli bölgelere ayrılır: Gama Işınları, X-Işınları, Ultraviyole (UV) Işınları, Görünür Işık, Kızılötesi (IR), Mikrodalga ve Radyo Dalgalarıdır (Manickavasagan and Jayasuriya, 2014).

Bu bölgeler, elektromanyetik enerjinin farklı dalga boylarında sergilediği özellikleri ve uygulama alanlarını ifade eder. Örneğin, Gama Işınları ve X-Işınları yüksek enerjili ve kısa dalga boylu ışınlardır; bu nedenle tıp alanında (örneğin, röntgen cihazları) ve malzeme analizinde kullanılır. Ultraviyole ışınlar, özellikle biyolojik çalışmalarda ve sterilizasyon süreçlerinde önemli bir rol oynar.



Şekil 2.4. Elektromanyetik spektrum (Sunar, 2019)

Görünür Işık, insan gözünün algılayabildiği dar bir dalga boyu aralığını (yaklaşık 400-700 nm) kapsar ve uzaktan algılama uygulamalarında sıkça kullanılan multispektral görüntülerin temelini oluşturur. Kızılötesi bölge, ısı algılama ve termal görüntüleme gibi alanlarda kullanılırken, mikrodalga bölgesi ise radar sistemleri ve hava durumu izleme gibi uygulamalarda tercih edilir. Radyo Dalgaları ise en uzun dalga boyuna sahip bölgedir ve iletişim sistemlerinde yaygın bir şekilde kullanılır. Elektromanyetik Spektrum' un bu çeşitliliği farklı disiplinlerdeki araştırmalara ve pratik uygulamalara olanak tanır (Norgard and Best, 2017).

2.3. Enerji-Atmosfer Etkileşimi

Uzaktan algılamada enerji-atmosfer etkileşimi, elektromanyetik enerjinin atmosferle olan etkileşim süreçlerini ifade eder ve bu süreçler, uzaktan algılama verilerinin doğruluğu ile yorumlanabilirliği üzerinde temel bir rol oynar. Güneşten gelen elektromanyetik radyasyon, atmosfere ulaştığında saçılma, soğurma ve tekrar uzaya yansıma gibi fiziksel süreçlerden etkilenir. Bu etkileşimler, atmosferdeki gazlar, aerosoller ve bulutlar gibi bileşenler tarafından şekillendirilir (Lillesand, Kiefer and Chipman, 2015).

Saçılma, atmosferde ışığın farklı parçacıklarla etkileşime girerek yön değiştirmesi olarak tanımlanır ve genellikle üç kategoriye ayrılır: Rayleigh, Mie ve Seçmesiz saçılma. Rayleigh saçılımı, atmosferdeki gaz molekülleri ve küçük parçacıklar tarafından gerçekleştirilir ve özellikle kısa dalga boylarındaki ışık (örneğin, mavi ve mor ışık) üzerinde baskın bir etkiye sahiptir. Bu, gökyüzünün mavi görünmesinin temel nedenlerinden biridir. Mie saçılımı ise, polen, toz veya ince aerosol gibi daha büyük parçacıklar tarafından meydana gelir ve ışığın dalga boyuna daha az bağımlılık gösterir.

ve bu da genellikle beyaz veya gri tonlarda bir bulanıklığa yol açar. Seçmesiz saçılma, ışığın dalga boyundan çok daha büyük olan iri partiküllerle, örneğin büyük toz parçacıkları, su damlacıkları veya sis gibi unsurlarla etkileşime girmesi durumunda ortaya çıkar ve tüm dalga boylarındaki ışığı eşit şekilde dağıtarak genellikle beyaz bir görünüm oluşturur (Jensen, 2009).

Soğurma ise; atmosferik bileşenlerin belirli dalga boylarındaki ışıınım enerjisini emmesi işlemidir. Bu süreç, atmosferdeki gazlar ve partiküllerin kimyasal yapısına bağlı olarak farklı dalga boylarında gerçekleşir. Örneğin, su buharı kızılötesi bölgede güçlü soğurma bantlarına sahiptir ve atmosferin enerji dengesinde önemli bir rol oynar. Diğer bileşenler, örneğin ozon ultraviyole ışınları soğururken, karbondioksit de belirli kızılötesi dalga boylarında enerji emilimine katkıda bulunur. Bu süreçler hem iklim sistemlerinin anlaşılmasında hem de UA teknolojilerinin geliştirilmesinde kritik bir öneme sahiptir. Çünkü soğurma ve saçılma, atmosferin ışığı nasıl işlediğini ve yeryüzüne ulaşan enerjinin dağılımını doğrudan etkiler (Richards and Richards, 2022).

2.4. Enerji-Yeryüzü Nesneleri Etkileşimi

Uzaktan algılama teknolojisinde enerji ve yeryüzü nesnelerinin etkileşimi, bu sürecin temel kuramsal yapı taşlarından birini oluşturur ve elektromanyetik spektrum ile hedef-madde arasındaki enerji alışverişi üzerine yoğunlaşır. Elektromanyetik spektrum, güneşten gelen enerjiyi oluşturan farklı dalga boylarını (örneğin, görünür ışık, yakın kızılötesi, termal kızılötesi ve mikrodalga bölgeleri) kapsar. Bu enerji, yeryüzündeki nesne ve yüzeyler tarafından ya yansıtılır ya emilir ya da iletilir. Her bir yüzeyin bu enerjiye tepkisi, malzemenin fiziksel ve kimyasal özelliklerine bağlıdır. Bu benzersiz yansıma ve emilim desenleri her nesnenin "spektral imzası" olarak tanımlanır ve uzaktan algılamada nesnelerin ayırt edilmesini sağlar. Enerji-yeryüzü etkileşiminin detaylı analizi sayısal görüntü işleme teknikleriyle daha da derinleştirilir. Örneğin, yansıyan veya yayılan enerjinin yoğunluğu piksel değerleri olarak kaydedilir ve bu veriler kullanılarak bitki sağlığı, su varlığı veya arazi örtüsü değişimleri gibi parametreler hesaplanabilir. Enerji ile nesneler arasındaki bu dinamik ilişki, uzaktan algılamanın doğal kaynak yönetimi, tarım (örneğin, mahsul verim tahmini), ormancılık (yangın izleme), afet izleme (deprem veya sel hasar tespiti) ve kentsel planlama (kentleşme izleri) gibi çok çeşitli alanlarda etkin çözümler sunmasının temelini oluşturur. Bu bağlamda, enerji ve yeryüzü nesnelerinin etkileşimi, uzaktan algılama teknolojisinin hem teorik hem de pratik başarısının anahtarıdır (Lillesand, Kiefer and Chipman, 2015).

2.5. Görüntü İşleme

Görüntü işleme, dijital görüntülerin bilgisayarlar aracılığıyla analiz edilmesi ve üzerinde çeşitli düzenlemeler yapılmasını kapsayan disiplinler arası bir alandır. Tıp, astronomi, güvenlik sistemleri, robotik ve coğrafi bilgi sistemleri gibi geniş bir yelpazede uygulama alanı bulan bu teknikler ham görüntülerden anlamlı bilgiler elde etmeyi, görüntü kalitesini iyileştirmeyi ya da belirli özellikleri öne çıkarmayı amaçlar. Bu süreçte filtreler, görüntü verisi üzerinde matematiksel işlemler uygulayarak gürültüyü azaltmak, kenarları belirginleştirmek, renk düzenlemeleri yapmak veya görüntüdeki belirli yapıları ortaya çıkarmak gibi temel işlevleri yerine getiren önemli araçlar olarak öne çıkar (Jähne, 2005). Bir dijital görüntü pikseller adı verilen ve her biri belirli bir renk ile yoğunluk değerini temsil eden küçük birimlerden meydana gelir. Filtreleme işlemi, bu piksellerin değerlerini ve komşu piksellerle olan ilişkilerini dikkate alarak yeni piksel değerleri üretir. Bu işlem genellikle çekirdek ya da maske adı verilen küçük bir matris yardımıyla gerçekleştirilir. Çekirdek, görüntü üzerinde kaydırılarak her pikselin ve çevresindeki komşu piksellerin değerleri belirli katsayılarla çarpılır ve bu sonuçların toplamı ilgili pikselin yeni değerini oluşturur (Tyagi, 2018).

Filtreler, kullanım amaçlarına ve işlevlerine göre farklı kategorilere ayrılır. Doğrusal filtreler, çıktı piksel değerinin girdi piksellerinin doğrusal bir kombinasyonu olarak hesaplandığı filtrelerdir. Yaygın kullanılan doğrusal filtre türleri arasında şunlar bulunur: Ortalama Filtre (Mean Filter), bir pikselin ve komşularının değerlerinin ortalamasını alarak ani yoğunluk değişimlerini yumuşatır ve gürültüyü azaltır. Ancak bu işlem, görüntüdeki keskin kenarları bulanıklaştırabilir. Gauss Filtresi (Gaussian Filter), gürültüyü azaltmada ortalama filtreye benzer bir işlev görür. Fakat komşu piksellere uzaklıklarına göre ağırlıklar atayarak daha doğal bir bulanıklık etkisi yaratır ve kenar detaylarını daha iyi korur. Yüksek Geçiren Filtre (High-Pass Filter), görüntüdeki yüksek frekanslı bileşenleri (örneğin, keskin kenarlar ve detaylar) vurgularken düşük frekanslı bileşenleri (düz alanlar) bastırır. Bu nedenle kenar belirginleştirme ve detay çıkarma işlemlerinde tercih edilir. Düşük Geçiren Filtre (Low-Pass Filter) ise yüksek frekanslı bileşenleri azaltarak düşük frekanslı bileşenleri korur ve genellikle bulanıklaştırma veya yumuşatma işlemleri için kullanılır. Doğrusal olmayan filtreler ise çıktı piksel değerinin, girdi piksellerinin doğrusal olmayan bir fonksiyonu olarak hesaplandığı filtrelerdir ve özellikle gürültü giderme uygulamalarında doğrusal filtrelerle göre bazı avantajlar sunar. Örneğin, Medyan Filtresi (Median Filter), bir pikselin ve komşularının değerlerini

sıralayarak ortanca (medyan) değeri çıktı olarak belirler. Bu yöntem, özellikle "tuz ve biber" gürültüsü gibi ani ve seyrek yoğunluk değişimlerini temizlemede oldukça etkilidir ve kenar detaylarını koruma konusunda daha iyi sonuçlar verir. Morfolojik Filtreler (Morphological Filters) ise görüntüdeki şekil ve yapıları analiz etmek ve dönüştürmek için kullanılan işlemleri içerir. Erozyon, genişleme, açma ve kapama gibi temel morfolojik işlemler ise nesne tespiti, sınır çıkarma ve gürültü giderme gibi alanlarda yaygın şekilde kullanılır (Coady vd., 2019).

2.6. Sobel Filtresi

Sobel filtresi, görüntü işleme alanında kenar tespiti (edge detection) için yaygın olarak kullanılan bir türev tabanlı operatördür. Temel prensibi, görüntünün piksel yoğunluğundaki ani değişimleri matematiksel gradyan hesaplamalarıyla belirlemeye dayanır. Bu filtre, iki ayrı 3x3 boyutlu konvolüsyon çekirdeği (kernel) kullanır ve biri yatay (G_x), diğeri dikey (G_y) yöndeki yoğunluk değişimlerini ölçer. Bu çekirdekler, Formül 1' de verildiği şekilde ifade edilir:

$$G_x = \begin{bmatrix} -1 & 0 & +1 \\ -2 & 0 & +2 \\ -1 & 0 & +1 \end{bmatrix}, \quad G_y = \begin{bmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ +1 & +2 & +1 \end{bmatrix} \quad (2.1)$$

Her bir piksel için gradyan büyüklüğü (G) ve yönü (θ), Formül 2 de verilen formülle hesaplanır:

$$G = \sqrt{G_x^2 + G_y^2}, \quad \theta = \arctan\left(\frac{G_y}{G_x}\right) \quad (2.2)$$

Pratikte, hesaplama karmaşıklığını azaltmak için G büyüklüğü, mutlak değerlerin toplamıyla ($|G_x| + |G_y|$) de yaklaşık olarak ifade edilebilir (Gonzalez, 2009).

Sobel operatörünün en önemli avantajı, hesaplama verimliliği ve gürültüye kısmen dirençli olmasıdır. Çekirdeklerdeki ağırlıklandırma (örneğin, merkez satır/sütuna 2 kat katsayı uygulanması), yüksek frekanslı gürültülerin etkisini azaltırken kenarları korur. Ancak, düşük kontrastlı görüntülerde veya yumuşak geçişli kenarlarda performansı sınırlıdır. Ayrıca, kenar kalınlığının artmasına neden olabilir ve ince detayların kaybına yol açabilir (Szeliski, 2022).

Diğer kenar tespit yöntemleriyle karşılaştırıldığında, Sobel'in daha az hesaplama kaynağı gerektirmesi, gerçek zamanlı uygulamalarda tercih edilmesini sağlar. Ancak,

Canny'nin aksine kenar inceliği optimizasyonu veya histereze tabanlı eşikleme gibi gelişmiş özellikler içermez.

2.7. Segmentasyon

Görüntü segmentasyonu, dijital görüntüleri belirli bölgelere ayırarak analiz edilmesi gereken önemli alanları belirlemeye yarayan temel bir yöntemdir. Bu işlem, görüntüde analiz edilmek istenen belirli bölgelerin, örneğin bir binanın çatısı, bir tümör yapısı ya da bir yol hattı gibi unsurların diğer alanlardan ayrılmasını sağlar. Böylece analiz sadece bu anlamlı bölgelere odaklanarak daha etkin bir hale gelir. Ayrıca, ham görüntü tüm pikselleri kapsarken segmentasyon sayesinde yalnızca önemli kısımlar üzerinde çalışılır. Bu da işlem süresini kısaltır ve bellek kullanımını azaltır. Segmentasyonun bir diğer avantajı, sınıflandırma algoritmalarının daha doğru sonuçlar vermesine olanak tanımasıdır. Segmentasyon sonrası ortaya çıkan bölgesel yapılar bu algoritmaların daha iyi kararlar almasını destekler. Bunun yanı sıra, karmaşık sahnelerde farklı nesnelerin veya yüzeylerin daha net bir şekilde ayrılmasını sağlar. Özellikle birden fazla nesnenin bulunduğu görüntüler söz konusu olduğunda bu fayda daha belirgin hale gelir. Piksel tabanlı yöntemler, gölge, yansıma ya da renk değişimleri gibi etkenlerden kolayca etkilenebilirken, segmentasyon nesne odaklı bir yaklaşım benimsediğinden dolayı bu tür hataları en aza indirme potansiyeline sahiptir. Bu nedenle, görüntülerde nesneleri ayırt etmeye yönelik çalışmalarda sıkça tercih edilen bir yöntemdir (Yuheng and Hao, 2017).

Ancak, segmentasyon sürecinde bazı önemli zorluklarla karşılaşılmaktadır. Öncelikle, anlamlı bölgelerin doğru bir şekilde belirlenmesi her zaman kolay değildir. Görsel algı kişiden kişiye değişiklik gösterebildiği için bir alanın "nesne" mi yoksa "arka plan" mı olduğu konusunda net bir ayrım yapmak her zaman mümkün olmayabilir. Bu belirsizlik, özellikle karmaşık sahnelerde segmentasyon işlemini zorlaştırır ve sonuçların tutarlılığını etkileyebilir. İkinci bir zorluk ise görüntüdeki nesnelerin nasıl temsil edileceğiyle ilgilidir. Dijital görüntüler, temelde piksellerden oluşur ve bu piksellerin renk ya da doku gibi özellikleri kullanılarak bazı bölgeler gruplandırılabilir. Ancak bu tür yerel özellikler, genellikle görüntünün genel yapısını anlamak için yeterli değildir. Dolayısıyla, yalnızca piksellere dayalı yöntemlerle istenen doğrulukta sonuçlara ulaşmak zor olabilir. Bu bağlamda, görüntü segmentasyonunun daha etkili bir şekilde yapılabilmesi için hem yerel hem de genel görüntü özelliklerini dikkate alan bütüncül yaklaşımlara ihtiyaç

duyulmaktadır. Bu tür yaklaşımlar, özellikle karmaşık ya da çok nesneli sahnelerde daha iyi sonuçlar elde edilmesini sağlayabilir. Son yıllarda yapılan akademik çalışmalar, bu alanda geliştirilen yeni tekniklerin söz konusu zorlukların aşılmasına önemli katkılar sunduğunu ortaya koymaktadır. Bu gelişmeler segmentasyon yöntemlerinin daha güvenilir ve yaygın şekilde kullanılmasına olanak tanımaktadır (Yu vd., 2023).

2.8. Çoklu Çözünürlüklü Segmentasyon (MRS)

Literatürde segmentasyon süreçlerinde en yaygın olarak tercih edilen yöntemlerden biri MRS yöntemidir. Bu yöntem, görüntü analizinde bitişik nesnelerin yerel homojenlik ölçütlerine dayalı bir bottom-up (aşağıdan yukarıya) bölge birleştirme tekniği olarak tanımlanır. MRS, geleneksel segmentasyon yaklaşımlarının yalnızca ikili bir uyum/uyumsuzluk kriterine dayalı basit birleşim stratejilerinin ötesine geçerek her bir birleştirme işlemi için niceliksel bir birleştirme maliyeti hesaplar. Bu maliyet, segmentasyon sürecinin sistematik bir şekilde optimize edilmesini sağlar ve birleştirme kararlarını daha tutarlı bir temel üzerine oturtur. Süreç, homojenlik kriterlerini karşılayan olası birleşimlerin tamamen tükenene kadar tekrarlanan bir iterasyonla devam eder. Bu yinelemeli yaklaşım, görüntüdeki nesnelerin hiyerarşik bir yapıda organize edilmesine imkân tanır ve farklı ölçeklerdeki nesne sınırlarının belirlenmesini kolaylaştırır (Kim, Shim and Park, 2023).

MRS yönteminin işleyişi iki temel bileşen etrafında şekillenir. İlk bileşen, her bir iterasyonda hangi bölgelerin birleştirileceğine karar vermek için kullanılan sezgisel yöntemlerdir. Bu sezgisel yaklaşımlar, birleştirme sürecinde yerel özelliklerin ve komşuluk ilişkilerinin dikkate alınmasını sağlayarak segmentasyonun doğruluğunu artırır. İkinci bileşen ise, bir görüntü nesnesi çifti arasındaki uyum derecesini hesaplamak için geliştirilen homojenlik metrikleridir. Bu metrikler, bölge çiftleri arasındaki benzerlik derecesini değerlendirmek amacıyla renk histogramı, dokusal uyum ve sınır düzenliliği gibi çok yönlü kriterleri kapsar. Renk histogramı piksel yoğunluklarının dağılımını analiz ederken, dokusal uyum, nesnelerin yüzey özelliklerini karşılaştırması ve sınır düzenliliği gibi birleştirme sonrası nesnelerin kenarlarının tutarlılığını ölçer. Bu metriklerin birleşimi, segmentasyonun hem görsel hem de istatistiksel açıdan dengeli bir sonuç vermesini destekler (Batz and Schäpe, 2000).

Yöntemin uygulanışı, kullanıcı tarafından belirlenen üç kritik parametre ile kontrol edilir. Bunlar; ölçek parametresi, şekil parametresi ve kompaktlık parametresidir. Ölçek

parametresi, segmentasyon sürecinde alt nesnelerin üst nesnelere göre maksimum göreceli sınır uzunluğunu tanımlar ve birleştirme işleminin hangi ölçekte gerçekleşeceğini belirler. Bu parametre, görüntünün çözünürlüğüne ve analiz hedeflerine bağlı olarak ayarlanmalıdır. Örneğin, büyük ölçekli bir arazi haritalamasında daha yüksek bir ölçek değeri tercih edilebilir. Şekil parametresi, bölgelerin geometrik düzenliliğini ve biçimsel bütünlüğünü etkiler. Bu, nesnelerin şekillerinin korunması gereken durumlarda kritik bir rol oynar. Kompaktlık parametresi ise nesnelerin topolojik bütünlüğünü ve içsel düzgünlüğünü kontrol eder. Bu parametre, segmentasyon sonucunda ortaya çıkan nesnelerin dağınıklığını en aza indirmeyi amaçlar. Bu üç parametrenin optimize edilmesi MRS yönteminin adaptasyon yeteneğini artırır ve farklı görüntü türlerine (örneğin, uydu görüntüleri veya mikroskop görüntüleri) uygulanabilirliğini güçlendirir. MRS yöntemi, bu özellikleriyle, karmaşık görüntü verilerinin analizinde esneklik ve doğruluk sunar. Özellikle uzaktan algılama, tıp görüntüleme ve coğrafi bilgi sistemleri gibi alanlarda, nesnelerin hiyerarşik segmentasyonu sayesinde detaylı ve güvenilir sonuçlar elde edilmesini sağlar. Ancak, parametrelerin manuel olarak ayarlanması ve hesaplama maliyetinin yüksekliği gibi zorluklar yöntemin daha geniş ölçekli uygulamalarda geliştirilmesini gerektirebilir (Witharana and Civco, 2014).

2.9. Yapay Zeka (YZ)

YZ, insanın düşünme, öğrenme ve karar verme süreçlerini örnek alarak bu yetenekleri bilgisayar sistemlerine kazandırmayı hedefleyen bir teknolojidir. Bu alan, özellikle veri analizi, örüntü tanıma ve karar destek sistemleri gibi karmaşık problemlerin çözümünde önemli bir rol üstlenmektedir. YZ'nın bu özellikleri büyük ve karmaşık veri kümelerini anlamlı bilgilere dönüştürmede etkili bir araç olmasını sağlamıştır. Bu yönüyle, sadece bilimsel araştırmalara katkıda bulunmakla kalmamış, aynı zamanda uzaktan algılama, sağlık, eğitim, tarım ve endüstri gibi farklı sektörlerde yenilikçi uygulamaların önünü açmıştır (Hunt, 2014). Son yıllarda YZ, özellikle görüntü sınıflandırma alanında dikkate değer ilerlemeler kaydetmiştir. Geleneksel yöntemlerle görsel verilerden anlam çıkarmak, hem zaman açısından yoğun bir çaba gerektirir hem de insan hatalarına açık bir süreçtir. Ancak YZ algoritmaları, bu süreci hızlandırarak daha hassas sonuçlar elde edilmesini mümkün kılmıştır. Büyük hacimli görsel verilerin hızlı ve güvenilir bir şekilde işlenmesi, özellikle tıbbi görüntüleme, güvenlik kameraları ve uydu görüntülerinin analizi gibi alanlarda büyük bir kolaylık sağlamıştır. Zaman tasarrufu, bu teknolojinin yaygınlaşmasında kilit bir faktör olmuştur ve bu da YZ'nın

farklı disiplinlerdeki etkisini artırmıştır. YZ'nın sağladığı bu avantajlar, teknolojinin kullanım alanlarını çeşitlendirmiş ve çok sayıda sektöre entegre edilmesini teşvik etmiştir. Güvenlik alanında, yüz tanıma sistemleri sayesinde havaalanlarında kimlik doğrulama işlemleri daha hızlı ve güvenli hale gelmiştir. Üretim sektöründe, otomatik kalite kontrol sistemleri, ürünlerin kalitesini insan gözünden daha tutarlı bir şekilde değerlendirebilmekte ve bu da maliyetleri düşürmektedir. Bunun ötesinde, doğal afetler sonrası hasar tespit çalışmalarında YZ uydu görüntülerini analiz ederek yıkım alanlarını hızlıca haritalandırmada kullanılmaktadır. Bu da kurtarma ekiplerinin zamanında müdahale edebilmesine olanak tanır. Ayrıca, perakende sektöründe müşteri davranışlarını analiz ederek kişiselleştirilmiş alışveriş deneyimleri sunan sistemler ya da eğitimde öğrencilerin öğrenme süreçlerini izleyen akıllı platformlar gibi yenilikçi uygulamalar da YZ'nın disiplinler arası potansiyelini gözler önüne sermektedir. Bu örnekler, YZ'nın sadece teknik bir araç olmaktan çıkarak toplumun farklı katmanlarında pratik çözümler sunan bir teknoloji haline geldiğini göstermektedir (Ertel, 2024). YZ'nın bu geniş kapsamlı etkileri, araştırmacıları ve mühendisleri yeni uygulamalar geliştirmeye teşvik etmektedir. Örneğin, çevre koruma alanında orman yangınlarının erken tespiti için termal görüntü analizi yapan sistemler üzerinde çalışmalar yapılmaktadır. Benzer şekilde, trafik yönetiminde yol durumu ve yoğunluğunu gerçek zamanlı olarak izleyen YZ tabanlı araçlar geliştirilmektedir. Bu tür projeler, teknolojinin yalnızca mevcut sorunlara çözüm sunmakla kalmayıp, gelecekteki zorluklara da hazırlık yapmada önemli bir rol oynayabileceğini ortaya koymaktadır. Dolayısıyla, YZ'nın insan yaşamını kolaylaştırmadaki etkisi hem günümüzdeki uygulamalarda hem de uzun vadeli yeniliklerde kendini giderek daha belirgin bir şekilde hissettirmektedir (Joshi and Bagade, 2023).

2.10. Makine Öğrenim Algoritmaları (ML)

ML, YZ alanının temel bir alt dalı olarak kabul edilir ve bilgisayarların, kendilerine sunulan verilerden öğrenme yeteneği kazanarak karar verme süreçlerini yürütmesi ya da geleceğe yönelik tahminlerde bulunması amacıyla geliştirilmiş ileri bir disiplin olarak tanımlanabilir. Bu yöntem, büyük hacimli veri kümeleri üzerinde desenleri, ilişkileri ve gizli yapıları tespit etme yeteneğine dayanır ve bu bulguları, daha önce karşılaşılmamış ya da yeni verilerle ilişkilendirerek analiz yapma kapasitesi sunar. Bu sayede görüntü tanıma, veri sınıflandırma, regresyon analizi, doğal dil işleme, zaman serisi tahmini ve karmaşık sistem modellemesi gibi çok yönlü ve zorlu görevleri otomatik bir şekilde

yerine getirebilir. Makine öğrenimi, özellikle manuel analiz yöntemlerinin zaman açısından yetersiz kaldığı veya insan hatasına açık olduğu durumlarda, verilerin hızlı bir şekilde işlenmesini ve bu verilerden anlamlı çıkarımlar yapılmasını mümkün kılarak dikkat çeker. Makine öğrenimi modellerinin bir diğer güçlü yönü, yüksek doğruluk oranlarıyla tahminlerde bulunma yeteneğine sahip olmasıdır. Bu modeller, sürekli olarak yeni veri akışlarıyla beslenerek zaman içinde kendilerini geliştirme ve performanslarını optimize etme potansiyeline sahiptir. Bu öz-öğrenme (self-learning) özelliği, sistemlerin değişen çevresel koşullara, veri yapılarındaki farklılıklara veya kullanıcı ihtiyaçlarına adaptasyonunu kolaylaştırır ve uzun vadeli etkinliklerini artırır. Bu güçlü özellikler, makine öğrenimini akademik araştırmalardan endüstriyel uygulamalara kadar geniş bir yelpazede vazgeçilmez bir araç haline getirmiştir. Disiplinler arası çalışmalarda giderek daha fazla yer bulan bu teknoloji, yalnızca teknik problemlere çözüm sunmakla kalmaz, aynı zamanda farklı alanlardaki yenilikçi yaklaşımları teşvik eder. Örneğin, uzaktan algılama alanında, makine öğrenimi yöntemleri, iklim değişikliği izleme ve doğal afet yönetiminde kritik veriler sağlayarak çevresel politikaların şekillenmesine katkıda bulunur (Lary vd., 2016).

Bununla birlikte ML modelleri, eğitim verilerinin kalitesine ve temsil gücüne son derece bağımlıdır. Eğer veri seti eksik, dengesiz veya gürültülü ise modelin genelleme kapasitesi ciddi şekilde sınırlanır. Örneğin, bir sınıflandırma probleminde, belirli bir sınıfın az temsil edilmesi, modelin bu sınıfı doğru bir şekilde öğrenmesini engelleyebilir ve yanlış sonuçlara yol açabilmektedir. Ayrıca, yanlış etiketlenmiş veriler veya tutarsız veri formatları, modelin doğruluğunu olumsuz etkileyerek hatalı tahminlere neden olabilmektedir. Veri toplama süreçlerinin maliyetli ve zaman alıcı olması da bu dezavantajı daha belirgin hale getirmektedir. Ayrıca, ML modellerinin performansı hiperparametrelerin doğru bir şekilde ayarlanmasına bağlıdır. Ancak, bu optimizasyon süreci karmaşık ve zaman alıcıdır. Bu süreç, özellikle büyük veri setlerinde yoğun hesaplama kaynakları gerektirmekte ve bu da maliyetleri artırmaktadır. Ayrıca, hiperparametre optimizasyonu için kullanılan çapraz doğrulama gibi yöntemler, hesaplama süresini daha da uzatabilmektedir (Khanzode and Sarode, 2020).

2.11. Sınıflandırma

Sınıflandırma, veri bilimi, istatistik ve makine öğrenimi gibi disiplinlerde temel bir kavram olarak yer alır ve bir veri kümesindeki öğelerin, belirli özelliklere veya ölçütlere

dayanarak önceden tanımlı kategorilere ayrılması işlemidir. Sınıflandırma, gözlemlerin ya da nesnelerin benzerliklerine veya farklılıklarına göre sistematik bir şekilde gruplandırılmasını ifade eder. Bu süreç, genellikle bir veri setindeki örüntüleri ve ilişkileri anlamak, veri karmaşıklığını azaltmak ve anlamlı sonuçlar çıkarmak amacıyla gerçekleştirilir (Mitchell, 1997).

Uzaktan algılama görüntü sınıflandırması, bir görüntüdeki tüm piksel veya bölgelerin spektral özellikleri veya diğer özniteliklere dayanarak sınıflara veya temalara kategorize edilmesi sürecidir ve bu süreç, arazi kullanımı haritalama, çevre izleme, tarım ve kentsel planlama gibi uygulamalarda kritik bir rol oynar. Sınıflandırma yöntemleri arasında Piksel Tabanlı Sınıflandırma, çeşitli algoritmaların kullanıldığı basit ancak "tuz-biber" gürültüsüne yol açabilen bir yaklaşımdır. OBIA, pikselleri segmentlere gruplayarak şekil, doku ve bağlamsal bilgileri de dikkate alan ve yüksek çözünürlüklü görüntüler için daha doğru sonuçlar veren bir yöntemdir. Alt-Piksel Sınıflandırma ise, bir pikselin birden fazla arazi örtüsü türünü içerdiği durumlarda sınıf oranlarını tahmin ederek arazi örtüsü fraksiyon haritalama ve değişim tespiti gibi uygulamalarda kullanılır iken Alan Tabanlı Sınıflandırma, daha geniş bölgeler için tematik haritalama yaparak ince detay gerektirmeyen durumlarda tercih edilir. Sonuç olarak, görüntü sınıflandırması, ham uydu verilerini arazi örtüsü türlerini etiketleyerek uygulanabilir bilgilere dönüştürür (Li vd., 2014).

Sınıflandırma yaklaşımlarından biri denetimsiz öğrenmedir. Denetimsiz öğrenme, ML alanında önemli bir sınıflandırma yaklaşımıdır ve veri setindeki etiketlenmiş örneklerin bulunmadığı durumlarda verilerdeki doğal örüntüleri ve kümelenmeleri temel alarak gruplandırma yapmayı hedefler. Denetimsiz öğrenme yaklaşımında, veriler önceden belirlenmiş sınıf etiketleri olmadan analiz edilir. Bu nedenle modelin görevi verinin içsel yapısını ve benzerliklerini keşfetmektir. Yaygın olarak kullanılan denetimsiz öğrenme algoritmaları arasında K-Ortalamalar (K-Means), Hiyerarşik Kümeleme ve DBSCAN (Density-Based Spatial Clustering of Applications with Noise) gibi yöntemler bulunur. Bu algoritmalar, veri noktaları arasındaki mesafeleri veya yoğunluk ölçütlerini kullanarak gruplandırma işlemini yaparlar (Olaode, Naghdy, and Todd, 2014).

Denetimli öğrenme ise, makine öğrenimi alanında en yaygın kullanılan sınıflandırma yaklaşımlarından biridir ve bir veri setindeki örneklerin her birinin ait olduğu sınıf etiketleriyle birlikte bir modelin eğitimi için kullanılması esasına dayanır. Bu yöntem, etiketlenmiş bir eğitim veri setinden öğrenerek daha önce karşılaşılmamış ya

da etiketlenmemiş yeni verileri doğru bir şekilde sınıflandırmayı amaçlar. Denetimli öğrenme, özellikle veri setinin açıkça tanımlı sınıflarla yapılandırıldığı durumlarda sınıflandırma problemlerini çözmek için güçlü bir araç olarak kabul edilir ve geniş bir uygulama yelpazesine sahiptir. Denetimli öğrenme sürecinde, bir model, eğitim veri setindeki örneklerin özelliklerini ve bu özelliklerin ilgili sınıf etiketleriyle olan ilişkilerini analiz ederek öğrenir. Model, bu verilerden öğrenerek yeni bir görüntüdeki pikselleri doğru bir şekilde sınıflandırmayı hedefler. Bu süreç, modelin genelleme yeteneğini test etmek için genellikle eğitim ve test veri setlerine bölünmüş bir veri seti üzerinde gerçekleştirilir. Böylece modelin eğitim verisi dışındaki veriler üzerinde de başarılı olup olmadığı değerlendirilebilir. Denetimli öğrenme, birçok alanda başarılı sonuçlar vermesine rağmen bazı sınırlılıkları da beraberinde getirir. En önemli gerekliliklerden biri, etiketlenmiş bir veri setine ihtiyaç duymasındır. Bu ihtiyaç, veri etiketlemenin zaman alıcı ve maliyetli olabileceği durumlarda bir dezavantaj oluşturabilir. Ayrıca, eğitim veri setinin temsil gücü düşükse veya dengesiz bir dağılım gösteriyorsa modelin genelleme kapasitesi zayıflayabilir ve yanlış sonuçlar üretme riski artabilir (Gorte, 1999).

3. ÇALIŞMA ALANI VE KULLANILAN VERİ SETİ

Bu bölümde, çalışmanın gerçekleştirildiği coğrafi alanın fiziki ve beşeri özellikleri detaylı olarak ele alınmakta, aynı zamanda araştırmada kullanılan veri setinin özellikleri hakkında kapsamlı bilgiler sunulmaktadır.


3.1. Çalışma Alanı

Antakya, Hatay ilinin merkez ilçesi olarak Türkiye'nin güneyinde, Akdeniz Bölgesi'nin doğu kesiminde yer almaktadır. Coğrafi konumu itibarıyla önemli bir jeopolitik ve jeostratejik öneme sahip olan ilçe, 36°10' kuzey enlemleri ile 36°09' doğu boylamları arasında bulunur ve yaklaşık 86 km²'lik bir alana yayılmıştır. Antakya, Amanos Dağları ile Keldağ arasında uzanan Amik Ovası'nın güneybatı ucunda konumlanmış olup, Asi Nehri'nin oluşturduğu verimli bir vadi üzerinde kuruludur. Deniz seviyesinden ortalama 80-100 metre yükseklikte bulunan ilçe, çevresindeki 1.200 metreye kadar yükselen dağlık alanlarla çevrilidir. İlçede tipik Akdeniz iklimi hakim olup, yazları sıcak ve kurak, kışları ılık ve yağışlı geçmektedir. Yıllık ortalama sıcaklık 18-20°C, yağış miktarı ise 1.000-1.200 mm civarındadır. Doğal bitki örtüsü makilikler ve zeytin ağaçları ile karakterize olan bölgede, yüksek kesimlerde kızılçam ormanları görülmektedir. Antakya; Arap, Afrika ve Anadolu levhalarının kesişim noktasında yer aldığı için yüksek deprem riski taşımaktadır (Özşahin, 2010).

Antakya, Ölü Deniz Fay Zonu, Doğu Anadolu Fayı ve Kıbrıs Yayı gibi aktif tektonik yapıların kesişiminde yer aldığı için tarih boyunca sık sık yıkıcı depremlerle karşılaşmıştır. Tarihsel kayıtlara göre, M.Ö. 148, M.S. 115 (7.5 Ms, 260.000 ölüm), M.S. 526 (7.0 Ms, 250.000 ölüm) ve M.S. 588 (60.000 ölüm) gibi büyük depremler şehirde ciddi yıkımlara yol açmıştır. Orta Çağ'da 846-847 ve 1054 depremleri, modern dönemde ise 1822 (7.4 Ms, 20.000 ölüm) ve 1997 (5.2-5.5 Ms) depremleri kayda geçmiştir. Son olarak, 6 Şubat 2023'te Kahramanmaraş merkezli 7.7 ve 7.6 büyüklüğündeki depremler ile 20 Şubat'ta Defne (6.4) ve Samandağ (5.8) depremleri Antakya'da büyük yıkıma neden olmuştur. Tarihsel veriler, Antakya'nın 100-150 yılda bir 7.0 ve üzeri depremler yaşadığını gösterirken, şehir yedi kez tamamen yıkılıp yeniden inşa edilmiştir. 2023 depremleri, sekizinci büyük yıkım olarak kayıtlara geçmiştir (Dinç, 2015).

Çalışma kapsamında, Antakya'nın iki spesifik bölgesi analiz edilmiştir. Odabaşı Mahallesi sınırları içinde bulunan Alan-1, 36° 13' 00" ile 36° 14' 00" kuzey enlemleri ve 36° 09' 30" ile 36° 10' 30" doğu boylamları arasında konumlanırken, Güzelburç Mahallesi

sınırları içindeki Alan-2 ise 36° 14' 00" ile 36° 15' 00" kuzey enlemleri ve 36° 10' 00" ile 36° 11' 00" doğu boylamları arasında yer almaktadır (Şekil 3.1). Her iki alanın yüzölçümü, Alan-1 için 0,66 km² ve Alan-2 için 0,64 km² olarak hesaplanmıştır. Bu bölgeler, deprem sonrası hasar tespit çalışmalarının yoğunlaştığı ve jeolojik risklerin değerlendirildiği temel alanlar olarak seçilmiştir.




Şekil 3.1. Çalışma alanı.

3.2. Kullanılan Veri Seti

Bu tez çalışmasında, deprem sonrası yıkılan binaların yüksek doğrulukla tespit edilmesi amacıyla uzaktan algılama teknikleri kullanılarak İHA görüntülerinin sunduğu avantajlardan faydalanılmıştır. İHA'ların yüksek çözünürlüklü, güncel ve geniş alanları kapsayan görüntü sağlama kapasitesi, afet sonrası hasar değerlendirme süreçlerinde hızlı ve güvenilir veri temini için kritik bir rol oynamaktadır.

Bu çalışmada kullanılan İHA görüntüsü, yaklaşık 6,5 cm yer çözünürlüğüne sahiptir. Bu yüksek çözünürlük düzeyi, küçük ölçekli detayların net bir şekilde ayırt edilmesine olanak sağlayarak özellikle yapı bazlı analizlerde önemli bir avantaj sunmaktadır. Şekil 3.2'de, çalışma kapsamında elde edilen İHA görüntüsü sunulmuştur.




Şekil 3.2. İHA ile elde edilen görüntü

Ortofoto üretimi için toplam 642 adet görüntü kullanılmıştır. Görüntüler, konum bilgilerini içerecek şekilde WGS 84 (EPSG:4326) koordinat sistemine göre referanslanmıştır. Veriler, Agisoft Metashape yazılımı kullanılarak işlenmiştir. İlk olarak görüntüler hizalanmış ve kameraların konumları ile yönelim bilgileri hesaplanmıştır. Görüntüler yüksek doğrulukla hizalanmış, hizalama sırasında ortalama yeniden projeksiyon hatası 0.39 piksel olarak elde edilmiş olup bu da hizalamanın yüksek doğrulukta olduğunu göstermektedir. Görüntülerin işlenmesi sonucunda 6 saat 18 dakikalık işlem süresinin ardından yaklaşık 3.2 milyar noktadan oluşan yoğun nokta bulutu elde edilmiştir. Bu nokta bulutuna dayalı olarak oluşturulan yüzey modeli üzerinden, konumsal bozulmalardan arındırılmış ve yüksek çözünürlüklü ortofoto başarıyla üretilmiştir.

Görüntüleme sırasında kullanılan kamera sistemi elektromanyetik spektrumun görünür bölgesinde çalışmakta olup, kırmızı (R), yeşil (G) ve mavi (B) bantlarından oluşan üç kanallı görüntüler üretmektedir. Bu görüntü, analiz sürecinde temel görsel veri kaynağı olarak kullanılmış ve hasar tespiti amacıyla geliştirilen yöntemlerin uygulanmasında ana bileşeni oluşturmuştur.

4. YÖNTEM

Bu çalışmada, deprem sonrası yapı hasarlarının tespiti amacıyla, çok yüksek çözünürlüklü İHA görüntülerine dayalı bir analiz yöntemi geliştirilmiştir. Özellikle afet sonrası müdahale süreçlerinde zamanın kritik öneme sahip olması nedeniyle, İHA'ların sağladığı güncel, detaylı ve geniş alanı kapsayan görüntüler, hızlı ve güvenilir veri temini açısından önemli bir avantaj sunmaktadır. Bu doğrultuda oluşturulan sistematik analiz süreci, görsel verilerin işlenmesinden başlayarak hasar tespiti sonuçlarının elde edilmesine kadar uzanan bir dizi aşamayı içermektedir. Şekil 4.1'de Çalışma kapsamında uygulanan iş akışı verilmiştir.




Şekil 4.1. Çalışmada uygulanan yöntem

Şematik olarak sunulan bu iş akışı; görüntülerin toplanması, verilerin hazırlanması, segmentasyon, sınıflandırma algoritmaları kullanılarak hasarlı ve hasarsız yapıların ayrıştırılması, doğruluk analizi ve sonuçların karşılaştırılması adımlarını kapsamaktadır. Her bir aşama, veri kalitesi ve sınıflandırma doğruluğunu artırmaya yönelik olarak özenle yapılandırılmıştır. Böylelikle, deprem sonrası müdahale planlamasında kullanılabilecek, mekânsal olarak anlamlı ve güvenilir hasar haritalarının üretilmesi hedeflenmiştir.

4.1. Veri Toplama

Deprem gibi doğal afetlerin ardından ortaya çıkan yıkımın hızlı ve güvenilir bir şekilde değerlendirilmesi, müdahale sürecinin etkinliği açısından büyük önem taşımaktadır. Bu noktada, son yıllarda kullanımı giderek yaygınlaşan İHA, afet bölgelerinde veri toplama ve hasar tespiti açısından önemli bir araç olarak öne çıkmaktadır. İHA'lar, yüksek çözünürlüklü görüntüleme sistemleri ve çeşitli sensörlerle donatılabilmesi sayesinde, erişimi güç ya da tehlikeli olan alanlardan dahi kısa sürede ayrıntılı veriler toplayabilmektedir (Laghari vd., 2023).

Bu bölümde tez kapsamında kullanılan görüntüleri elde eden İHA ve bu görüntülerin elde edilme süreci verilmektedir. Şekil 4.2'de çalışmada kullanılan görüntülerinde elde edilmesinde kullanılan İHA'nın görseli bulunmaktadır.



Şekil 4.2. İHA görseli (<http-2>)

Bu çalışmada analiz edilen yüksek çözünürlüklü görsel veriler, Atlatus markasının Otus modeli olan bir İHA kullanılarak elde edilmiştir. Söz konusu İHA, özellikle hassas yer gözlemi ve fotogrametrik uygulamalar için tasarlanmış olup, yüksek kaliteli görüntüleme sistemine ve stabil uçuş kabiliyetine sahiptir. İHA, hem geniş alanları kısa sürede tarayabilme kapasitesi hem de düşük irtifada uçuş yaparak ayrıntılı mekânsal veri sağlayabilme özelliği ile araştırma sahasında etkili veri toplama imkânı sunmuştur. Kullanılan sistem, entegre GPS ve atalet ölçüm birimi (IMU) gibi konumlandırma bileşenleri sayesinde, elde edilen görüntülerin coğrafi olarak hassas şekilde referanslanmasına olanak tanımıştır. Araştırmada kullanılan Otus İHA'nın teknik donanımına ve temel özelliklerine ilişkin ayrıntılı bilgiler Tablo 4.1' de sunulmaktadır.

Tablo 4.1. İHA teknik özellikleri (http-2).

Sıralama	Özellik	Değer
1	Ağırlık	2,3 kg
2	Kanat Açıklığı	120 cm
3	Kanat alanı	33 dm ²
4	Boyut	120x60x9 cm
5	Uçuş Süresi	50 dk(Güvenli) 70dk (Maksimum)
6	Menzil	60 km (Güvenli) 84 km (Maksimum)
7	Seyir Hızı	72 km/s
8	Kalkış/İniş	Katapult/Paraşüt
9	Yer Örnekleme Aralığı (GSD)	2 cm /15 cm
10	Faydalı Yük	24 MP Sony A6000 (ILCE-6000)

Çekim sırasında kullanılan kamera, Sony Alpha 6000 modelidir (Şekil 4.3). Bu kamera ile elde edilen görüntüler 6000 x 4000 piksel çözünürlüğünde olup, yüksek görsel kalite sağlamaktadır.



Şekil 4.3. Çalışmada kullanılan görüntülerin çekimini gerçekleştiren kamera görseli (<http-3>)

Tablo 4.2'de çalışma kapsamında İHA ile gerçekleştirilen uçuşlar sırasında kullanılan Sony Alpha 6000 aynasız dijital kameranın teknik özellikleri detaylı bir şekilde sunulmaktadır.


Tablo 4.2. Kamera teknik özellikleri (<http-3>)

Sıralama	Özellik	Değer
1	Model Adı	A6000 / ILCE-6000
2	Kamera Türü	Aynasız (Mirrorless)
3	Sensör Boyutu	23.5 x 15.6 mm
4	Maksimum Görüntü Çözünürlüğü	6000 x 4000 piksel
5	Efektif Piksel Sayısı	24.3 megapiksel
6	Toplam Piksel	24.7 megapiksel
7	Deklanşör	1/4000 – 30 s + Bulb modu
8	Dosya Formatları	JPEG, RAW (Sony ARW 2.3)

İHA ile uçuş sırasında kameranın konumu ve hata tahmin grafiği, veri doğruluğunu ve analiz güvenilirliğini sağlamak için kritik öneme sahiptir. Kameranın konumu, çekilen görüntülerin coğrafi olarak doğru bir şekilde referanslanmasını sağlar. Bu da ortofoto ve DEM gibi ürünlerin hassas bir şekilde oluşturulması için gereklidir. Konum verileri olmadan, görüntüler mekânsal bağlamdan yoksun kalır ve analizler yanlış sonuçlar verebilir (Toth and Jożkow, 2016).

Bu bağlamda İHA'nın veri toplama esnasında kamera konum hataları meydana gelmektedir. Aşağıdaki görselde Agisoft Metashape yazılımında bir fotogrametri projesinin tamamlanmasının ardından oluşturulan Processing Report çıktısından alınmıştır. Görsel, raporun "Camera Error Vectors" (Kamera Hata Vektörleri) başlıklı analizine aittir ve projede kullanılan her bir fotoğrafın tahmini konum hatalarını görselleştirmektedir. Bu analiz, proje doğruluğunu değerlendirmek, veri kalitesini kontrol etmek ve gerekli durumlarda iyileştirmeler yapmak amacıyla kullanılır. Görselde, hava fotoğraflarının çekildiği her bir konumu temsil eden renkli eliptik simgeler yer almaktadır. Bu simgeler, her bir kameranın (fotoğrafın) hesaplanan konum hatasını ve hatanın yönünü ifade eder. Vektörlerin boyutları ve yönleri, her bir fotoğraf için tahmin edilen hata miktarını ve hangi yöne doğru bir sapma olduğunu gösterir. Haritada görülen elipsler, hata vektörlerinin gerçek değerlerinden 30 kat büyütülerek çizildiğini belirtir. Bu büyütme oranı, hata vektörlerinin görsel olarak daha net bir şekilde analiz edilebilmesi amacıyla kullanılır.


Lejant üzerinde belirtilen 0 (sıfır)m değeri ise, hata miktarının metre cinsinden ölçülmediğini, normalize edilmiş bir değer olduğunu ve sıfıra yakın bir hata olması durumunda ideal bir sonuç elde edildiğini ifade ederken, sıfır değerine yakın olan bölgeler ise kameranın tahmini konum hatasının çok düşük olduğu ve modelin doğruluğunun yüksek olduğu bölgeleri temsil etmektedir. Şekil 4.4'de gerçekleştirilen uçuş esnasında kameranın konumu ve hata tahmini verilmiştir.



Şekil 4.4. Kameranın konumu ve hata tahmini

Uçuş kolonları, İHA'ların belirli bir alanda veri toplamak için izlediği planlı uçuş rotalarını ifade eder. Bu rotalar, genellikle paralel çizgiler halinde düzenlenir ve uçuş yüksekliği, bindirme oranları ile kapsanacak alanın özelliklerine göre tasarlanır. Uçuş kolonları, İHA'nın kamerasının görüntü çektiği alanları sistematik bir şekilde örtmesini sağlayarak veri setinde boşlukların veya tekrarların önüne geçmektedir (Toth and Jożkow, 2016).

Çalışma kapsamında kullanılan görüntülerin çekimi için gerçekleştirilen uçuş planlaması, toplamda 8 kolondan oluşacak şekilde gerçekleştirilmiştir. Bu görselleştirme, çok küçük hataların bile görsel olarak fark edilmesini sağlar. Şekil 4.5'de İHA'nın kamera konumlarını ve çekilen görüntülerin örtüştüğü alanların göstermektedir.




Şekil 4.5. Kamera konumları ve görüntü örtüşmesi

Yer Kontrol Noktaları (YKN), İHA ile uçuş sırasında çekilen görüntülerin coğrafi olarak doğru bir şekilde referanslanması için kullanılan, arazide fiziksel olarak belirlenmiş ve hassas ölçüm cihazlarıyla koordinatları bilinen sabit noktalardır. Bu noktalar, genellikle belirgin işaretlerle işaretlenir ve uçuş öncesinde veya sonrasında konumları yüksek hassasiyetle kaydedilir (Wolf and Dewitt, 2000).

Çalışmada kullanılan görüntülerin fotogrametrik işleme süreci, Agisoft Metashape Professional yazılımı ile gerçekleştirilmiştir. Bu yazılım, fotogrametri ve üç boyutlu modelleme alanında yaygın olarak kullanılan, profesyonel bir araçtır. Yukarıdaki görsel, Agisoft Metashape yazılımı kullanılarak oluşturulan bir uçuş kapsama yoğunluğu haritasını (coverage map / image overlap map) göstermektedir. Haritanın lejantında bulunan renkler, aynı bölgenin kaç farklı fotoğraf tarafından görüntülendiğini ifade etmektedir. Kırmızı renkler, 3B modelleme için yetersiz kapsama alanlarını gösterirken; mavi renkler, sağlıklı bir 3B modelin oluşturulabileceği alanları temsil etmektedir ve fotogrametri projelerinde veri kalitesini değerlendirmek için kritik bir araçtır. İHA, hava


fotoğrafları veya yer tabanlı çekimlerden elde edilen yüksek çözünürlüklü görüntülerden üç boyutlu nokta bulutları, DEM, dijital yüzey modelleri (DSM), dijital arazi modelleri (DTM), ortofoto mozaikler ve ayrıntılı üç boyutlu modeller üretmek için tasarlanmıştır. Agisoft Metashape, Structure from Motion (SfM) ve Multi-View Stereo (MVS) algoritmalarını birleştirerek görüntüleri eşleştirir, kamera konumlarını hesaplar ve yoğun nokta bulutları oluşturur. Bu süreçte, görüntülerin geometrik ve radyometrik özellikleri dikkatlice analiz edilerek yüksek doğruluklu üç boyutlu rekonstrüksiyonlar elde edilir. Yazılım, kullanıcı dostu arayüzü ve otomatikleştirilmiş iş akışlarıyla dikkat çeker; çoklu GPU desteği ve yüksek hassasiyetli çıktılar sunar. Uzaktan algılama, haritacılık, şehir planlama, arkeoloji, madencilik ve kültürel miras gibi alanlarda sıkça tercih edilir. Özellikle İHA tabanlı fotogrametri uygulamalarında, yazılımın sunduğu yüksek otomasyon ve santimetre altı doğruluk, saha çalışmalarının etkinliğini artırır. Ayrıca, entegre kalibrasyon araçları, kamera parametrelerinin optimize edilmesini ve projeksiyon hatalarının azaltılmasını sağlamaktadır (Over vd., 2021).

Bu süreçte, yedi adet YKN kullanılarak görüntüler coğrafi olarak doğrulanmış ve yüksek mekânsal hassasiyet sağlanmıştır. Lejant kısmında ise YKN'ler 600 kat büyütülmüştür ve 0(sıfır) cm değeri yatay ve düşey doğrultudaki konumsal hatanın cm'den daha hassas olduğunu gösterirken kırmızı renge doğru gidildikçe hata artı yönde artarken, mavi renge gidildikçe eksi yönde artış göstermektedir. Şekil 4.6'da toplanan YKN'lere ait görsel verilmiştir.



Şekil 4.6. Yer kontrol noktaları

Bu çalışmada kullanılan görüntülerin elde edilmesi sürecinde uygulanan uçuş planı, İHA ile gerçekleştirilen veri toplama işleminin sistematik ve kontrollü bir şekilde yürütülmesini sağlamak amacıyla önceden belirlenmiş parametrelere göre oluşturulmuştur (Şekil 4.7).



Şekil 4.7. Uçuş planı


Bu çalışmada kullanılan görüntünün elde edilmesi için tasarlanan uçuş planlaması, toplamda 8 kolondan oluşacak şekilde yapılmış ve plan doğrultusunda 642 adet hava

fotoğrafi çekilmiştir. Uçuş, 477 metre irtifada gerçekleştirilmiş olup, toplamda yaklaşık 10,5 km² büyüklüğünde bir alanı kapsamıştır. Uçuş sırasında ileri bindirme oranı %80, yan bindirme oranı ise %50 olarak belirlenmiştir. Planlanan uçuş toplamda 51 dakika sürmüştür.

4.2. DEM Oluşturma


Dijital Yükseklik Modeli (DEM), yeryüzünün topografik yapısını üç boyutlu olarak temsil eden ve yükseklik bilgilerini düzenli bir ızgara (grid) veya Triangulated Irregular Network (TIN) yapısında saklayan sayısal bir veri setidir. Bu modeller, arazi yüzeyinin geometrik özelliklerini sayısal olarak kodlayarak yükseklik verilerinin analiz edilmesine olanak tanır (Balasubramanian, 2017). DEM'lerin üretiminde çeşitli teknolojiler ve yöntemler kullanılmaktadır. Bu yöntemler, veri kaynağına ve uygulanan tekniklere bağlı olarak çeşitlilik gösterir. Bu yöntemlerden biri olan Fotogrametrik yöntemler, stereoskopik hava fotoğrafları (genellikle %60 örtü oranıyla çekilen) kullanılarak yükseklik verilerinin türetilmesinde yaygın olarak uygulanır. Paralaks eşleştirme algoritmaları, örneğin Semi-Global Matching (SGM), bu süreçte kritik bir rol oynar. Yersel fotogrametri ise Structure from Motion (SfM) teknikleriyle, özellikle küçük ölçekli alanlarda santimetre ölçeğinde yüksek çözünürlüklü DEM'ler üretmek için tercih edilir. Uydu tabanlı teknolojiler ise geniş alanların DEM'lerini oluşturmak için idealdir. SAR interferometrisi (InSAR), Sentinel-1 gibi uydularla milimetre hassasiyetinde deformasyon ölçümleri yapabilir; ancak DEM üretimi için genellikle metre ölçeğinde doğruluk sunar (örneğin, TanDEM-X ile 2-10 metre). IFSAR (Interferometric SAR) sistemleri, RADARSAT ve TanDEM-X gibi platformlarla geniş ölçekli DEM üretiminde kullanılır. Optik stereo görüntüleme sistemleri, ALOS PRISM ve Pleiades gibi uydularla yüksek çözünürlüklü DEM'ler sağlar. Ayrıca, havadan LiDAR (ALS), yüksek doğruluklu (10-50 cm) ve yüksek çözünürlüklü (1-5 puan/m²) DEM'ler üretir. Ayrıca bu yöntem, yoğun bitki örtüsü altındaki arazi yapısını bile tespit edebilen bir yeteneğe sahiptir. Karasal LiDAR (TLS) ise madencilik ve arkeoloji gibi alanlarda detaylı yüzey modelleri oluşturmak için uygundur. Bunun yanı sıra, GNSS ölçümleri ve topoğrafik haritalardan türetilen veriler de düşük çözünürlüklü DEM'ler elde etmek için alternatif yöntemler olarak değerlendirilebilir (Hancock and Willgoose, 2001).

Bu çalışmada oluşturulan DEM fotogrametrik yöntemlerle elde edilmiştir. Çözünürlüğü 6,5 cm'dir. Elde edilen DEM katmanı Şekil 4.8'de verilmiştir.



Şekil 4.8. *Oluşturulan DEM*

Üretilmiş olan DEM katmanından eğim verisi türetilerek sınıflandırma sürecine dahil edilmiştir. Ayrıca, kenar tespiti amacıyla Sobel filtresi uygulanarak ek bir veri katmanı oluşturulmuştur (Şekil 4.9).



Şekil 4.9. Oluşturulan katmanlar a) Sobel b) Eğim katmanı

4.3. Segmentasyon

Bu çalışmada, deprem gibi doğal afetlerin ardından hasar görmüş binaların tespiti için İHA görüntülerine dayalı bir analiz yöntemi uygulanmıştır. Analiz sürecinde temel olarak çok sık kullanılan bir OBIA yöntemi olan MRS tercih edilmiştir. Literatürde sıkça kullanılan ve başarılı sonuçlar sunduğu bilinen MRS yöntemi, özellikle farklı ölçeklerde görüntü verilerini işleyebilme ve karmaşık sahnelerde nesne sınırlarını daha net tanımlayabilme özelliğiyle öne çıkmaktadır. Bu yöntem; ölçek, şekil ve renk gibi parametreleri ile, özellikle karmaşık enkaz alanlarında daha uyumlu segmentasyon sonuçları elde edilmesini sağlamaktadır. Ancak literatürde, MRS yönteminin deprem sonrası hasar tespiti özelinde parametre ayarlarının sistematik biçimde optimize edildiği çalışmalar oldukça sınırlıdır. Çoğu çalışmada segmentasyon sabit parametrelerle yapılmakta, ancak bu parametrelerin çalışma sahasına özgü koşullara—örneğin bina yoğunluğu ya da enkazın karmaşıklığı—bağlı olarak değişebileceği yeterince dikkate alınmamaktadır (Janalipour and Mohammadzadeh, 2015).

Bu da segmentasyonun doğruluğunu azaltarak, sonraki sınıflandırma aşamalarında hatalara yol açabilmektedir. Bu tez kapsamında ise, MRS yöntemiyle yapılan segmentasyon adımıda kullanılan parametrelerin—ölçek, şekil ve renk ağırlıkları sistematik biçimde optimize edilmiştir. Çalışma kapsamında elde edilen RGB görüntü, DEM, Eğim ve Sobel verileri, analizlerin yürütüldüğü eCognition Developer yazılımına yüklenmiştir. Segmentasyon aşamasında, bu katmanlara belirli ağırlıklar verilerek çok katmanlı bir segmentasyon gerçekleştirilmiştir. Bu kapsamda; DEM katmanına 3, RGB görüntüye 2, eğim verisine 2 ve Sobel verisine 1 ağırlık değeri atanmıştır. Belirlenen ağırlıklar ve parametreler kullanılarak gerçekleştirilen segmentasyon sonucunda elde edilen nesneler üzerinden manuel olarak eğitim verileri toplanmıştır.

4.4. Model Eğitimi

Eğitim verileri, çalışmanın yürütüldüğü her iki Alan (Alan-1 ve Alan-2) için aynı yöntem izlenerek oluşturulmuştur. Bu veriler, sınıflandırma aşamasında kullanılmak üzere dikkatle seçilmiş ve her sınıfı temsil edecek şekilde toplanmıştır. Bu eğitim verilerinin sayısı ve belirlenen sınıflar çalışma alanında bulunan nesnelerin yoğunluk durumuna göre farklılıklar göstermektedir. Alan-1’ de oluşturulan sınıflar ve toplanan eğitim verilerinin sayısal değerleri Tablo 4.3’te verilmiştir.

Tablo 4.3. Alan-1 için toplanan eğitim verileri.

Alan-1	Beton				Kırmızı	Siyah	Yeşil	
	Çatılı Bina	Çadır	Enkaz	Gölge	çatılı bina	Çatı Bina	Alan	Yol
Eğitim Veri Sayısı	224	24	398	244	176	51	431	416

Alan-1’ de beton çatı bina, çadır, enkaz, gölge, kırmızı çatı bina, siyah çatı bina, yeşil alan, yol sınıfları belirlenmiş ve toplam 1964 adet eğitim verisi toplanmıştır. Alan-2’ de araç, beton çatı bina, çadır, enkaz, gölge, kırmızı çatı bina, su alanı, yeşil alan, yol, diğer sınıfları belirlenmiş ve toplam 2049 adet eğitim verisi toplanmıştır (Tablo 4.4).

Tablo 4.4. Alan-2 için toplanan eğitim verileri.


Alan-2	Araç	Beton					Kırmızı	Su	Yeşil	Yol
		Çatılı Bina	Çadır	Diğer	Enkaz	Gölge	Çatılı Bina	Alanı	Alan	
Eğitim Veri										
Sayısı	114	301	64	47	333	300	296	11	207	376

4.5. Sınıflandırma Adımı

Bu çalışmada, deprem sonucu yıkılmış binaların tespiti amacıyla ML tabanlı üç farklı sınıflandırma yöntemi olan SVM, RF ve KNN algoritmaları kullanılmıştır. Bu yöntemlerin seçilmesinde temel etken, literatürde özellikle uzaktan algılama verilerinin sınıflandırılmasında yaygın biçimde tercih edilmeleri ve birçok çalışmada yüksek doğruluk oranlarıyla başarılı sonuçlar vermiş olmalarıdır. Her bir yöntemin farklı veri yapıları ve sınıflandırma problemleri karşısında gösterdiği performans, hasar tespiti gibi karmaşık senaryolarda da bu algoritmaların işe yarar olduğuna işaret etmektedir. Ayrıca, bu yöntemler görece düşük hesaplama maliyetine sahip olmaları ve uygulanabilirliklerinin yüksek olması nedeniyle, özellikle geniş alanlara ait verilerin hızlı ve güvenilir biçimde analiz edilmesi gereken afet sonrası süreçlerde avantaj sağlamaktadır. Bu bağlamda, çalışmada bu üç yöntemin karşılaştırmalı olarak değerlendirilmesi, hangi algoritmanın benzer çalışmalar için daha uygun olduğunu ortaya koymak açısından önemli bir adım olarak düşünülmüştür.

4.5.1. K- en yakın komşuluk (KNN)

KNN algoritması, makine öğrenmesinde en temel ve sezgisel sınıflandırma yöntemlerinden biridir. Bu algoritma, "benzer örneklerin benzer şekilde davranacağı" prensibine dayanarak çalışır. Öğrenme aşamasında herhangi bir model oluşturmaz, bunun yerine tüm eğitim verilerini hafızasında saklar ve tahmin yaparken bu verileri kullanır. KNN algoritmasının da ilk olarak K değeri belirlenir ki bu tahmin yaparken dikkate alınacak komşu sayısını ifade eder. Daha sonra, test örneği ile tüm eğitim örnekleri arasındaki mesafeler hesaplanır. Son adımda ise en yakın K komşunun sınıf bilgilerine bakılarak tahmin yapılır (Fix, 1985). KNN algoritmasının iş akışı Şekil 4.10'da verilmiştir.



Şekil 4.10. KNN algoritması


Algoritmanın performansını belirleyen en önemli faktörlerden biri kullanılan mesafe ölçütüdür. En yaygın kullanılan ölçüt Öklid mesafesidir ve iki nokta arasındaki düz çizgi uzaklığını hesaplar. Manhattan mesafesi ise ızgara şeklindeki yollar üzerinden hesaplama yapar. Minkowski mesafesi bu ikisini genelleştirirken, Mahalanobis mesafesi özellikler arasındaki korelasyonu dikkate alır. Algoritmanın performansını belirleyen bir diğer faktör ise K parametresinin belirlenmesidir. Çok küçük K değerleri gürültüye duyarlılığı artırırken çok büyük değerler sınırları bulanıklaştırabilmektedir (Pandey and Jain, 2017).

KNN'nin avantajlarından biri teorik olarak basit ve uygulama açısından kolay olması ve karmaşık matematiksel modellemeye ihtiyaç duymamasıdır. KNN, parametrik olmayan bir yöntemdir; yani veri dağılımı hakkında herhangi bir varsayımda bulunmaz.

Bu da onu farklı veri yapıları için esnek kılmaktadır. Bunun yanında KNN çok sınıflı sınıflandırma problemlerinde etkili şekilde çalışabilir. Algoritmanın dezavantajı ise, her test noktası için tüm eğitim örnekleriyle mesafe hesaplaması yapması nedeniyle önemli bir hesaplama maliyeti doğurmasıdır (Yahia and Ibrahim, 2003).

4.5.2. Rastgele orman(RF)

RF, hem sınıflandırma hem de regresyon problemlerinde yaygın olarak kullanılan, güçlü bir toplu öğrenme (ensemble learning) yöntemidir (Şekil 4.11). Bu algoritma, çok sayıda karar ağacı oluşturarak ve bu ağaçların sonuçlarını birleştirerek daha doğru ve güvenilir tahminler üretmeyi amaçlar. RF'nin temel çalışma prensibi, eğitim verisinden rastgele örnekleme (bootstrap sampling) yaparak her bir ağaç için farklı veri alt kümeleri oluşturmak ve her ağacı bu verilerle bağımsız olarak eğitmektir. Ağaçların her biri, karar noktalarında tüm özellikler yerine yalnızca rastgele seçilmiş bir alt küme üzerinden bölünmeler gerçekleştirir; bu yaklaşım, modelin çeşitliliğini artırarak genel performansın iyileştirilmesini sağlar. Her bir karar ağacı kendi başına karmaşık yapılar sergileyebilir ve eğitim verisine aşırı uyum gösterebilirken, tüm ağaçların çıktılarının ortalaması (regresyon için) veya çoğunluk oyu (sınıflandırma için) alınarak elde edilen sonuçlar, daha dengeli ve genellenebilir hale gelir (Breiman, 2001).




Şekil 4.11. RF Algoritması

Bu yöntem, özellikle yüksek boyutlu veri kümelerinde başarılı performans göstermesi, eksik verilerle esnek bir şekilde başa çıkabilmesi ve değişken önem düzeylerini analiz edebilme gibi avantajlara sahiptir. Ancak, çok sayıda ağacın oluşturulması ve yönetilmesi nedeniyle işlem süresi uzayabilir ve modelin yorumlanabilirliği tek bir karar ağacına kıyasla daha düşüktür. Tüm bu yönleriyle RF, karmaşık veriler üzerinde yüksek doğrulukta tahminler yapabilen güvenilir bir makine öğrenmesi algoritması olarak öne çıkmaktadır.

4.5.3. Destek vektör makineleri (SVM)

SVM, makine öğrenmesi alanında özellikle sınıflandırma problemlerinde sıkça başvurulan bir yöntemdir. SVM' in temel prensibi, farklı sınıflara ait verileri birbirinden en iyi şekilde ayıracak bir hiper düzlem belirlemektir. Bu düzlem, sınırlarda yer alan ve destek vektörü olarak adlandırılan veri noktalarına olan uzaklığı en büyük olacak biçimde seçilir. Böylece modelin farklı veri kümelerine genelleme yapma yeteneği artar ve aşırı öğrenmenin önüne geçilmiş olur. SVM sadece doğrusal olarak ayrılabilen veri kümeleriyle sınırlı değildir (Şekil 4.12). Eğer veriler doğrusal olarak ayrılmıyorsa, çekirdek fonksiyonu adı verilen bir yöntemle veriler daha yüksek boyutlu bir uzaya taşınarak burada doğrusal bir ayırım sağlanabilir. Tüm bu özellikleriyle SVM, farklı türde sınıflandırma problemlerine karşı esnek ve güçlü bir çözüm sunar (Kuzey, 2012).



Şekil 4.12. SVM Algoritması

Bu yöntemin avantajlarından biri, yüksek boyutlu verilerle uyum sağlayabilmesi ve sınırlı sayıda örnekle bile başarılı sonuçlar elde edebilmesidir. Ayrıca, doğrusal olmayan verilerin sınıflandırılmasında çekirdek fonksiyonlarını kullanarak esnek ve etkili çözümler sunma kapasitesiyle öne çıkar. Bununla birlikte, yöntemin bazı zayıf yönleri de bulunmaktadır. Özellikle büyük veri kümeleri üzerinde eğitim süreci oldukça zaman alıcı olabilir ve bu durum, yöntemin bellek kullanımını da önemli ölçüde artırabilir. Bu nedenlerle, yöntem küçük ve orta ölçekli veri setlerinde oldukça başarılı sonuçlar verse

de büyük veri setleri ya da gerçek zamanlı uygulamalar için tercih edilirliliği sınırlı kalabilir.

4.6. Hasar Tanımlaması

Depremler, tarih boyunca insan yaşamını ve yerleşim alanlarını doğrudan etkileyen en yıkıcı doğal afetlerden biri olarak kabul edilmiştir. Yeryüzünün farklı bölgelerinde sıklıkla meydana gelen bu olaylar, özellikle nüfusun yoğun olduğu şehir merkezlerinde can kaybı, yaralanmalar, ekonomik kayıplar ve altyapı üzerinde ciddi tahribatlar yaratmaktadır. Depremlerin ani ve öngörülemez doğası, afet sonrası müdahale ve değerlendirme süreçlerini daha da karmaşık hale getirmekte; bu süreçlerin sağlıklı yürütülmesi için bilimsel temellere dayalı sistematik yaklaşımların geliştirilmesini zorunlu kılmaktadır. Bu bağlamda (Grunthal, 1998) deprem sonrası hasar tespiti süreçlerine rehberlik etmek amacıyla, yapıların maruz kaldığı hasarı belirli kategorilere ayıran bir sınıflandırma sistemi geliştirmiştir. Bu sistem, yapıların taşıyıcı elemanlarında oluşan deformasyon düzeyine ve genel yapısal bütünlüğüne göre hasar derecelerini sınıflandırmakta ve böylece müdahale önceliklerinin belirlenmesine katkı sağlamaktadır. Grunthal tarafından önerilen bu geleneksel hasar sınıflandırma yöntemi hem mühendislik hem de afet yönetimi disiplinlerinde yaygın olarak kabul görmekte olup risk analizi, kaynak planlaması ve yeniden inşa süreçlerinde temel bir referans olarak kullanılmaktadır. Bu çerçevede, afet sonrası sürecin hızlı, tutarlı ve nesnel bir şekilde yürütülmesine olanak tanırken aynı zamanda uluslararası karşılaştırmalara da uygun bir standartlaşma sağlamaktadır. Bu geleneksel bina hasar sınıfları, hasarın ciddiyetini ve müdahale önceliklerini belirlemede temel bir rehber olarak işlev görmekte olup, Tablo 4.5' de detaylı bir şekilde özetlenmiştir.

Tablo 4.5. *Yapılarda meydana gelen hasarın sınıflandırılması* (Grunthal, 1998)

Yapılar	Güçlendirilmiş yapılar	Hasar sınıflandırması
		1. Derece: Önemsiz ila hafif hasar (yapısal hasar yok, hafif yapısal olmayan hasar)
		2. Derece: Orta hasar (hafif yapısal hasar, orta düzeyde yapısal olmayan hasar)
		3. Derece: Önemli ila ağır hasar (orta yapısal hasar, ağır yapısal olmayan hasar)
		4. Derece: Çok ağır hasar (ağır yapısal hasar, çok ağır yapısal olmayan hasar)
		5. Derece: Yıkım (çok ağır yapısal hasar)

Bu tez çalışmasında, kullanılan İHA tabanlı uzaktan algılama sistemlerinin nadir görüntüleme geometrisinden dolayı, bu çalışmada özellikle beşinci derece yapıların tespitine odaklanılmıştır.

4.7. Doğruluk Analizi

Uzaktan algılanan verilerin farklı disiplinlerde etkili bir şekilde kullanılabilmesi için bu verilerin işlenmesi ve yorumlanması kritik bir öneme sahiptir. Bu süreçlerin sonucunda elde edilen çıktılarının güvenilirliğini değerlendirmek amacıyla doğruluk analizleri gerçekleştirilmektedir. Bu bağlamda, en yaygın olarak tercih edilen yöntemlerden biri hata matrisi yaklaşımıdır. Hata matrisi, referans alanlardan toplanan verilerin, haritada sınıflandırılmış bilgilerle sistematik bir şekilde karşılaştırılmasını sağlayarak, analiz sonuçlarının doğruluğunu nicel olarak ortaya koyar (MacLean and Congalton, 2012).

Hata matrisinden, aşağıdaki önemli doğruluk metrikleri türetilir:

Genel Doğruluk: Sınıflandırma modellerinin performansını değerlendirmek için kullanılan temel bir doğruluk metriğidir ve bu metrik, analiz sürecinde doğru bir şekilde sınıflandırılan toplam örnek sayısının, çalışmada dikkate alınan tüm referans örnek sayısına oranlanmasıyla hesaplanır. Bu hesaplama, modelin veri seti üzerindeki genel başarısını nicel bir şekilde ortaya koyar ve özellikle karmaşık veri yapılarında algoritmanın tutarlılığını ölçmede önemli bir gösterge olarak işlev görür. Genel Doğruluk değeri, sınıflandırma sonuçlarının ne ölçüde güvenilir olduğunu yansıtır ve bu metrik, farklı algoritmaların karşılaştırmalı analizinde birincil kriterlerden biri olarak değerlendirilir. Ayrıca bu metriğin hesaplanması, modelin yalnızca belirli bir sınıf üzerindeki performansını değil, tüm veri seti üzerindeki toplam etkinliğini kapsayarak, daha bütüncül bir değerlendirme sunar (Sugimori, 2019).


Üretici Doğruluğu: Sınıflandırma süreçlerinde her bir sınıfın performansını değerlendirmek için kullanılan önemli bir metrik olarak tanımlanır. Bu metrik, her bir sınıf özelinde doğru bir şekilde sınıflandırılmış piksel sayısının, o sınıfa ait toplam referans piksel sayısına bölünmesiyle hesaplanır. Bu oran, referans verilerin harita üzerinde ne derece doğru ve eksiksiz bir şekilde temsil edildiğini ölçerek, modelin belirli bir sınıfı ne kadar iyi tanımlayabildiğini gösterir. Bu metrik, modelin eksik sınıflandırma veya yanlış sınıflandırma yaptığı durumları ortaya koyarak, hangi sınıfların daha fazla iyileştirme gerektirdiğini belirlemede önemli bir rehber sağlar. Ayrıca, Üretici Doğruluğu, özellikle az temsil edilen sınıfların tespit edilme başarısını değerlendirmede faydalıdır (Foody, 2020).

Kullanıcı Doğruluğu: Sınıflandırma modellerinin performansını değerlendiren temel bir metrik olarak tanımlanır ve her bir sınıf için doğru bir şekilde sınıflandırılmış piksel sayısının, o sınıfa atfedilen toplam piksel sayısına oranlanmasıyla hesaplanır. Bu metrik, haritanın kullanıcı açısından güvenilirliğini ölçmek amacıyla geliştirilmiş olup, bir sınıfa atanan piksel sayısının ne kadarının gerçekten o sınıfa ait olduğunu ortaya koyar. Bu metrik, yanlış sınıflandırmaların (örneğin, bir hasarlı bina alanının başka bir sınıf olarak etiketlenmesi) oranını da dolaylı olarak yansıttığı için, haritanın saha uygulamalarında ne kadar güvenilir bir rehber olabileceğini gösterir. Ayrıca, Kullanıcı Doğruluğu, farklı sınıflar arasında karışıklıkların ne ölçüde kullanıcıyı yanıltabileceğini analiz ederek, sınıflandırma modelinin iyileştirilmesi gereken yönlerini belirlemede rehber bir araç olarak işlev görür. Bu bağlamda, metrik, afet yönetimi gibi zaman kritik

uygulamalarda karar alma süreçlerini destekleyen haritaların kalitesini artırmaya yönelik önemli bir gösterge sunar (Patel and Kaushal, 2010).

Doğruluk analizi, sınıflandırılmış uzaktan algılama verilerinin güvenilir olmasını sağlayarak, arazi kullanım planlaması, çevre izleme ve tarım gibi alanlarda karar alma süreçlerinde güvenle kullanılabilmesini temin eder.

Bu doğrultuda çalışma kapsamında, rassal olarak Alan-1 (a) için 800, Alan-2 (b) için 1000 adet nokta oluşturulmuştur. Hata matrisi oluşturmak için hazırlanan noktaların görüntüsü Şekil 4.13’ de verilmiştir.




Şekil 4.13. Doğruluk analizi için oluşturulan noktaların görüntüsü a) Alan-1 b) Alan-2

5. BULGULAR VE TARTIŞMA

Bu bölümde, araştırma kapsamında kullanılan materyal ve belirlenen yöntemler doğrultusunda elde edilen analiz sonuçları detaylı bir biçimde ele alınmıştır. Çalışmada uygulanan yöntemlerin doğruluğu ve etkinliği, çeşitli görsel ve sayısal performans değerlendirme kriterleri çerçevesinde kapsamlı bir şekilde analiz edilmiştir. Elde edilen bulgular, kullanılan veri setleri ve makine öğrenme algoritmaları doğrultusunda değerlendirilmiş; her bir yöntemin hasar tespiti üzerindeki başarımı nicel verilerle desteklenmiştir.

5.1. Segmentasyon Parametreleri Optimizasyonu


MRS yönteminde parametrelerin doğru seçilmesi, görüntüdeki nesnelerin (örneğin, binalar veya çadırlar) doğru bir şekilde ayrıştırılmasını sağlar. Hatalı parametre ayarları, aşırı segmentasyon veya birleşik segmentasyon gibi hatalara yol açarak analiz doğruluğunu düşürebilir. Bu nedenle, parametrelerin çalışma alanının özelliklerine (örneğin, bina yoğunluğu veya arazi karmaşıklığı) uygun şekilde optimize edilmesi, hasar tespiti gibi uygulamalarda güvenilir ve anlamlı sonuçlar elde edilmesini kritik önemde kılar. Bu doğrultuda, çalışma kapsamında, elde edilen İHA görüntüsüne uygulanan MRS yöntemine ait parametreleri belirleme çalışması yapılmıştır. Alan 1’de yapılan çalışmalardan seçilen örnekler Şekil 5.1’de verilmiştir.



Şekil 5.1. a) Ölçek 30, Şekil 0.3, Yoğunluk 0.7 b) Ölçek 30, Şekil 0.9, Yoğunluk 0.1


Şekil 5.1-b'de görüldüğü üzere enkaz alanları yol ve çatı gibi diğer bölgelerle karıştırılmıştır. Buna karşılık, Şekil 5.1-a'da bu tür detayları yüksek düzeyde başarıyla ayırt ederek net bir şekilde yakalamıştır.

Alan 2'de yapılan çalışmalardan seçilen örnekler Şekil 5.2'de verilmiştir.



Şekil 5.2. a) Ölçek 35, Şekil 0.2, Yoğunluk 0.7 b) Ölçek 35, Şekil 0.9, Yoğunluk 0.1


Çalışma kapsamında gerçekleştirilen segment parametre denemeleri sonucunda Alan-1 çalışma bölgesinde Ölçek 35, Şekil 0.3, Yoğunluk 0.7 olarak belirlenirken, Alan-2 çalışma bölgesinde Ölçek 36, Şekil 0.2 ve Yoğunluk 0.7 olarak belirlenmiştir (Şekil 5.3). Çalışma alanları içerisinde farklı yapılar olmasından ve çalışma bölgeleri ayrı iki Alan olduğundan dolayı segment parametreleri farklılık göstermektedir.



Şekil 5.3. Segmentasyon sonuçları a) Alan-1 b) Alan-2

5.2. Sınıflandırma Sonuçları


Segmentasyon işleminin ardından, sınıflandırma aşamasında KNN, RF ve SVM algoritmaları algoritmaları uygulanarak performansları değerlendirilmiştir. Bu yöntemler iki farklı çalışma alanında uygulanmıştır. Şekil 5.4'de Alan-1'e ait IHA görüntüsünün KNN ile sınıflandırma sonucu elde edilen sonuç haritası verilmiştir.



Şekil 5.4. Alan-1 de KNN yöntemi ile elde edilen sonuç haritası

Görsel olarak incelenen sonuç haritasına göre, genel anlamda başarılı bir sınıflandırma performansı elde edilmiştir. Özellikle hasarlı bina alanlarının doğru bir şekilde tespit edildiği gözlemlenirken, diğer sınıfların ayrıştırılmasında önemli bir karışıklık olmadığı anlaşılmıştır. Bununla birlikte, spektral yansımaları oldukça benzer olan yollar ile beton çatılı binaların bazı bölgelerde birbirine karıştığı tespit edilmiştir.


Şekil 5.5'de Alan-1'e ait IHA görüntüsünün RF ile sınıflandırma sonucunda elde edilen sonuç haritası verilmiştir.



Şekil 5.5. Alan-1 de RF yöntemi ile elde edilen sonuç haritası

RF ile oluşturulan sonuç haritasının görsel inceleme bulguları, KNN algoritmasıyla elde edilen sonuçlara paralel olarak oldukça başarılı bir sınıflandırma performansı sergilediğini ortaya koymaktadır. Hasarlı bina alanlarının büyük ölçüde doğru bir şekilde belirlendiği gözlemlenirken, spektral yansımaları birbirine yakın olan yollar ile beton çatılı binalar arasındaki karışıklığın daha düşük seviyede olduğu tespit edilmiştir.

Şekil 5.6'da Alan-1'e ait IHA görüntüsünün SVM ile sınıflandırma işlemi sonucunda elde edilen sonuç haritası verilmiştir.




Şekil 5.6. Alan-1 de SVM yöntemi ile elde edilen sonuç haritası

Sonuç haritasının görsel incelemesiyle, hasarlı bina alanlarının oldukça başarılı bir şekilde tespit edildiği görülmüştür. Bununla birlikte, yollar ile beton çatılı binaların büyük ölçüde birbirine karıştığı belirlenmiştir.

Çalışmanın bir sonraki aşamasında, yüksek kullanıcı doğruluğu ile belirlenen (SVM sonucu) enkaz alanları Humanitarian Data Exchange (HumData) platformunda yer alan ve 2023 depreminde yıkılan binalara ilişkin verilerle karşılaştırılmıştır (Şekil 5.7). HumData, insani kriz durumlarında veri paylaşımını daha kolay hale getirmek için 2014 yılında hayata geçirilmiş bir açık veri platformudur. Birleşmiş Milletler İnsani İşler Koordinasyon Ofisi (OCHA) bünyesinde faaliyet gösteren Centre for Humanitarian Data tarafından yönetilmektedir. HumData, 254' ten fazla bölgeden toplanmış 18.000' den fazla veri setini bir araya getirerek, insani yardım kuruluşları ve araştırmacılar için güvenilir ve güncel bir veri kaynağı sunar. Platform, veri hizmetleri, veri bilimi, veri sorumluluğu ile öğrenme ve uygulama gibi alanlarda çalışmalar yürütür; temel amacı ise kriz anlarında müdahale süreçlerini ve karar alma mekanizmalarını desteklemektir (Abuoda, Hendrix and Campo, 2021).

Alan-1 için elde edilen sonuçlar Şekil 5.7'de verilmiştir.




Şekil 5.7. Alan-1 de belirlenen enkaz alanları ve Humdata karşılaştırılması

Yapılan karşılaştırmalı analizlerde, Humdata tarafından sağlanan yıkılan binalara ait oturma alanlarının tamamının, uygulanan ML yöntemi tarafından enkaz olarak sınıflandırıldığı tespit edilmiştir. Bu durum, ML tabanlı yaklaşımların yıkılmış bina tespitinde yüksek doğruluk sağladığını göstermektedir. Özellikle, hasar görmüş yapıların enkaz alanlarının belirlenmesinde modelin başarılı performans sergilediği gözlemlenmiştir. Ancak, oluşturulan sonuç haritalarının detaylı incelenmesi, mevcut ML yöntemlerinin binaların orijinal oturma alanlarını doğru şekilde tanımlamada sınırlı kaldığını ortaya koymaktadır. Bunun yerine, modelin temel olarak yıkım sonrası oluşan enkaz tabakasını tespit edebildiği anlaşılmaktadır. Bu bulgu, ML algoritmalarının yapısal hasar değerlendirmede etkili olmakla birlikte, bina temel alanlarının belirlenmesi gibi daha hassas detaylar için ek iyileştirmelere ihtiyaç duyulduğunu göstermektedir. Elde edilen veriler, afet sonrası hızlı müdahale ve hasar analizinde ML tekniklerinin kullanışlı olduğunu desteklemektedir. Ancak, bina ayak izlerinin doğru şekilde haritalanabilmesi için çoklu veri kaynaklarının entegrasyonunun (örn., olay öncesi sonrası karşılaştırma, LiDAR verileri) araştırılması önerilmektedir.

Google Earth programı, yalnızca güncel uydu ve hava fotoğraflarını sunmakla kalmayıp, aynı zamanda kullanıcılarına "Tarihi Görüntüler" sekmesi aracılığıyla geçmişe

yönelik görüntüleri de inceleyebilme imkânı tanımaktadır. Bu özellik sayesinde, belirli bir bölgedeki zaman içindeki değişimler detaylı bir şekilde analiz edilebilmektedir.

Şekil 5.8’de, yıkılan binaların ayak izleri, Google Earth’ün geçmiş tarihli ortofoto görüntülerinden sayısallaştırılarak elde edilmiştir. Bu sayısallaştırma ile yıkılan bina ayak izlerinin, ML algoritması kullanılarak üretilen enkaz alanlarıyla büyük ölçüde örtüştüğü belirlenmiştir. Ancak, sınıflandırma sürecinde binaların gölgesinde kalan enkaz alanlarının gölge sınıfı olarak algılanması nedeniyle bu bölgelerde doğru bir enkaz sınıflandırması yapılamamıştır. Sonuç olarak, binaların gölgesinde kalan yıkılmış bina ayak izleri ile enkaz sınıfı tam olarak örtüşmezken, diğer alanlarda yüksek bir örtüşme başarısı sağlanmıştır.



Şekil 5.8. Alan-1 de belirlenen enkaz alanları ve yıkılmış bina ayak izleri karşılaştırılması

Alan-1 de gerçekleştirilen sınıflandırma performansının nicel olarak değerlendirilebilmesi amacıyla bir hata matrisi (confusion matrix) oluşturulmuştur. Hata matrisi üzerinden; genel doğruluk (Overall Accuracy - OA), sınıf bazında üretici doğruluğu (Producer' s Accuracy - PA) ve kullanıcı doğruluğu (User' s Accuracy - UA) metrikleri hesaplanmıştır. Sınıflandırma sonuçlarının istatistiksel analizi bu veriler üzerinden gerçekleştirilmiştir olup Söz konusu doğruluk değerleri Tablo 5.1'de sunulmuştur.

Tablo 5.1. Alan-1'e ait doğruluk analizi sonuçları

Yöntem		K-NN			SVM			RF	
Metrikler	OA	UA	PA	OA	UA	PA	OA	UA	PA
BetonÇatı		0.63	0.75		0.58	0.65		0.57	0.75
Cadır		0.60	0.33		0.60	0.19		0.40	0.06
Enkaz		0.72	0.73		0.76	0.71		0.68	0.65
Gölge	0.77	0.78	0.94	0.76	0.78	0.99	0.71	0.71	0.92
KırmızıÇatı		0.77	0.84		0.79	0.82		0.77	0.61
SiyahÇatı		0.73	0.73		0.82	0.82		0.73	0.67
YeşilAlan		0.86	0.67		0.94	0.69		0.80	0.62
Yol		0.77	0.79		0.62	0.83		0.72	0.94


Elde edilen doğruluk analizi sonuçları incelendiğinde bütün yöntemlerin başarılı sonuçlar verdiği gözlemlenmektedir. En yüksek genel doğruluğu %77 ile K-NN yöntemi sağlamakta, bunu SVM ve RF yöntemleri takip etmektedir. Çalışmanın amacı olan hasarlı binaların temsil edildiği enkaz sınıfı için elde edilmiş olan kullanıcı ve üretici doğruluk oranları da bu üç yöntem arasında dengeli bir dağılım göstererek, enkaz tespitinde tüm modellerin kabul edilebilir bir başarı sağladığını ortaya koymaktadır. Bu kullanıcı ve üretici doğrulukları incelendiğinde K-NN ve SVM' in benzer sonuçlar verdiği görülürken, RF yöntemiyle daha düşük sonuçlar elde edilmiştir.

Çadır sınıfına ilişkin sınıflandırma sonuçları, diğer sınıflara kıyasla daha düşük bir başarı oranı sergilemiştir. K-En Yakın Komşu (K-NN) ve Destek Vektör Makineleri (SVM) algoritmaları, bu sınıfta sırasıyla %60 kullanıcı doğruluğu oranıyla sınırlı bir performans göstermiştir. Rastgele Orman (Random Forest, RF) algoritması ise %40 kullanıcı doğruluğu oranıyla daha düşük bir başarı elde etmiştir. Bu düşük performansın temel nedeni, çadır sınıfının görüntüde az yer kaplaması ve buna bağlı olarak eğitim veri setinde bu sınıfa ait örneklerin yetersiz olması olarak değerlendirilmektedir.

Gölge sınıfında K-NN ve SVM'in kullanıcı doğruluk oranı %78 gibi oldukça yüksek bir değere ulaşmıştır. RF de bu sınıfta kullanıcı doğruluk oranları %71 değerleriyle dikkat çekicidir. Bu, gölge alanların tespitinde modellerin yüksek doğruluk sağladığını göstermektedir. Kırmızı çatı, siyah çatı, yeşil alan ve yol sınıflarında da

benzer şekilde yöntemler arasında performans farkları gözlemlenmiştir. Kırmızı çatıda SVM %78,7 ile en iyi kullanıcı doğruluk oranını sunarken, yeşil alanda K-NN %86 kullanıcı doğruluğuyla lider konumdadır.

Beton çatı sınıfında K-NN yöntemi kullanıcı doğruluk oranı %63 olarak kaydedilmiştir. SVM ile bu sınıf için kullanıcı doğruluk oranı %57,9'a gerilemiş, ancak RF ile bu oran %56,8 olarak elde edilmiştir. Beton çatı sınıfına çok benzeyen yol sınıfında bu oranlar ise bir miktar yükseldiği görülmektedir. Bu durumun, muhtemelen her iki sınıfın spektral yansımalarının benzerlik göstermesi ve kullanılan özelliklerin bu sınıfları yeterince ayırt edememesinden kaynaklanmaktadır. Söz konusu sonucun nedenlerini daha ayrıntılı bir şekilde anlamak ve sınıflandırma doğruluğunu artırmaya yönelik potansiyel çözümler geliştirmek amacıyla, yol ve beton çatı sınıflarına ait spektral özelliklerin detaylı bir analizi gerçekleştirilmiştir. Bu bağlamda, her iki sınıfın piksel bazlı yansıtıcılık değerlerini karşılaştırmak için histogramlar oluşturulmuştur (Şekil 5.9). Bu histogramlar, görünür ışık (kırmızı, yeşil, mavi) ve yakın kızılötesi bantlardaki spektral imzaların dağılımını görselleştirerek, sınıflar arasındaki örtüşme bölgelerini ve potansiyel ayırım noktalarını belirlemeyi amaçlamaktadır.



Şekil 5.9. Yol ve beton çatı alanlarına ait histogram grafikleri

Hazırlanan histogramlar ayrıntılı bir şekilde analiz edildiğinde, yol ve beton çatı alan sınıflarının benzer yoğunluk değerlerine sahip olduğu açıkça ortaya çıkmaktadır.

Bantlardaki piksel değerlerinin dağılımı, her iki sınıf arasında belirgin bir örtüşme göstermekte; bu durum, sınıflandırma algoritmalarının bu iki sınıfı etkili bir şekilde ayırt etme yeteneğini ciddi şekilde kısıtlamaktadır. Ayrıca, literatürde bulunan çalışmalar incelendiğinde kentsel alanların sınıflandırılmasında sıklıkla kullanılan SWIR, NIR ve Termal bantlarının kullanıldığı görülmektedir (Zhu vd., 2024).

Çalışma kapsamında kullanılan görüntünün yalnızca görünür bölge bantlarını (kırmızı, yeşil, mavi) içermesi ve kentsel alanlarda bulunan yapıların sınıflandırılmasında kullanılabilecek diğer bantların olmaması sınıflandırma başarısını düşürmektedir.

Çalışmanın bir sonraki aşamasında, ikinci çalışma alanına ait görüntü, daha önce belirlenen yöntemle sistematik bir şekilde analiz edilmiştir. Bu kapsamda, MRS yaklaşımı kullanılarak görüntü segmentasyon işlemi gerçekleştirilmiş, ardından elde edilen segmentler ilk olarak KNN algoritması ile sınıflandırmaya tabi tutulmuştur. Elde edilen sonuç haritası Şekil 5.10' da verilmiştir.



Şekil 5.10. Alan-2 'de KNN yöntemi ile elde edilen sonuç haritası

Görsel değerlendirme sonucunda, sonuç haritasının genel olarak etkili bir sınıflandırma başarımı sergilediği gözlemlenmiştir. Hasarlı bina alanlarının yanı sıra, diğer sınıfların ayırımında dikkate değer bir karışıklık yaşanmadığı belirlenirken, spektral yansımaları birbirine yakın olan yollar ile beton çatılı binaların da başarılı bir şekilde ayırt

edildiği tespit edilmiştir. Bunun yanında çalışma alanında bulunan içerisinde yeşil bitkilerin bulunduğu su alanı ile yeşil alanların bir ölçüde karıştığı tespit edilmiştir.

Çalışmanın sonraki aşamasında Alan-2'ye ait İHA görüntüsünün RF algoritması kullanılarak sınıflandırılmıştır. Elde edilen sonuç haritası Şekil 5.11'de sunulmuştur.



Şekil 5.11. Alan-2 'de RF yöntemi ile elde edilen sonuç haritası

Sınıflandırma işleminin tamamlanmasının ardından, öncelikle görsel bir analiz gerçekleştirilmiştir. Elde edilen sonuçlara göre, sonuç haritasının genel olarak yüksek bir sınıflandırma performansı sergilediği gözlemlenmiştir. KNN algoritmasına benzer şekilde, hasarlı bina alanları da dahil olmak üzere tüm sınıfların ayrıştırılmasında belirgin bir karışıklık olmadığı tespit edilmiştir. Spektral yansımaları birbirine yakın olan yollar ve beton çatılı binalar oldukça başarılı bir şekilde ayırt edilmiştir.


Son olarak görüntü RF algoritması ile sınıflandırılmıştır. Elde edilen sonuç haritası Şekil 5.12'de verilmiştir.



Şekil 5.12. Alan-2 'de SVM yöntemi ile elde edilen sonuç haritası

Sınıflandırma sonrasında gerçekleştirilen görsel inceleme sonuçlarına göre, SVM ile elde edilen sonuç haritasının genel olarak diğer yöntemlere kıyasla daha düşük bir sınıflandırma performansı sergilediği gözlemlenmiştir. Hasarlı bina alanlarının sınıflandırılmasında ciddi bir sorun yaşanmamakla birlikte, yollar ve beton çatılı binaların yeterince etkin bir şekilde tespit edilemediği gözlemlenmiştir.


Çalışmanın bir sonraki aşamasında, en yüksek kullanıcı doğruluğu ile belirlenen (KNN sonucu) enkaz alanları, HumData platformunda yer alan ve 2023 depreminde yıkılan binalara ilişkin verilerle karşılaştırılmıştır. Alan-2 için elde edilen sonuçlar Şekil 5.13'de verilmiştir.



Şekil 5.13. Alan-2 de belirlenen enkaz alanları ve Humdata karşılaştırılması

Elde edilen analiz sonuçları detaylı bir şekilde incelendiğinde, yıkılmış binaların bulunduğu bölgelerin tespitinde yüksek bir başarı oranı elde edildiği görülmektedir. Ancak, Alan-1 için gözlemlenen durumla paralellik gösterir şekilde, binaların oturma alanlarının çizgisel sınırlarının tam olarak belirlenemediği dikkat çekmektedir. Bunun yerine, deprem sonucunda oluşan moloz ve enkaz alanlarının tespitinde daha yüksek bir doğruluk sağlandığı görülmüştür. Bu durum, özellikle deprem sonrası hasar değerlendirme süreçlerinde hasarın mekânsal dağılımını ve yoğunlaştığı bölgeleri belirlemek açısından önemli bir katkı sunmaktadır. Enkaz alanlarının başarılı bir şekilde haritalanması, hasarın hangi bölgelerde daha fazla yoğunlaştığına dair kritik bilgiler sağlayarak, acil müdahale ekiplerinin önceliklerini belirlemesine ve kaynak tahsisini daha etkin bir şekilde planlamasına olanak tanıyacağı düşünülmektedir.

Yapılan analizleri derinleştirmek amacıyla Alan-2'de bulunan yıkılmış binaların ayak izleri Google Earth üzerinden sayısallaştırılmıştır. Elde edilen sonuçlar Şekil 5.14' de verilmiştir.



Şekil 5.14. Alan-2 de belirlenen enkaz alanları ve yıkılmış bina ayak izleri karşılaştırılması

Elde edilen sonuçlar incelendiğinde yıkılan bina ayak izlerinin sınıflandırma sonucunda belirlenen enkaz alanları ile örtüştüğü belirlenmiştir. Bununla birlikte, Alan-1'de olduğu gibi sınıflandırma sürecinde binaların gölgesinde kalan enkaz alanlarının gölge sınıfı olarak algılanması nedeniyle bu bölgelerde doğru bir enkaz sınıflandırması yapılamamıştır.

Alan-2'ye ait sınıflandırma performansını sayısal olarak değerlendirmek için oluşturulan hata matrisi kullanılarak OA, PA ve UA metrikleri hesaplanmıştır. Elde edilen doğruluk değerleri Tablo 5.2'de sunulmuş ve sınıflandırma sonuçlarının istatistiksel analizi bu verilere dayandırılmıştır.


Tablo 5.2. Alan-2'ye ait doğruluk analizi sonuçları

Yöntem	K-NN			SVM			RF		
Metrikler	OA	UA	PA	OA	UA	PA	OA	UA	PA
Araç		0.50	0.62		0.31	0.38		0.31	0.31
BetonÇatı		0.65	0.78		0.52	0.62		0.55	0.89
Çadır		0.78	0.54		0.44	0.21		0.67	0.11
Diğer		0.54	0.22		0.46	0.14		0.77	0.11
Enkaz	0.77	0.82	0.64	0.69	0.81	0.56	0.70	0.68	0.65
Gölge		0.89	0.92		0.85	0.93		0.85	0.91
KırmızıÇatı		0.82	0.84		0.91	0.77		0.72	0.83
SuAlanı		0.00	0.00		0.40	0.67		0.00	0.00
YeşilAlan		0.79	0.57		0.76	0.69		0.60	0.51
Yol		0.77	0.86		0.61	0.72		0.76	0.89

Elde edilen doğruluk analizi sonuçları incelendiğinde bütün yöntemlerin başarılı sonuçlar verdiği gözlemlenmektedir. En yüksek genel doğruluğu Alan-1 dekine benzer şekilde %77 ile K-NN yöntemi sağlamakta, bunu RF ve SVM yöntemleri takip etmektedir. Araç sınıfında K-NN yöntemi diğerlerine göre daha yüksek oranlarla kullanıcı doğruluğu %50 ve üretici doğruluğu %61,5 olarak sağlamışken, SVM ve RF ise kullanıcı ve üretici doğruluk oranların da %31,2-38,4 bandında kalarak bu sınıfın tüm yöntemler için zorlayıcı olduğunu göstermiştir. Beton çatı sınıfında KNN kullanıcı doğruluğu %65 ile oldukça yüksek bir başarı göstermiştir. Bunun yanında SVM'nin kullanıcı doğruluğu %52 olmasına rağmen RF'nin kullanıcı doğruluğu %55 olarak elde edilmiştir. Bu durum, RF'nin beton çatı sınıfını doğru bir şekilde tespit etme konusunda daha tutarlı olduğunu düşündürmektedir. Çadır sınıfında ise sonuçlar oldukça farklılık göstermektedir. K-NN kullanıcı doğruluğu %78 iken SVM'in kullanıcı doğruluğu %44 gibi düşük bir seviyede kalmıştır. RF ise %67 ile orta bir başarı elde etmiştir. Bu, çadır sınıfının özellikle SVM ve RF için ayırt edilmesi zor bir kategori olduğunu göstermektedir. Enkaz sınıfında K-NN ve SVM sırasıyla %82,4 ve %81,3 kullanıcı doğruluk oranlarıyla yüksek bir başarı elde etmiştir. RF ise %68,1 kullanıcı doğruluğu ile kabul edilebilir bir seviyede ölçülmüştür. Gölge sınıfında tüm yöntemler yüksek

performans göstermiştir. K-NN %89 kullanıcı doğruluğu ile en iyi sonucu verirken, SVM %85 kullanıcı doğruluğu ile yakın bir başarı sergilemiştir. RF de %85,1 kullanıcı doğruluğu ile bu sınıfta oldukça başarılı olmuştur. Bu sonuçlar, gölge alanlarının Alan-1' de olduğu gibi tüm yöntemler tarafından kolaylıkla tespit edildiğini göstermektedir. Kırmızı çatı sınıfında SVM %90,8 kullanıcı doğruluğu oranıyla lider konumdadır. K-NN %81,6 ve RF %72,4 kullanıcı doğruluk oranlarıyla bu sınıfta iyi sonuçlar almıştır. Yeşil Alan ve yol sınıflarında ise K-NN sırasıyla %79 ve %77 kullanıcı doğruluk oranlarıyla iyi bir performans sergilemiştir. SVM ve RF de bu sınıflarda dengeli sonuçlar vermişlerdir.


Su alanı sınıfına ilişkin sınıflandırma sonuçları, diğer sınıflara kıyasla dikkat çekici derecede düşük bir performans sergilemiştir. K-NN ve RF algoritmaları, su alanı sınıfında sıfır kullanıcı doğruluğu oranıyla tamamen başarısız olmuş, bu sınıftaki örneklerin doğru bir şekilde tanımlanmasında yetersiz kalmıştır. SVM algoritması ise %40 kullanıcı doğruluğu oranıyla sınırlı bir başarı elde etmiş, ancak bu oran da su alanlarının güvenilir bir şekilde sınıflandırılması için yeterli bulunmamıştır. Bu düşük performansın nedenlerini daha iyi anlamak ve sınıflandırma doğruluğunu artırmaya yönelik potansiyel iyileştirme yollarını belirlemek amacıyla, su alanı ve yeşil alan sınıflarına ait spektral özelliklerin detaylı bir analizi gerçekleştirilmiştir. Bu bağlamda, her iki sınıfın piksel bazlı spektral yansımalarını karşılaştırmak için histogramlar oluşturulmuştur (Şekil 5.15).



Şekil 5.15. Su ve yeşil alanlara ait histogram grafikleri

Hazırlanan histogramlar detaylı bir şekilde incelendiğinde, su ve yeşil alan sınıflarının benzer yoğunluk değerlerine sahip olduğu açıkça görülmektedir. Bantlardaki piksel değerlerinin dağılımı, her iki sınıf için belirgin bir örtüşme sergilemekte; bu durum, sınıflandırma algoritmalarının bu iki sınıfı etkin bir şekilde ayırt etme kapasitesini önemli ölçüde sınırlamaktadır. Bunun yanında, 3 bantlı (RGB) İHA görüntülerinin yalnızca görünür bölge bantlarını (kırmızı, yeşil, mavi) içermesi ve yakın kızılötesi (NIR) gibi bitki örtüsünü ve su yüzeylerini ayırt etmede daha etkili olan ek spektral bilgiyi sağlamamasıdır. Literatürde, RGB bantlarının sınırlı içeriği nedeniyle su ve bitki örtüsü gibi sınıfların ayrıştırılmasında benzer zorlukların yaşandığı rapor edilmiştir (Richards and Richards, 2022). Ek olarak, iki sınıfın ayrıştırılma başarısının düşük olmasının bir diğer nedeni, su sınıfının görüntüde çok küçük bir alanı kapsamaması nedeniyle bu sınıfa ait yeterli sayıda eğitim örneğinin toplanamamış olmasıdır. Eğitim verilerinin azlığı ve dengesiz dağılımı, makine öğrenimi algoritmalarının su sınıfını doğru bir şekilde öğrenmesini zorlaştırmış ve sınıflandırma performansını olumsuz etkilemiştir (Congalton and Green, 2019; Foody, 2002).

Çalışmada elde edilen sonuçlar incelendiğinde doğruluk analizi aşamasında işleminin doğasından kaynaklı problemlerle karşılaşıldığı görülmüştür. Örneğin bazı alanlarda yer alan karışık pikseller ya da hata matrisi oluşturmak için rastsal olarak atılan noktaların her iki sınıfı birden kapsamaması gibi nedenler doğruluğu etkilemiştir. Şekil 5.16'de bu durumu gösteren örnekler verilmiştir.



Şekil 5.16. Karşılaşılan problemler

Şekilde örneği görüldüğü üzere, kontrol noktasının bulunduğu bölgede iki farklı sınıfa ait piksellerin karıştığı Şekil 5.14-a gözlemlenmiştir. Bu durum, algoritmaların bu tür alanlarda sınıflandırma başarısını olumsuz etkilemektedir. Benzer bir şekilde Şekil 5.14-b'de incelendiğinde bazı bölgelerde ağaç gibi parçalı yapılara sahip nesnelerin gölgelerinin bulunduğu noktalarda sınıflandırma süreçlerinde zorluklar yaşandığı değerlendirilmektedir. Bu bulgular, karmaşık arazi özellikleri ve gölge etkilerinin otomatik sınıflandırma yöntemlerinin doğruluğunu sınırlandırdığını ortaya koymaktadır.

Sonuçlar genel olarak değerlendirilecek olursa, bu sonuçlar yöntemlerin sınıflara göre farklı başarılar gösterdiğini ortaya koymaktadır. K-NN ve SVM, gölge ve enkaz gibi sınıflarda yüksek performans gösterirken, araç ve su alanı gibi sınıflarda zorlanmıştır. RF ise yol ve kırmızı çatı gibi sınıflarda tutarlı sonuçlar vermiştir. Bu farklılıklar, veri özelliklerinin veya model parametrelerinin sınıflara göre optimize edilmesi gerektiğini göstermektedir. Özetle çalışma, makine öğrenimi yöntemlerinin deprem sonrası hasar tespiti için umut vadeden sonuçlar sunduğunu, özellikle enkaz alanlarının belirlenmesinde başarılı olduğunu göstermektedir. Ancak, bazı sınıflandırma zorluklarının ve veri sınırlamalarının olduğu da tespit edilmiştir.

6. SONUÇLAR VE ÖNERİLER

Türkiye, aktif fay hatları üzerinde yer alması nedeniyle yüksek deprem riski taşıyan bir ülkedir ve geçmişte birçok yıkıcı deprem yaşanmıştır. Depremler sonrası bina hasarlarının hızlı ve doğru bir şekilde tespiti büyük önem taşımaktadır. Geleneksel saha temelli yöntemler zaman alıcı ve iş gücü yoğun olduğundan, uzaktan algılama ve fotogrametri gibi teknolojilere dayalı yöntemler ön plana çıkmaktadır. Uydu ve İHA görüntülerinin kullanımıyla, geniş alanlardaki hasar tespiti hızlı ve maliyet etkin biçimde yapılabilmektedir. Bu görüntülerin analizinde, görüntü analiz tekniklerinin başarısı önemli rol oynamaktadır.

Bu tez çalışmasında, 2023 Kahramanmaraş depremleri sonrasında Hatay Antakya bölgesinde yüksek çözünürlüklü İHA görüntüleri kullanılarak hasarlı ve yıkılmış yapıların tespiti için nesne tabanlı görüntü analizi (OBIA) ve farklı makine öğrenimi (ML) yöntemleri (K-NN, RF ve SVM) uygulanmıştır. Segmentasyon parametrelerinin sistematik optimizasyonu ile elde edilen sonuçlar, deprem sonrası hasar tespitinde ML tabanlı yaklaşımların pratik faydasını ortaya koymuştur. Multi-resolution segmentation (MRS) yöntemiyle ölçek, şekil ve yoğunluk parametrelerinin çalışma alanlarına özgü olarak ayarlanması, nesne ayrımında önemli bir başarı sağlamıştır. Analizler, K-NN algoritmasının OA bakımından diğer yöntemlere kıyasla üstün performans sergilediğini (%77' ye varan oranlarla) göstermiştir. Özellikle enkaz sınıfında K-NN ve SVM' nin kullanıcı ve üretici doğruluk oranları (%82 ve %81 gibi yüksek değerler) dikkat çekicidir, ki bu da yıkılmış bina tespitinde bu yöntemlerin etkinliğini doğrular. RF ise yol ve kırmızı çatı gibi sınıflarda tutarlı sonuçlar sunarken, çadır ve su alanı gibi spesifik sınıflarda diğer yöntemlere göre daha az başarılı olmuştur.

Çalışmanın bulguları, İHA görüntülerinin yüksek çözünürlüklü verilerle desteklendiğinde, afet sonrası hızlı değerlendirme süreçlerinde güvenilir bir temel oluşturduğunu ortaya koymaktadır. Ancak, spektral yansımaları benzer olan sınıflar (örneğin, yol ve beton çatılı binalar) arasında karışıklıkların yanı sıra gölge etkileri ve karmaşık arazi özellikleri, sınıflandırma doğruluğunu sınırlayan temel faktörler olarak belirlenmiştir. Ayrıca, su alanı gibi düşük temsil edilen sınıflarda sıfır doğruluk oranları, veri setinin çeşitliliği ve örnekleme yoğunluğunun bu tür analizlerde kritik olduğunu göstermektedir. Google Earth programı üzerinden manuel olarak sayısallaştırılan yıkılmış bina ayak izleri ve HumData verisi ile karşılaştırılmıştır. Yapılan analizler sonucunda, ML yöntemlerinin enkaz alanlarını doğru bir şekilde tespit ettiği belirlenmiştir.

Bu sonuçlar ışığında, afet yönetimi ve hasar değerlendirme çalışmalarında ML tabanlı yaklaşımların potansiyelini artıracak bazı çözümler ortaya çıkmaktadır. Öncelikle, segmentasyon süreçlerinde daha gelişmiş optimizasyon teknikleri kullanılarak parametrelerin adaptif bir şekilde ayarlanması, farklı arazi ve hasar koşullarında doğruluğu artırılabilir. İkinci olarak, çoklu veri kaynaklarının (örneğin, LiDAR verileri, uydu görüntüleri ve termal sensörler) entegrasyonu, bina temel alanlarının ve yapısal detayların daha hassas bir şekilde haritalanmasını sağlayabilir. Üçüncüsü, veri setlerinin çeşitlendirilmesi ve az temsil edilen sınıflar (örneğin, su alanı veya çadır) için ek eğitim verileri toplanması, sınıflandırma performansını dengeli bir şekilde yükseltebilir.

Bu çalışma, deprem sonrası hasar tespitinde İHA görüntülerinin ve ML algoritmalarıyla analizinin etkinliğini kanıtlamış olup, gelecekteki araştırmalar için bir temel sunmaktadır. Önerilen iyileştirmelerin, afet yönetiminde operasyonel verimliliği artırarak kurtarma operasyonlarının etkinliğini ve afetlere hazırlık stratejilerini güçlendireceği düşünülmektedir.

KAYNAKÇA

- Abuoda, G., Hendrix, C., and Campo, S. (2021). Automatic Tag Recommendation for the UN Humanitarian Data Exchange. *BIRDS+ WEPIR Workshop @ CHIIR 2021*, 2863, s. 4-10.
- Aggarwal, S. (2004). Principles of remote sensing. R. R. Navalgund, V. Jayaraman, and P. S. Roy (Dü) içinde, *Satellite Remote Sensing and GIS Applications in Agricultural Meteorology* (s. 23-28). India: World Meteorological Organization(WMO).
- Baatz, M., and Schäpe, A. (2000). Multiresolution Segmentation: An Optimization Approach for High Quality Multi-Scale Image Segmentation. J. Strobl, T. Blaschke, and G. Griesebner (Dü) içinde, *Angewandte Geographische Informationsverarbeitung XII* (s. 12-23). Karlsruhe: Wichmann Verlag.
- Bai, Y., Adriano, B., Mas, E., Koshimura, S. (2017). Machine learning based building damage mapping from the ALOS-2/PALSAR-2 SAR imagery: Case study of 2016 Kumamoto earthquake. *Journal of Disaster Research*, 12, 646-655.
- Balasubramanian, A. (2017). *Digital elevation model (DEM) in GIS*. Mysuru: Centre for Advanced Studies in Earth Science.
- Bartels, S. A., and VanRooyen, M. J. (2012). Medical complications associated with earthquakes. *The Lancet*, 379(9817), 748-757.
- Bhandiya, A., and Pandey, K. (2024). *Assessing the effectiveness of ML algorithms in earthquake damage. Deep learning and visual artificial Intelligence: Proceedings of ICDLAI 2024*. Bikaner: Springer.
- Bialas, J., Oommen, T., Rebbapragada, U., Levin, E. (2016). Object-based classification of earthquake damage from high-resolution optical imagery using machine learning. *Journal of Applied Remote Sensing*, 10(3), 036025.
- Bitelli, G., Camassi, R., Gusella, L., Mognol, A. (2004). Image change detection on urban area: The earthquake case. *International Archives Of The Photogrammetry, Remote Sensing And Spatial Information Sciences*(35), 692-697.

- Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5–32.
- Buda, M., Maki, A., and Mazurowski, M. A. (2018). A systematic study of the class imbalance problem in convolutional neural networks. *Neural Networks*, 106, 249-259.
- Campbell, J. B., and Wynne, R. H. (2011). *Introduction to remote sensing*. New York: Guilford Press.
- Campos-Taberner, M. (2017). Development of an earth observation processing chain for crop biophysical parameters at local and global scale. *Revista de Teledetección*(50), 101-104.
- Canözü, Ö. (2022). Deprem Sonrasında İnsansız Hava Araçları ile Temin Edilen Görüntülerden Üretilen 3B Nokta Bulutu ve Mevcut Kadastral Haritalar ile Hasarlı Binaların Otomatik Tespiti. Trabzon: Ulusal Tez Merkezi.
- Coady, J., O'Riordan, A., Dooly, G., Newe, T., Toal, D. (2019). An overview of popular digital image processing filtering operations. *13th International Conference on Sensing Technology(ICST)*, (s. 1-5). <https://ieeexplore.ieee.org/abstract/document/9047683> (Erişim Tarihi: 24.04.2025).
- Congalton, R. G., and Green, K. (2019). *Assessing the accuracy of remotely sensed data: Principles and Practices*. Florida: CRC Press.
- Cooner, A. J., Shao, Y., and Campbell, J. B. (2016). Detection of urban damage using remote sensing and machine learning algorithms: Revisiting the 2010 Haiti earthquake. *Remote Sensing*, 8(10), 868.
- Çömert, R., Matcı, D. K., ve Avdan, U. (2017). Yıkılmış binaların nesne tabanlı sınıflandırma ile insansız hava aracı verilerinden tespit edilmesi. *4.Uluslararası Deprem Mühendisliği ve Sismoloji Konferansı*. Eskişehir: Eskişehir Teknik Üniversitesi.
- Çömert, R., Matcı, D., and Avdan, U. (2018). Detection of collapsed building from unmanned aerial vehicle data with object based image classification.

Eskişehir Teknik Üniversitesi Bilim ve Teknoloji Dergisi B-Teorik Bilimler, 6, 109-116.

Dinç, Y. (2015). Antakya (Hatay) Şehir Coğrafyası. *Sosyal bilimler enstitüsü*. Yüksek Lisans Tezi Hatay.

Erdogan, M., and Yilmaz, A. (2019). Detection of building damage caused by Van earthquake using image and digital surface model (DSM) difference. *International Journal of Remote Sensing*, 40(10), 3772-3786.

Ertel, W. (2024). *Introduction to artificial intelligence*. Wiesbaden: Springer Nature.

Féret, J. B., and Asner, G. P. (2014). Mapping tropical forest canopy diversity using high-fidelity imaging spectroscopy. *Ecological Applications*, 24(6), 1289-1296.

Fix, E. (1985). *Discriminatory analysis: nonparametric discrimination, consistency properties*. Texas: USAF School of Aviation Medicine.

Foody, G. M. (2002). Status of Land Cover Classification Accuracy Assessment. *Remote Sensing of Environment*, 80(1), 185–201.

Foody, G. M. (2020). Explaining the unsuitability of the kappa coefficient in the assessment and comparison of the accuracy of thematic maps obtained by image classification. *Remote Sensing of Environment*, 239.

Gonzalez, R. C. (2009). *Digital image processing*. Delhi: Pearson Education India.

Gorte, B. (1999). Supervised image classification. *Spatial Statistics for Remote Sensing* (s. 153–163). içinde Dordrecht: Springer Netherlands.

Grunthal, G. (1998). *European macroseismic scale 1998 (EMS-98)*. Lüksemburg: Centre Européen de Géodynamique et de Séismologie.

Hancock, G. R., and Willgoose, G. R. (2001). The production of digital elevation models for experimental model landscapes. *Earth Surface Processes and Landforms*, 26(5), 475–490.

Hunt, E. B. (2014). *Artificial intelligence*. Academic Press.

Jähne, B. (2005). *Digital image processing* (6. b.). Berlin: Springer-Verlag.

- Janalipour, M., and Mohammadzadeh, A. (2015). Building damage detection using object-based image analysis and ANFIS from high-resolution image (Case Study: BAM Earthquake, Iran). *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 9(5), 1937-1945.
- Jensen, J. R. (2009). *Remote sensing of the environment: An earth resource perspective (2nd Edition)*. Delhi: Pearson Education India.
- Jia, J., and Ye, W. (2023). Deep learning for earthquake disaster assessment: Objects, Data, Models, Stages, Challenges, and Opportunities. *Remote Sensing*, 15(16), 4098.
- Jing, Y., Ren, Y., Liu, Y., Wang, D., Yu, L. (2022). Automatic extraction of damaged houses by earthquake based on improved YOLOv5: A case study in Yangbi. *Remote Sensing*, 14(2), 382.
- Joshi, P. P., and Bagade, A. M. (2023). Explainable artificial intelligence techniques for image classification models in diverse domains. *2023 7th International Conference on Computing, Communication, Control and Automation (ICCUBEA)* (s. 1-7). IEEE. <https://ieeexplore.ieee.org/abstract/document/10392188> (Erişim Tarihi: 29.04.2025).
- Kaya, Ö. (2024). Comparative analysis of multiple machine learning algorithms for post-earthquake building damage assessment in Hatay city following the 2023 earthquake. Ankara: Middle East Technical University (Turkey) ProQuest Dissertations & Theses.
- Kersten, J., Hadidian, N. M., Hwirang, K., Karagianni, A., Kazmi, Y., Manojlovski, F. (2017). Object-based analysis of satellite images for building change detection after an earthquake: The case study of L'Aquila. L. Abrahamczyk, and J. Schwarz (Dü) içinde, *From past desing to future decision 2017* (s. 20). Weimar: Bauhaus-Universität Weimar, Faculty of Civil and Environmental Engineering, Institute of Structural Engineering (IKI).

- Khanzode, K., and Sarode, R. D. (2020). Advantages and disadvantages of artificial intelligence and machine learning: A literature review. *International Journal of Library & Information Science (IJLIS)*, 9(1), 30-36.
- Kim, B. G., Shim, J. I., and Park, D. J. (2003). Fast image segmentation based on multi-resolution analysis and wavelets. *Pattern Recognition Letters*, 24(16), 2995-3006.
- Korkmaz, K. A., and Abualkibash, M. (2018). Earthquake damage detection using before and after earthquake satellite images. 2018 IEEE International Conference on Electro/Information Technology (EIT)' de sunulan bildiri. <https://ieeexplore.ieee.org/abstract/document/8500225> (Erişim Tarihi: 20.04.2025).
- Kuzey, C. (2012). Veri madenciliğinde destek vektör makinaları ve karar ağaçları yöntemlerini kullanarak bilgi çalışanlarının kurum performansı üzerine etkisinin ölçülmesi ve bir uygulama. *Yayımlanmamış Doktora Tezi*. İstanbul: İstanbul Üniversitesi, Sosyal Bilimler Enstitüsü.
- Laghari, A. A., Jumani, A. K., Laghari, R. A., Nawaz, H. (2023). Unmanned aerial vehicles: A review. *Cognitive Robotics*, 3, 8–22.
- Lary, D. J., Alavi, A. H., Gandomi, A. H., Walker, A. L. (2016). Machine learning in geosciences and remote sensing. *Geoscience Frontiers*, 7(1), 3-10.
- Li, M., Zang, S., Zhang, B., Li, S., Wu, C. (2014). A review of remote sensing image classification techniques: The role of spatio-contextual information. *European Journal of Remote Sensing*, 47(1), 389–411.
- Lillesand, T. M., and Kiefer, R. W. (1981). *Remote sensing and image interpretation*. New Jersey: John Wiley and Sons, Ltd.
- Lillesand, T. M., Kiefer, R. W., and Chipman, J. W. (2015). *Remote sensing and image interpretation* (7 b.). New Jersey: John Wiley and Sons.
- Liu, P. (2015). A survey of remote-sensing big data. *Frontiers in Environmental Science*, 3, 45.

- MacLean, M. G., and Congalton, R. G. (2012). Map accuracy assessment issues when using an object-oriented approach. *Proceedings of the American Society for Photogrammetry and Remote Sensing (ASPRS) 2012 Annual Conference*, (s. 19–23).
- Mangalathu, S., Sun, H., Nweke, C. C., Yi, Z., Burton, H. V. (2020). Classifying earthquake damage to buildings using machine learning. *Earthquake Spectra*, 36(1), 183-208.
- Manickavasagan, A., and Jayasuriya, H. (2014). *Imaging with electromagnetic spectrum*. Muscat: Springer.
- Matin, S. S., and Pradhana, B. (2022). Challenges and limitations of earthquake-induced building damage mapping techniques using remote sensing images- A systematic review. *Geocarto International*, 37(21), 6186-6212.
- Mitchell, T. M. (1997). *Machine learning*. New York: McGraw-Hill.
- Naito, S., Tomozawa, H., Mori, Y., Nagata, T., Monma, N., Nakamura, H., Shoji, G. (2020). Building-Damage detection method based on machine learning utilizing aerial photographs of the Kumamoto earthquake. *Earthquake Spectra*, 36(3), 1166-1187.
- Norgard, J., and Best, G. L. (2017). The electromagnetic spectrum. A. J. Graham (Dü.) içinde, *National Association of Broadcasters Engineering Handbook* (s. 3-10). New York: Routledge.
- Olaode, A., Naghdy, G., and Todd, C. (2014). Unsupervised classification of images: A Review. *International Journal of Image Processing (IJIP)*, 8(5), 325–342.
- Omarzadeh, D., Karimzadeh, S., Matsuoka, M., Feizizadeh, B. (2021). Earthquake aftermath from very high-resolution WorldView-2 image and semi-automated object-based image analysis (Case Study: Kermanshah, Sarpol-e Zahab, Iran). *Remote Sensing*, 13(21), 4272.
- Over, J. R., Ritchie, A. C., Kranenburg, C. J., Brown, J. A., Buscombe, D., Noble, T., Wernette, P. A. (2021). *Processing coastal imagery with agisoft*

metashape professional edition, version 1.6—structure from motion workflow documentation. Virginia: U.S. Geological Survey.

Özşahin, E. (2010). Antakya'da Hatay yer seçiminin jeomorfolojik özellikler ve doğal risk açısından değerlendirilmesi. *Balıkesir Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 13(23), 1-16.

Pandey, A., and Jain, A. (2017). Comparative analysis of KNN algorithm using various normalization techniques. *International Journal of Computer Network and Information Security (IJCNIS)*, 10(11), 36-42.

Patel, N., and Kaushal, B. K. (2010). Improvement of user's accuracy through classification of principal component images and stacked temporal images. *Geo-Spatial Information Science*, 13, 243–248.

Prasad, L., Bruce, L. M., Chanussot, J., Prasad, S. (2011). *Optical remote sensing*. Berlin: Springer.

Reichstein, M., Camps-Valls, G., Stevens, B., Jung, M., Denzler, J., Carvalhais, N., Prabhat, F. (2019). Deep learning and process understanding for data-driven earth system science. *Nature*, 566(7743), 195–204.

Richards, J. A. (2005). Analysis of remotely sensed data: The formative decades and the future. *IEEE Transactions on Geoscience and Remote Sensing*, 43(3), 422 - 432.

Richards, J. A., and Richards, J. A. (2022). *Remote sensing digital image analysis* (6 b., Cilt 5). Berlin: Springer Cham.

Sabuncu, A., ve Sunar, F. (2017). Ortofotolar ile nesne tabanlı görüntü sınıflandırma uygulaması: Van-Erciş depremi örneği. *Doğal Afetler ve Çevre Dergisi*, 3(1), 1-8.

Soleimani-Babakamali, M. H., Askari, M., Heravi, M. A., Sisman, R., Attarchian, N., Askan, A., Taciroglu, E. (2025). Deep ensemble learning for rapid large-scale postearthquake damage assessment: Application to satellite images from the 2023 Türkiye earthquakes. *Asce Open:Multidisciplinary Journal of Civil Engineering*, 3(1), 04025003.

- Sugimori, H. (2019). Evaluating the overall accuracy of additional learning and automatic classification system for CT images. *Applied Sciences*, 9(4), 682.
- Sunar, F. (2019). *Dijital görüntü işleme*. Eskişehir: Anadolu Üniversitesi.
- Szeliski, R. (2022). *Computer vision: Algorithms and applications*. Cham: Springer Nature.
- Takhtkeshha, N., Mohammadzadeh, A., and Salehi, B. (2022). A rapid self-supervised deep-learning-based method for post-earthquake damage detection using UAV data (Case Study: Sarpol-e Zahab, Iran). *Remote Sensing*, 15(1), 123.
- Tong, X., Hong, Z., Liu, S., Zhang, X., Xie, H., Li, Z., Bao, F. (2012). Building-damage detection using pre- and post-seismic high-resolution satellite stereo imagery: A case study of the May 2008 Wenchuan earthquake. *ISPRS Journal of Photogrammetry and Remote Sensing*, 68, 13-27.
- Toth, C., and Joźkow, G. (2016). Remote sensing platforms and Sensors: A Survey. *ISPRS Journal of Photogrammetry and Remote Sensing*, 115, 22-36.
- Turker, M., and Cetinkaya, B. (2005). Automatic detection of earthquake-damaged buildings using DEMs created from pre- and post-earthquake stereo aerial photographs. *International Journal of Remote Sensing*, 26(4), 823-832.
- Tyagi, V. (2018). *Understanding Digital Image Processing*. Florida: CRC Press.
- Wang, C., Qiu, X., Huan, H., Wang, S., Zhang, Y., Chen, X. H., He, W. (2021). Earthquake-Damaged buildings detection in very high-resolution remote sensing images based on object context and boundary enhanced loss. *Remote Sensing*, 13(16), 3119.
- Wang, S., Xu, W., and Guo, T. (2024). Advances in thermal infrared remote sensing technology for geothermal resource detection. *Remote Sensing*, 16(10), 1690.
- Witharana, C., and Civco, D. L. (2014). Optimizing multi-resolution segmentation scale using empirical methods: Exploring the sensitivity of the supervised

discrepancy measure euclidean distance 2 (ED2). *ISPRS Journal of Photogrammetry and Remote Sensing*, 87, 108-121.

Wolf, P. R., and Dewitt, B. A. (2000). *Elements of photogrammetry: With Applications in GIS*. Boston: McGraw-Hill Higher Education.

Xiang, T. Z., Xia, G. S., and Zhang, L. (2019). Mini-UAV-based remote sensing: Techniques, applications and perspectives. *IEEE Geoscience and Remote Sensing Magazine*, 7(3), 29-63. <https://arxiv.org>. adresinden alındı

Yahia, M. E., and Ibrahim, B. A. (2003). K-Nearest Neighbor and C4.5 algorithms as data mining methods: Advantages and difficulties. *IEEE International Conference on Computer Systems and Applications (AICCSA)*, 103–109.

Yu, Y., Wang, C., Fu, Q., Kou, R., Huang, F., Yang, B., Gao, M. (2023). Techniques and challenges of image segmentation: A Review. *Electronics*, 12(5), 1199.

Yuheng, S., and Hao, Y. (2017). Image segmentation algorithms overview. arXiv preprint.

Zhang, B., Wu, Y., Zhao, B., Chanussot, J., Hong, D., Yao, J., Gao, L. (2022). Progress and challenges in intelligent remote sensing satellite systems. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 15, 1814 - 1822.

Zheng, J., Song, X., Yang, G., Du, X., Mei, X., Yang, X. (2022). Remote sensing monitoring of rice and wheat canopy nitrogen: A Review. *Remote Sensing*, 14(22), 5712.

Zhu, W., Yuan, C., Tian, Y., Wang, Y., Li, L., Hu, C. (2024). A new high-resolution rural built-up land extraction method based on artificial surface index with short-wave infrared downscaling. *Remote Sensing*, 16(7), 1126.

http-1:<https://www.afad.gov.tr/deprem-nedir> (Erişim Tarihi: 03.05.2025).

http-2:<https://www.atlasus.com.tr/otus/>(Erişim Tarihi: 09.05.2025).

http-3:<https://www.sony.com.tr/electronics/support/e-mount-body-ilce-6000-series/ilce-6000/specifications>(Erişim Tarihi: 11.05.2025).

ÖZGEÇMİŞ

ORCID NO: 0009-0006-8672-4844

Ad Soyad : Faruk ÖZARSLAN

Yabancı Dil : İngilizce

Eğitim ve Mesleki Geçmişi:

- 2020, Anadolu Üniversitesi/İktisat Fakültesi
- 2013, Harita Genel Müdürlüğü

