

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

**DEPREM SONRASINDA BİNALARIN HASAR TESPİTİNDE KULLANILAN
YAPAY ÖĞRENME ALGORİTMALARININ ANALİZİ**

YÜKSEK LİSANS TEZİ

Serhat Mürsel KÖROĞLU

Bilişim Uygulamaları Anabilim Dalı

Coğrafi Bilgi Teknolojileri Programı

ŞUBAT 2025

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

**DEPREM SONRASINDA BİNALARIN HASAR TESPİTİNDE KULLANILAN
YAPAY ÖĞRENME ALGORİTMALARININ ANALİZİ**

YÜKSEK LİSANS TEZİ

**Serhat Mürsel KÖROĞLU
(706211027)**

Bilişim Uygulamaları Anabilim Dalı

Coğrafi Bilgi Teknolojileri Programı

Tez Danışmanı: Doç. Dr. Caner GÜNEY

ŞUBAT 2025

ISTANBUL TECHNICAL UNIVERSITY ★ GRADUATE SCHOOL

**ANALYSIS OF MACHINE LEARNING ALGORITHMS USED IN POST-
EARTHQUAKE BUILDING DAMAGE ASSESSMENT**

MASTER THESIS

**Serhat Mürsel KÖROĞLU
(706211027)**

Applied Informatics Department

Geographical Information Technologies Program

Thesis Advisor: Assoc. Prof. Dr. Caner GÜNEY

ŞUBAT 2025

İTÜ, Lisansüstü Eğitim Enstitüsü'nün 706211027 numaralı Yüksek Lisans Öğrencisi Serhat Mürsel KÖROĞLU, ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı “DEPREM SONRASINDA BİNALARIN HASAR TESPİTİNDE KULLANILAN YAPAY ÖĞRENME ALGORİTMALARININ ANALİZİ” başlıklı tezini aşağıda imzaları olan jüri önünde başarı ile sunmuştur.

Tez Danışmanı : **Doç. Dr. Caner GÜNEY**
İstanbul Teknik Üniversitesi

Jüri Üyeleri : **Doç. Dr. Caner GÜNEY**
İstanbul Teknik Üniversitesi

Prof. Dr. Filiz BEKTAŞ BALÇIK
İstanbul Teknik Üniversitesi

Doç. Dr. Alper ŞEN
Yıldız Teknik Üniversitesi

Teslim Tarihi : 14 Ocak 2025
Savunma Tarihi : 18 Şubat 2025



ÖNSÖZ

Bu yüksek lisans tezinin hazırlanması sırasında her zaman yönlendirme ve destekleriyle tezin oluşturulması sürecinde büyük katkıları olan danışman hocam Sayın Doç. Dr. Caner GÜNEY'e teşekkür ederim.

Yüksek lisans öğrenimim sürecinde desteklerini esirgemeyen bölüm hocalarıma ve iş arkadaşlarıma, her zaman yanımda olan aileme teşekkürlerimi sunarım.

Şubat 2025

Serhat Mürsel KÖROĞLU



İÇİNDEKİLER

Sayfa

ÖNSÖZ	v
İÇİNDEKİLER	vii
KISALTMALAR	xiii
ÇİZELGE LİSTESİ.....	xv
ŞEKİL LİSTESİ.....	xvii
ÖZET	xxi
SUMMARY	xxiii
1. GİRİŞ	1
1.1 Tezin Amacı	3
1.2 Literatür Araştırması	4
2. YAPAY ÖĞRENME	9
2.1 Makine Öğrenmesi Algoritmaları	10
2.1.1 Doğrusal regresyon	10
2.1.2 Lojistik regresyon	12
2.1.3 Destek vektör makineleri	13
2.1.4 Karar ağaçları	14
2.1.5 Rastgele ormanlar	15
2.1.6 K- en yakın komşu	15
2.1.7 Naive bayes	16
2.1.8 Yapay sinir ağları	17
2.2 Derin Öğrenme	18
2.2.1 Derin öğrenme türleri	19
2.2.1.1 Convolutional neural network (CNN).....	19
2.2.1.2 Recurrent neural network (RNN) (yinelemeli sinir ağı)	20
2.2.1.3 Distributed representation (dağıtık temsil).....	20
2.2.1.4 Autoencoders (oto kodlayıcılar).....	20
2.2.2 Derin öğrenme adımları	21
2.2.3 Eğitim adımları ile ilgili terimler	21
2.2.3.1 Yitim (hata) (loss)	22
2.2.3.2 Optimizatör (optimizers).....	22
2.2.3.3 Öğrenme oranı.....	22
2.3 Makine Öğrenmesi Model Değerlendirmesi	23
2.4 Makine Öğrenmesi Yöntemlerinde Veri Setleri.....	25
2.5 Makine Öğrenmesi Algoritmalarında Özellik Çıkarımı.....	27
2.6 Makine Öğrenmesi Model Eğitiminde Kullanılan Bilgi Sistemleri.....	28
3. İNCELENEN YAYINLAR	31
3.1 Yayın 1: Gerçek Zamanlı Derin Öğrenme Modeli ile Hasar Tespiti	34
3.1.1 Amaç	34
3.1.2 Kullanılan algoritmalar	34
3.1.3 Yöntemler.....	34

3.1.4 Sonuçlar.....	36
3.2 Yayın 2: Derin Öğrenme ile Bina Hasar Değerlendirmesi.....	37
3.2.1 Amaç	37
3.2.2 Kullanılan algoritmalar	37
3.2.3 Yöntemler.....	37
3.2.4 Sonuçlar.....	39
3.3 Yayın 3: SAR Verisi ve Makine Öğrenmesi Kullanılarak Hasar Tespiti.....	41
3.3.1 Amaç	41
3.3.2 Kullanılan algoritmalar	41
3.3.3 Yöntemler.....	41
3.3.4 Sonuçlar.....	41
3.4 Yayın 4: Uydu Görüntüleri ve Derin Öğrenme ile Hasar Tespiti	42
3.4.1 Amaç	42
3.4.2 Kullanılan algoritmalar	43
3.4.3 Yöntemler.....	43
3.4.4 Sonuçlar.....	44
3.5 Yayın 5: Denetimli Öğrenme Kullanılarak Hasarlı Bina Tespiti	45
3.5.1 Amaç	45
3.5.2 Kullanılan algoritmalar	45
3.5.3 Yöntemler.....	45
3.5.4 Sonuçlar.....	46
3.6 Yayın 6: xBD Veri Seti ile Uydu Görüntülerinden Hasarlı Bina Tespiti.....	46
3.6.1 Amaç	46
3.6.2 Kullanılan Algoritmalar	47
3.6.3 Yöntemler.....	47
3.6.4 Sonuçlar.....	47
3.7 Yayın 7: Derin Öğrenme Tabanlı Bina Tespit ve Sınıflandırma.....	48
3.7.1 Amaç	48
3.7.2 Kullanılan algoritmalar	48
3.7.3 Yöntemler.....	48
3.7.4 Sonuçlar.....	49
3.8 Yayın 8: Hava Fotoğrafları ve Makine Öğrenmesi ile Bina Hasar Tespiti	50
3.8.1 Amaç	50
3.8.2 Kullanılan algoritmalar	50
3.8.3 Yöntemler.....	50
3.8.4 Sonuçlar.....	51
3.9 Yayın 9: Derin Öğrenme Tabanlı Semantik Segmentasyon Modelleri.....	52
3.9.1 Amaç	52
3.9.2 Kullanılan algoritmalar	52
3.9.3 Yöntemler.....	52
3.9.4 Sonuçlar.....	53
3.10 Yayın 10: Random Forest Sınıflandırıcısı ile Hasarlı Bina Tespiti.....	54
3.10.1 Amaç	54
3.10.2 Kullanılan algoritmalar	54
3.10.3 Yöntemler.....	54
3.10.4 Sonuçlar.....	54
3.11 Yayın 11: Derin Öğrenme Algoritması ile Deprem Sonrası Hasar Tespiti....	55
3.11.1 Amaç	55
3.11.2 Kullanılan algoritmalar	56
3.11.3 Yöntemler.....	56

3.11.4 Sonuçlar	57
3.12 Yayın 12: UNet-GCViT: Transformer Tabanlı Hasar Tespit Yöntemi	57
3.12.1 Amaç	57
3.12.2 Kullanılan yöntemler.....	57
3.12.3 Kullanılan algoritmalar	58
3.12.4 Sonuçlar	58
3.13 Yayın 13: SAR Görüntüleri Kullanarak Bina Hasar Tespiti Çalışması	61
3.13.1 Amaç	61
3.13.2 Yöntemler.....	61
3.13.3 Deneyler ve sonuçlar.....	62
3.13.4 Sonuç.....	62
3.14 Yayın 14: Afet Öncesi ve Sonrası Ortofoto Kullanarak Hasar Tespiti	62
3.14.1 Amaç	62
3.14.2 Yöntemler.....	62
3.14.3 Sonuçlar	65
3.15 Yayın 15: YOLOv8 ile Afet Sonrası Görüntülerden Hasar Tespiti	66
3.15.1 Amaç	66
3.15.2 Yöntemler.....	66
3.15.3 Sonuçlar	66
3.16 Yayın 16: Çoklu Özellik Kullanımı ve Derin Öğrenme ile Hasar Tespiti	69
3.16.1 Amaç	69
3.16.2 Yöntemler.....	69
3.16.3 Sonuçlar	70
3.17 Yayın 18: BDDNet+: Coat-Net Tabanlı Hasar Tespit Çatısı.....	71
3.17.1 Amaç	71
3.17.2 Yöntemler.....	71
3.17.3 Sonuçlar	73
3.18 Yayın 18: İHA Verisi ve Denetimli Derin Öğrenme ile Hasar Tespiti.....	74
3.18.1 Amaç	74
3.18.2 Kullanılan yöntemler.....	74
3.18.2.1 Özellik çıkarımı.....	74
3.18.2.2 Otomatik eğitim örneklerinin seçilmesi:	74
3.18.2.3 Makine öğrenmesi ve derin öğrenme algoritmaları ile sınıflandırma:	74
3.18.3 Sonuçlar	75
3.19 Yayın 19: Optik ve Radar Veri Kullanılarak Hasar Tespiti	77
3.19.1 Amaç	77
3.19.2 Yöntemler.....	77
3.19.3 Sonuçlar	77
3.20 Yayın 20: InCR: Derin Öğrenme Hasar Tespit Uygulaması.....	79
3.20.1 Amaç	79
3.20.2 Yöntemler.....	79
3.20.3 Sonuçlar	80
3.21 Yayın 21: GAN Mimarisi Kullanılarak Bina Hasar Tespit Uygulaması	81
3.21.1 Amaç	81
3.21.2 Yöntemler.....	82
3.21.3 Sonuçlar	83
3.22 Yayın 22: Hasar Tespitinde Derin Öğrenme Modellerinin Gelişimi	83
3.22.1 Amaç	83
3.22.2 Yöntemler ve algoritmalar	83

3.22.3 Sonuçlar.....	84
3.23 Yayın 23: Dinamik ve Sabit Filtreli Derin Öğrenme Modeli Kullanımı.....	85
3.23.1 Amaç	85
3.23.2 Yöntemler.....	86
3.23.3 Sonuç.....	88
3.24 Yayın 24: Çeşitli Afet Türleri için Ortak Derin Öğrenme Modeli	88
3.24.1 Amaç	88
3.24.2 Yöntemler.....	89
3.24.3 Sonuçlar.....	89
3.25 Yayın 25: RGB Uydu Verisinden U-Net Modeli ile Hasar Tespiti.....	90
3.25.1 Amaç	90
3.25.2 Yöntemler.....	91
3.25.3 Sonuçlar.....	91
3.26 Yayın 26: Çeşitli Afet Türleri için Derin Öğrenme Model Önerisi	92
3.26.1 Amaç	92
3.26.2 Yöntemler ve Kullanılan Algoritmalar	92
3.26.3 Sonuçlar.....	93
3.27 Yayın 27: Hasar Tespitinde Kullanılan Çeşitli Derin Öğrenme Modellerinin İncelemesi.....	94
3.27.1 Amaç	94
3.27.2 Yöntemler.....	95
3.27.3 Sonuçlar.....	95
3.28 Yayın 28: Hasar Tespiti için Sınırlı Denetimli Derin Öğrenme Modeli	96
3.28.1 Amaç	96
3.28.2 Yöntemler.....	96
3.28.3 Sonuçlar.....	97
3.29 Yayın 29: Yerden Alınan Görüntüler ve YOLOv5 ile Hasar Tespiti.....	98
3.29.1 Amaç	98
3.29.2 Yöntemler.....	98
3.29.3 Sonuçlar.....	99
3.30 Yayın 30: Çoklu Özellik Kullanımı ile Hasar Tespiti	100
3.30.1 Amaç	100
3.30.2 Kullanılan yöntemler.....	100
3.30.3 Sonuçlar.....	101
3.31 Yayın 31: Derin Öğrenme ve Superpiksel Düzeyinde Değişim Tespiti ile Hasar Tespiti.....	102
3.31.1 Amaç	102
3.31.2 Kullanılan yöntemler.....	103
3.31.3 Sonuçlar.....	104
3.32 Yayın 32: Denetimsiz Derin Öğrenme Yöntemiyle Hasar Tespiti.....	106
3.32.1 Amaç	106
3.32.2 Yöntemler.....	106
3.32.3 Sonuçlar.....	107
3.33 Yayın 33: Afet Bölgesinde Dron Rota Planlamasında Hasar Tespiti Algoritmalarından Faydalanılması	107
3.33.1 Amaç	107
3.33.2 Yöntemler.....	108
3.33.3 Sonuçlar.....	109
3.34 Yayın 34: Afet Sonrası İHA Görüntüleriyle Hızlı Hasar Tespiti	110
3.34.1 Amaç	110

3.34.2 Kullanılan yöntemler.....	111
3.34.3 Sonuçlar	112
3.35 Yayın 35: U-Net Kullanılarak Afet Öncesi ve Sonrası Verilerle Hasar Tespiti	113
3.35.1 Amaç	113
3.35.2 Kullanılan yöntemler.....	113
3.35.3 Sonuçlar	114
4. DEĞERLENDİRMELER	117
4.1 Çalışmaların Değerlendirilmesi.....	117
4.2 Türkiye İçin Öneriler.....	120
5. SONUÇLAR	127
KAYNAKLAR	131
EKLER	137
ÖZGEÇMİŞ.....	145





KISALTMALAR

CNN	: Convolutional Neural Network
CPU	: Central Process Unit
FPN	: Feature Pyramid Network
GIS	: Geographic Information Systems
GPU	: Graphics Processing Unit
IoU	: Intersection over Union
İHA	: İnsansız Hava Aracı
MSE	: Mean Squared Error
mAP	: Mean Average Precision
NLP	: Neural Language Processing
PAN	: Pyramid Attention Networks
PSPNet	: Pyramid Scene Parsing Network
RAM	: Random Access Memory
RGB	: Red Green Blue
RNN	: Recurrent Neural Network
SAR	: Synthetic Aperture Radar
SVM	: Support Vector Machines
TPU	: Tensor Processing Unit
UAV	: Unmanned Aerial Vehicles
VGG	: Visual Geometry Group
YOLO	: You Only Look Once



ÇİZELGE LİSTESİ

Sayfa

Çizelge 3.1 : Yayınlar aıt arařtırma kategorileri ve oranları.....	31
Çizelge 3.2 : DB-YOLOv5 modelinin ve diğeri YOLO versiyonlarının performans kıyaslaması.....	37
Çizelge 3.3 : BDANet modeli kesinlik (precision) ve hassasiyet (recall) oranlarının diğeri derin öğrenme modellerine ait sonuçlarla kıyaslaması.....	40
Çizelge 4.1 : İncelenen yayınlarda kullanılan yapay öğrenme yöntemlerinin hesaplanmış ve sunulmuş performans metrikleri.....	125



ŞEKİL LİSTESİ

Sayfa

Şekil 2.1 : Yapay sinir ağı katmanları.	18
Şekil 2.2 : Makine öğrenmesi algoritma türleri.	19
Şekil 2.3 : Makine öğrenmesi model değerlendirme matrisi.	23
Şekil 2.4 : Makine öğrenmesi algoritmalarında veri seti kullanımı (Bangert, 2021).	25
Şekil 2.5 : Veri zenginleştirme / çoğaltma yöntemleri.	27
Şekil 3.1 : Tarama sonucu bulunan yayınların kategorilere göre dağılım grafiği.	32
Şekil 3.2 : Tarama sonucu bulunan yayınların yıllara göre dağılımı.	32
Şekil 3.3 : Çalışmaların yayınlandığı alanları gösteren VOSviewer co-occurrence analizi şeması.	33
Şekil 3.4 : YOLOv5 mimarisi.	34
Şekil 3.5 : Değiştirilmiş DB-YOLOv5 mimarisi.	35
Şekil 3.6 : Yöntemin uygulama performansı. (a: Afet öncesi, b: Afet sonrası, c: ground truth, d: yöntemin tespit ettikleri (kırmızılar doğru tespit edilenler))....	36
Şekil 3.7 : BDANet hasarlı bina tespit sonuç görseli.	39
Şekil 3.8 : İki aşamalı BDANet derin öğrenme modeli mimarisi.	40
Şekil 3.9 : Modelin Zagreb depremi sonrası 3 boyutlu hasarlı bina sınıflandırma haritası.	42
Şekil 3.10 : Önceden eğitilmiş ResNet-34 mimarisi ile bina hasar tespit modeli.	44
Şekil 3.11 : ResNet-34 yöntemin hasar sınıflandırma performansı: Yeşil renk hasarsız yapıları, sarı renk hasarlı yapıları gösteriyor.	45
Şekil 3.12 : Unet + vgg16 bn kombinasyonunda bina maskeleme performansı görseli (sırasıyla uydu, tahmin edilen ve doğrulanmış).	48
Şekil 3.13 : ECADS-CNN yöntemi hasar tespit performansının diğer yöntemlerle kıyaslaması.	49
Şekil 3.14 : Gerçekte belirlenen hasarlı yapılar.	51
Şekil 3.15 : CNN yöntemiyle yapılan hasar tespiti.	52
Şekil 3.16 : U-net, LinkNet, FPN ve PSPNet yöntemleriyle yapılmış hasar tespitleri ve IoU değerleri.	53
Şekil 3.17 : Random forest ile hasar sınıflandırması performansı.	55
Şekil 3.18 : GCViT ground truth (doğrulanmış veri) bina maske görseli.	59
Şekil 3.19 : GCViT yönteminin hasarlı bina tahmin maskeleme performansı.	59
Şekil 3.20 : Unet-GCViT mimarisi.	60
Şekil 3.21 : SAR yansıma yayılım özellikleri analizi.	61
Şekil 3.22 : DDFormer ve diğer yöntemlerin iki farklı SAR görüntüsünden performans kıyaslaması.	63
Şekil 3.23 : 3 farklı yöntemle CNN ağına kullanım şemaları. (a) composite model, (b) twin model, and (c) fusion model.	64
Şekil 3.24 : Hasar sınıflandırma sonuçları: (a,g,m) afet öncesi, (b,h,n) afet sonrası, (c,i,o) gerçek değerler (GT), (d,j,p) birleşik model, (e,k,q) ikiz model, ve (f,l,r) birleşim modelidir.	65
Şekil 3.25 : Önerilen yöntem (a) performansının gerçek verilerle (b) karşılaştırılması; c ve d üstte sarı işaretli yerler.	67

Şekil 3.26 : Efficient ViTB ve YOLOv8 ile geliştirilen bina hasar tespit modelinin akış şeması.....	68
Şekil 3.27 : ResNet -18 kullanılarak geliştirilen özellik çıkarım stratejileri şeması..	70
Şekil 3.28 : Gerçek durum ve uygulamanın hasar tespiti performans karşılaştırması.	71
Şekil 3.29 : BDDNet+ algoritma mimarisi şeması.	72
Şekil 3.30 : Önerilen BDD-Net+ ve Coat-Net yöntemlerinin gerçek durumla kıyaslaması.	73
Şekil 3.31 : Tespit stratejilerine göre yöntemlerin maskeleye performansları kıyaslaması.	76
Şekil 3.32 : Uygulanan yöntem kombinasyonlarının doğruluk karşılaştırılması....	78
Şekil 3.33 : Gerçek durum ve farklı sınıflandırma yöntemlerinin tahmin karşılaştırması (a) CNN (piksel tabanlı), (b) CNN + SVM (piksel tabanlı), (c) CNN + FIS (piksel tabanlı), (d) CNN (nesne tabanlı), (e) CNN + SVM (nesne tabanlı), (f) CNN + FIS (nesne tabanlı).	78
Şekil 3.34 : Farklı boyutlu inception katmanlarının kullanıldığı InCR derin öğrenme modeli.....	80
Şekil 3.35 : Modelin açıklanabilirliği grad cam heat map yöntemiyle gösterilmiştir.	81
Şekil 3.36 : Geliştirilen SkipGAN mimarisi.	82
Şekil 3.37 : SwinTransformer model eğitim süreci şeması.	84
Şekil 3.38 : SwinTransformer yöntemin afet öncesi ve sonrası veriler kullanılarak elde edilmiş başarı performansları karşılaştırması.	85
Şekil 3.39 : Bina hasar sınıflandırılması için önerilen derin öğrenme modeli yönteme ait akış şeması.	87
Şekil 3.40 : Önerilen derin öğrenme modeli yöntemin diğer algoritmalara göre performans kıyaslaması.	88
Şekil 3.41 : ResNet-50 temelli modelin tespit performansı.	90
Şekil 3.42 : Uydu verisinden işaretlenen ve U-net modeli ile tahmin edilen hasarlı yapılar. Kırmızı çarpı ile işaretliler yanlış tahmin edilenler. (Kırmızı kutu içindekiler yıkılmış, mavi kutu olanlar sağlam binaları gösteriyor.)	92
Şekil 3.43 : BDD-Net modeli şeması.	93
Şekil 3.44 : Yöntemin afet öncesi ve sonrası görüntülerin kullanımına göre hasar tespit performansı.	94
Şekil 3.45 : Önerilen zayıf denetimli - weakly supervised model.	97
Şekil 3.46 : Yöntemin hasar tespit performansı.	98
Şekil 3.47 : LA-YOLOv5 yönteminin hasar tespit performansı.....	100
Şekil 3.48 : Çoklu özellik füzyonuna dayanan modelin, yalnızca İHA görüntüsü kullanarak ve uydu - İHA görüntülerinin bir arada kullanılmasıyla yapılan performans karşılaştırılması.	102
Şekil 3.49 : CECNN modeli kullanılarak uygulanan bina hasar tespit adımları şeması.	103
Şekil 3.50 : PreSC stratejisi kullanılarak yapılan performans testi ve diğer yöntemlerle karşılaştırılması.	105
Şekil 3.51 : USADA modeli şeması.	106
Şekil 3.52 : YOLOv5s kullanılan yöntem adımları şeması.	108
Şekil 3.53 : EFBS veri seti kullanılarak yapılan test.	110
Şekil 3.54 : Naive Bayes kullanılarak geliştirilen yöntemin işlem adımları.	111
Şekil 3.55 : Yöntem kullanılarak yapılan hasar tespit uygulaması: U: Undamaged ve D: Damaged.....	112

Şekil 3.56 : Önerilen U-Net tabanlı yöntemin aşamaları.....	113
Şekil 3.57 : Doğruluk performansını arttıran model füzyonu yöntemi ile elde edilen test sonuçları. (a: Kasırga verisi ground truth, b,c: attention mekanizmasını içeren ve içermeyen sonuçlar).....	115
Şekil 4.1 : Afet sonrası bina hasar tespiti için yapay öğrenme işlemleri akış şeması.	124





DEPREM SONRASINDA BİNALARIN HASAR TESPİTİNDE KULLANILAN YAPAY ÖĞRENME ALGORİTMALARININ ANALİZİ

ÖZET

Afet durumlarında özellikle deprem sonrasında bir kentte hangi binaların hasar aldığıın tespit edilebilmesi ve bu binaların hasar düzeylerinin belirlenebilmesi hem afet anında gerçekleştirilen arama kurtarma çalışmaları için hem de afet sonrasında kent yaşamının yeniden başlayabilmesi için hayati öneme sahip bir bilgidir. Özellikle şiddetli bir depremin gerçekleşmesinden sonraki kısa zaman içerisinde bu bilginin üretilebilmesi, afet alanındaki kaotik durum göz önünde bulundurulduğunda arama-kurtarma ve planlama çalışmaları için ne kadar hayati bir öneme sahip olduğu anlaşılabilecektir. Ayrıca söz konusu bilginin afet sırasında afet bölgesinde bulunan kurum ve kuruluşların yanı sıra afetzedeler tarafından üretilmesi pek olası olmadığı gibi gerçekçi de değildir. Bu durumda afetten görece daha az etkilenen bölgelerdeki uzmanlar ve kaynaklar yardımıyla havadan ve uzaydan elde edilen görüntüler kullanılarak hasar tespit çalışmaları yapılmaktadır. Bu çalışmalarda özellikle afet alanına ulaşımı sağlayan yollar ve köprüler ile afet alanındaki binaların afet sonrası durumları belirlenmeye ve afet sonrası bölgenin mevcut durumunun haritası üretilmeye çalışılmaktadır. Bu bilgiler üretildikten sonra da duruma ile ilişkin diğer tüm bilgilerle birlikte bir Uzamsal Bilgi Sistemi (Mekânsal Bilgi Sistemi/Coğrafi Bilgi Sistemi) uygulaması üzerinden arama-kurtarma, yardım ve lojistik çalışmaları planlanmakta ve gerçekleştirilmektedir.

Uçak, insansız hava aracı, uydu gibi platformlarda bulunan farklı sensörlerden elde edilen görüntüler üzerinde binaların hasar tespitleri geleneksel olarak insanlar tarafından manuel biçimde vektör veri yapısında veya yine insan tarafından görüntü işleme yazılımlarıyla raster veri yapısında gerçekleştirilmektedir. Sözü edilen her iki geleneksel yaklaşımın gerçekleştirilmesi belirli bir zaman almaktadır. Afet anında her geçen zamanın hayati olduğu göz önünde bulundurulduğunda bu sürecin hızlandırılması gerekmektedir. Burada devreye daha yenilikçi bir yöntem olan yapay öğrenme yaklaşımı devreye girmektedir. Bu yenilikçi yaklaşımda makine öğrenmesi, onun bir alt kümesi olan derin öğrenme yöntemleri ve onun da bir alt kümesi olan transformer mimarileri sözü edilen görüntüler üzerinde hasar tespiti için kullanılabilmektedir.

Her ne kadar söz konusu yenilikçi yöntemler geleneksel yöntemlere göre afet alanındaki hasar tespit hızını arttırsa da farklı mimarilere ve hiper parametrelere sahip farklı yapay öğrenme yöntemleri, doğruluk, kesinlik, duyarlılık gibi ölçütler üzerinden farklı başarımlar sergilemektedir. Yapay öğrenme modellerinin başarımlarının farklı olması deprem sonrasındaki arama-kurtarma ve yardım faaliyetlerinin başarımını da etkileyebileceği öngörülmelidir. Örneğin başarımlı düşük bir yapay öğrenme modelinin hasarsız veya az hasarlı binayı ağır hasarlı olarak sınıflandırması ya da tam tersi durumda arama-kurtarma faaliyetleri yanlış binalara yönlendirilerek zaman ve can kaybına neden olunabilir. Bu ve benzeri durumların ortaya çıkmaması için bugüne

kadar depremlerde hasar tespiti için kullanılan yapay öğrenme yaklaşımlarının karşılaştırılmalı bir analizinin yapılması gerekliliği ortaya çıkmaktadır.

Bu nedenle çalışma kapsamında deprem sonrası hasar tespiti için uydulardan ve insansız hava araçlarından elde edilen görüntülerin girdi verisi olarak kullanıldığı ve yapay öğrenme yönteminin uygulandığı 35 akademik çalışma incelenmiştir. Söz konusu 35 makalede kullanılan yapay öğrenme algoritmalarının, algoritmaların kullanım stratejilerinin ve algoritmalarının başarımlarının bir karşılaştırmalı analizi yapılmıştır. Sözü edilen modellerin eğitimi sırasında uygulanan tahmin başarımlarını artırıcı yöntemler ve ayarlamalar da irdelenmiştir.

Ayrıca çalışmalarda eğitim ve test verisi olarak kullanılan veri kümeleri de analiz kapsamında incelenmiştir. Örneğin bazı çalışmalar doğrudan hava veya uydu platformlarından elde edilen görüntüleri doğrudan kullanırken diğer çalışmalar eğitim verisi olarak önceden hazırlanmış hasarlı binalar eğitim veri kümelerini de kullanmıştır. Buna ek olarak çalışma kapsamında eğitim verisi kümesinin hazırlanmasındaki veri zenginleştirme/çoğaltma amacıyla uygulanan işlemler de göz önünde bulundurulmuştur.

Çalışma sonucunda 35 makaleye ilişkin yapılan karşılaştırmalı analize dayalı olarak bundan sonra gerçekleşebilecek olası depremlerde hasar tespitine ilişkin nasıl bir yapay öğrenme altyapısı, mimarisi ve modeli kullanılabileceğine ilişkin kavramsal bir tasarım yapılmıştır. Bu tasarımla bina segmentasyonu ve hasar sınıflandırma süreçlerinde yaşanan sorunlara çözüm sunulmaya çalışılmıştır.

ANALYSIS OF MACHINE LEARNING ALGORITHMS USED IN POST-EARTHQUAKE BUILDING DAMAGE ASSESSMENT

SUMMARY

After a disaster, especially after an earthquake, information about the location and damage level of buildings is a crucial data source for both search and rescue efforts during the disaster and the subsequent redesign of the city. Considering the chaotic conditions in the affected area immediately after the event, such information resources are vital for planning rescue and relief operations. It is highly unlikely that this information could be produced by people on the ground during the earthquake. Therefore, following an earthquake, damage assessments for objects like buildings, roads, and bridges are conducted using satellite and photogrammetric imagery acquired from the air, enabling the production of thematic maps that depict the current situation. Subsequently, this information can be integrated with other datasets in “Geospatial Information Systems” (Geographical Information Systems, GIS) to carry out search and rescue and relief planning efforts.

In addition to conducting damage assessments on aerial and satellite images through manual human labor and/or image processing software, artificial learning (machine learning, deep learning, artificial intelligence) approaches can be employed to accelerate the work.

Within the scope of this study, several academic research projects employing artificial learning approaches on high-resolution optical satellite imagery and optical imagery obtained from unmanned aerial vehicles (UAVs) were examined to determine the effects of the earthquake on urban areas. The methods applied in these studies were compared. This comparison generally covers the artificial learning algorithms used, the methods of applying these algorithms, and the performance metrics of these algorithms. Performance measures such as accuracy, precision, recall, F1 score, and Intersection over Union (IoU) were utilized.

In the studies compared in this work, some used only post-earthquake images as a dataset, while others used both pre- and post-earthquake images. During the training phase, some studies employed the xBD dataset, which contains both damaged and undamaged building data, while others used building and collapsed building images from the ImageNet dataset. The xBD dataset is a publicly available, large-scale satellite image dataset for building segmentation and damage assessment. It provides pairs of high-resolution global images of buildings before and after disasters, along with their annotations. Each image is $1,024 \times 1,024$ pixels in size, containing three RGB bands at 0.8 m resolution. ImageNet, on the other hand, is a massive visual dataset widely used in computer vision and deep learning domains, created in 2009. It is commonly employed as training data for classifying and recognizing various objects and includes millions of labeled images. ImageNet is especially popular for training deep learning models for object recognition, image classification, and image processing projects.

Moreover, some studies generated their own training datasets by extracting image patches from satellite imagery—either post-disaster or pre-disaster—that did or did not contain buildings. Since many neural networks expect input data of similar dimensions, images were, for example, prepared at 128x128 pixel sizes to create training sets. These images were produced for each of the RGB channels as well.

In order to enhance the learning capability of machine learning algorithms and prevent overfitting (i.e., excessive adaptation to the training data), raster-type datasets obtained from satellite imagery were subjected to various formatting operations for data diversification and enrichment. When the dataset is insufficient, these operations also aim to prevent the model from becoming biased toward the training data. For data augmentation and diversification, transformations like cropping, rotating, and blurring were applied to the satellite images. In a study titled “A Deep Learning Application for Building Damage Assessment Using Ultra-High-Resolution Remote Sensing Imagery in Turkey Earthquake,” conducted after the Kahramanmaraş earthquakes of February 6, 2023, the Cutmix technique was used for dataset diversification. Cutmix involves combining two different images by cutting a portion of one image and pasting it onto another.

Parts of the satellite images containing damaged buildings were resized for use in machine learning models. This resizing step was applied to adjust the satellite images to be suitable for the training process. The images were standardized to a fixed resolution (e.g., 512x512 pixels) to allow consistent processing by the models. This step is critical for ensuring uniform handling of images with different resolutions and is also important as a data preprocessing step to improve model performance. Afterward, the dataset was generally randomly divided into about 70% training and 30% testing. In some studies, an additional 10% was allocated for validation.

In machine learning algorithms, training data is used to optimize model parameters to uncover relationships and patterns within the data. These parameters are considered the weight values in artificial neural networks. The validation data, on the other hand, is used for “fine-tuning” these parameters during the learning process. It measures how successful the model is on data it hasn’t seen before. It also checks if the model is overfitting—performing poorly on unseen data. Finally, the test data is used after the model is trained and validated to evaluate how the model performs on a completely unseen dataset.

The studies also address problems that can occur when using artificial learning methods and propose solutions. For example, issues like a high number of misclassified areas or the transferability of tested models to different types of disasters were examined. Various methods were discussed for detecting objects like buildings or other structures at different altitudes or scales.

The studies also mention various feature extraction methods to improve detection performance in segmentation and damage classification tasks. For instance, by analyzing building edges, corners, changes in pixel spectral reflectance values, and various vegetation indices, feature maps were generated for training the models.

Different artificial learning models are used in the compared studies. However, it was observed that U-Net-based models generally perform well. Moreover, the choice of encoder accompanying the model significantly impacts performance. For example, in the study titled “Using Satellite Imagery to Automate Building Damage Assessment: A Case Study of the xBD dataset,” the VGG16 bn (VGG16 with Batch Normalization) encoder, a variant of the VGG16 deep learning model proposed by Oxford University’s

Visual Geometry Group in 2014, achieved the best building segmentation performance when used with the U-Net deep learning model.

In the comparison conducted within this study, it was observed that deep learning algorithms were more successful in building segmentation tasks. High segmentation performance levels were identified.

In studies with similar accuracy values, those with lower recall or F1 scores were found to have been trained with smaller datasets.

It was also determined that hyperparameter adjustments, such as the number of training epochs and the batch size used in each epoch, as well as optimization approaches, play a role in improving model performance. Normalization, which involves bringing various data into a standard range, was also applied as part of data preprocessing to improve model performance. For example, in the article titled “Earthquake building damage detection based on synthetic-aperture-radar imagery and machine learning,” data normalization was implemented to balance parameters used in damage classification. By scaling different measured data—such as SAR (synthetic aperture radar) reflectance values—into a standard range, the classification model aims to yield more accurate and balanced results.

With this study, by comparing the performances of artificial learning techniques that contribute to rapid intervention planning in the detection of building debris following earthquakes, an attempt was made to determine how the most efficient and fastest evaluation system should be. In particular, taking regional factors into account, a solution proposal was presented to address the challenges encountered in this field, specifically within the context of Türkiye.



1. GİRİŞ

Büyük bir deprem sonrası hasar alan binaların hangileri olduğunun ve yıkılan binaların nerede olduğunun tespit edilmesi ve binaların hasar düzeylerinin belirlenmesi afet bölgesindeki çalışmaların planlanmasında ve hızlı eyleme geçmede büyük öneme sahiptir. Depremi şiddetine bağlı olarak afet bölgesindeki hasarlı binaların saha çalışmalarıyla teker teker tespiti önemli bir insan gücü kullanımını gerektirmektedir. Buna ek olarak deprem sonrası hasar alan yollar ve köprüler nedeniyle ulaşımın olası olmadığı afet alanlarında da bu tür saha çalışmaları mümkün olmayabilir. Bu nedenle afet sonrasında havadan ve/veya uzaydan elde edilen uzaktan algılama veri kümeleri kullanılarak hızlı bir şekilde hasar tespiti yapılabilir. Hasar gören binaların yerlerinin ve hasar düzeylerinin belirlenmesinden sonra Uzamsal Bilgi Sistemi (Mekânsal Bilgi Sistemi/Coğrafi Bilgi Sistemi) uygulamaları kullanılarak arama-kurtarma ve yardım faaliyetleri hızlıca planlanabilir. Bu uygulamalarda kentin üst yapısına ilişkin veri kümeleri, kentin altyapısına ilişkin doğalgaz, elektrik, su, kanalizasyon gibi şebeke verileri ile bütünleştirilip patlama, yangın, su baskını gibi olası diğer olayların etki analizi yapılabilir. Bununla birlikte afet sonrasındaki sigorta süreçleri için afet anındaki hasar tespit bilgileri kullanılabilir.

Havadan elde edilen fotogrametrik görüntüler ile uzaydan elde edilen uydu ve radar görüntüleri kullanılarak hasarlı binaların yerleri tespit edilebilir (Rao vd., 2023). Afet bölgesinin afet öncesi ve sonrası durumuna ilişkin görüntüler kullanılarak görüntüdeki değişimlerin analizi ile hasar tespiti yapılabilir. Yalnız afet sonrası uydu görüntülerinden çıkarılan özellikler kullanılarak da hasar düzeyine ilişkin tahmin işlemi yapılabilmektedir (Naito vd., 2020).

Depremi etki alanının geniş olması durumunda hasarlı binaların belirlenmesi işinin görüntüler üzerinden insan gözüyle manuel olarak yapılması yerine, yapay öğrenme algoritmaları kullanılarak daha hızlı ve etkin biçimde gerçekleştirilmesi düşünülebilir. Yapay öğrenmenin bilgisayarlı görü alanında gelişen teknikler kullanılarak, havadan ve uzaydan elde edilen görüntüler üzerinde hasar tespiti ve hasar düzeyinin belirlenmesi işleri gerçekleştirilebilmektedir. Böylece deprem anında afetle

mücadelenin hızlı ve etkin biçimde yapılabilmesi için önemli bir bilgi kaynağı ortaya çıkarılmış olacaktır.

Diri fay hatlarının yoğun olarak bulunduğu Anadolu’da yıllar içerisinde sürekli olarak farklı büyüklüklerde depremle meydana gelmektedir. Türkiye’de yaşanan büyük depremlerden sonra afet anında genelde örgütlenme temelli sorunlar gözlenmektedir. Afet bölgesinde yaşayan ilgili personelin de afetzedede olması nedeniyle afet anında afet bölgesindeki çalışmalara dışarıdan görevli personel getirilmektedir. Dışarıdan gelen görevliler bölgeyi tanımadıkları için arama-kurtarma, planlama ve lojistik çalışmalara katkı verebilmeleri sınırlı düzeyde olabilmektedir. Bu durumda afet bölgesinde kentin üst yapısının durumuna ilişkin hızlı bilgi elde edilmesi mümkün olmamaktadır.

Afet anında afet bölgesinde karşılaşılabilen bir diğer sorun da yardım dağıtımının etkin biçimde planlanıp gerçekleştirilememesidir. Yardım dağıtımının planlamasındaki en önemli konu nerede, ne tür, ne kadar yardıma gereksinim olduğu bilgisinin üretilebilmesidir. Hemen arkasından da bu bilgiye dayalı olarak belirlenen yardımın ilgisine zamanında ulaştırılabilmesidir. Afet bölgesinin nerelerinde ne kadar binanın yıkıldığı veya hasar aldığı bilgisi, o bölgeye ne tür yardımların ne miktarda ulaştırılması gerektiği bilgisinin üretimiyle doğrudan ilişkilidir. Aynı zamanda yıkılan binaların enkazlarının bölgeye ulaşım yollarını kapayıp kapamadığı da üzerinde durulması gereken bir diğer konudur. Bununla birlikte yardım için kullanılması gereken yolların bina enkazı dışında başka bir nedenle kapalı olması durumunda bu bilginin de hızlıca üretilip afet haritasına ve bilgi sistemine eklenmesi gerekmektedir. Diğer bir konu da kurtarma ve yardım çalışmalarının yapılabilmesi için binaların hasar derecelerine göre sınıflandırılmasıdır. Böylece kurtarma ekipleri doğru ekipman ile yardım bölgelerine yönlendirilebilir.

Bunların dışında yine havadan ve uzaydan elde edebilecek görüntüler kullanılarak çözüm geliştirilebilecek ilgili diğer sorunlar aşağıda maddeler halinde verilmiştir:

- Afet anında içinde çadır kentlerinin kurulacağı yerlerin belirlenmesi
- Aşevi, sağlık merkezi, morg gibi hizmetlerin verileceği yerlerin belirlenmesi
- Kent içi dışında afet bölgesinde yer alan ancak kırsal alanda bulunan binaların durumunun tespit edilmesi
- Mezarlık alan yerlerinin belirlenmesi

Deprem ve benzeri afetler sonrası yaşanabilecek sorunların temelinde yer alan birlikte çalışma, eş güdüm sağlama ve örgütlenme sorunsalı hızlı bilgi üretimi ve etkin planlama yaklaşımı ile önlenebilir. Bu noktada Kent Bilgi Sistemi, Altyapı Bilgi Sistemleri, Bina Bilgi Sistemi, Mezarlık Bilgi Sistemi gibi uzamsal bilgi sistemi uygulamaları yararlanılabilecek önemli araçlar arasındadır. Kentlerin afet öncesinde sahip olduğu uzamsal bilgi sistemi uygulamalarındaki veri kümeleri ile afet sonrası üretilen uzamsal veri kümeleri bütünleştirildiğinde afetle mücadelede etkin bir araç elde edilmiş olacaktır.

1.1 Tezin Amacı

Deprem sonrası hızlı müdahale için etkin bir planlamaya ve bu tür planlama için de hızlı üretilmiş doğru bilgiye gereksinim bulunmaktadır. Buradan hareketle tez çalışmasının amacı; afet alanında acil müdahale için yapılacak planlamada kullanılmak üzere binaların ve yolların durumunu, havadan ve uzaydan elde edilen görüntülerden yapay öğrenme yöntemleri kullanarak belirlenmesine ilişkin etkin bir yol haritasının oluşturması biçiminde belirlenmiştir.

Tez kapsamında oluşturulan araştırma soruları aşağıda belirtilmiştir:

1. Uçak, insansız hava aracı ve uydu platformlarından elde edilen görüntülerden yapay öğrenme yöntemleriyle yapılan bina segmentasyonun deprem bölgelerindeki başarımı yeterli midir?
2. Uçak, insansız hava aracı ve uydu platformlarından elde edilen görüntülerden yapay öğrenme yöntemleriyle yapılan hasar sınıflandırmasının başarımı yeterli midir?
3. Çalışma kapsamında yararlanılan 35 akademik çalışmada kullanılan yapay öğrenme yaklaşımları, yapay öğrenme modelleri deprem bölgesinde afetle mücadeleye yönelik yukarıda belirtilen amaçları karşılamakta mıdır?
4. Çalışma kapsamında yararlanılan 35 akademik çalışmada kullanılan yapay öğrenme yaklaşımlarının, yapay öğrenme modellerinin karşılaştırmalı analizlerine dayalı olarak Türkiye'deki olası depremler için bir yapay öğrenme altyapısı oluşturulabilir mi?

1.2 Literatür Araştırması

Bu tezin hazırlanmasında literatür çalışması kapsamında uzaktan algılama verileri kullanılarak bilgisayar sistemleri yardımı ve makine öğrenmesi yöntemleriyle deprem sonrası meydana gelen bina yıkıntılarının yerlerinin tespiti ve hasar değerlendirmesi işlemlerini içeren akademik çalışmalar incelenmiştir.

Y. Wang vd., (2023) çalışmalarında, uydu görüntülerinden bina yıkıntı tespiti için YOLO derin öğrenme modeli tabanlı yeni bir model geliştirerek, İHA üzerinde düşük güç tüketimine sahip işlemci gücünde gerçek zamanlı olarak çalışacak şekilde yeni modeli optimize etmişlerdir. Çalışmada YOLO'nun 5. versiyonunda yer alan odak modülü çıkartılarak modelin gömülü cihazlarda çalışabilecek verimliliğe erişmesi sağlanmıştır. Xia vd., (2023) çalışmalarında, 6 Şubat 2023 Kahramanmaraş depremlerine ait yüksek çözünürlüklü WorldView uydu görüntüleri ile test edilen BDANet isimli derin öğrenme modeli geliştirmişlerdir. İki aşamalı olan derin öğrenme modeli xBD metre altı bina veri seti kullanılarak eğitilmiştir. Modelin ilk aşaması U-net tabanlı bir yapıdadır ve bu aşamada bina yerlerinin tespiti üzerine çalışılmıştır ve model eğitilmiştir. İkinci aşamada ise Çok Ölçekli Özellik Birleştirme Modülü dahil edilmiş ve çeşitli boyutlardaki binaların özelliklerinin tespiti için modelin verimliliği arttırılmıştır. Rao vd., (2023) çalışmalarında, uzaktan algılama verisinden bina hasar tespiti için makine öğrenmesi algoritmaları ve SAR (Syntetic Apreture Radar) verisinden faydalanmışlardır. 4 farklı büyük çaplı deprem sonrasında bina hasar tespiti yapılmak üzere Random Forest ve Support Vector Machines (SVM) algoritmaları değerlendirilmiştir. Geliştirilen makine öğrenmesi modeli SAR verisi, deprem şiddet haritaları ve bina envanter verilerini kullanarak binaların hasarlı-hasarsız ve farklı seviyelerde hasar sınıflandırması yapılmasını sağlamıştır. Abdi vd., (2021) çalışmalarında afet sonrası yüksek çözünürlüklü uydu görüntüsünden derin öğrenme algoritması yardımıyla bina hasar tespiti yapmışlardır. Önceden ImageNet bina hasar veri seti ile eğitilmiş ResNet34 modeli ince ayar (fine-tune) işlemine tabi tutularak farklı afet türlerinde hasar tespiti amacıyla test edilmiştir. Aswitha vd., (2024) çalışmalarında uydu görüntüsü üzerinde denetimli öğrenme öğrenme algoritmaları kullanılarak bina hasar tespiti konusunu ele almışlardır. Denetimli makine öğrenmesi algoritmalarından doğrusal regresyon ve K En Yakın Komşu algoritmaları ayrı ayrı kullanılarak kıyaslama yapılmış ve K-En Yakın Komşu hasar derecesi belirlemede daha iyi verim sağlamıştır. Makine öğrenmesi algoritmaları ve xBD veri seti

kullanılarak yapılan bir diğer çalışmada Chen, (2021) bina yeri ve hasar tespiti işlemleri için farklı derin öğrenme algoritmalarını kıyaslamıştır. U-net, FPN (Feature Pyramid Networks), PAN (Pyramid Attention Networks), ResNet18 modelleri VGG16 bn, ResNet50, SE ResNeXt50 32x4d ve DenseNet121 gibi kodlayıcılar kullanılarak test edilmiştir. Burada da U-net ve VGG16_bn kodlayıcısı bir arada kullanıldığında bina segmentasyonunda en iyi veriminin alındığı görülmüştür. Zhao vd., (2024) çalışmalarında, kodlayıcı ve çözücü özelliklerine sahip U-net mimarisini kullanan bir derin öğrenme algoritması geliştirmiştir. Bina segmentasyonu ve hasar tespiti amacıyla geliştirilen model, xBD veri setinin bir kısmı kullanılarak eğitilmiştir. Siamese yapay sinir ağı kullanılarak afet öncesi ve sonrası uydu görüntüleri arasındaki farklar tespit edilerek hasar sınıflandırması yapılmış. Naito vd., (2020) çalışmalarında Kumamoto depreminde elde edilen hava fotoğraflarından bina hasar tespiti ve derecelendirmesi yapmıştır. Bu çalışmada Bag-of –Visual-Words makine öğrenmesi modeli ile VGG tabanlı bir derin öğrenme modeli karşılaştırılmıştır. Derin öğrenme yöntemi hız ve doğruluk anlamında daha iyi verim sağlamıştır. Hacıefendioğlu vd., (2024) 6 Şubat 2023 Kahramanmaraş depremleri sonrası elde edilen uydu görüntüleri kullanılarak yapılan çalışmada, derin öğrenme tabanlı 4 farklı model kullanmışlardır. U-Net, LinkNet, FPN, PSPNet modellerinin kullanıldığı çalışmada FPN en yüksek doğruluğu, U-net en iyi duyarlılık (recall) oranını sağlamıştır. Bu çalışma kullanılan modelle beraber seçilen kodlayıcının modelin verimine katkı sağladığını göstermiştir. Virtriana vd., (2023) çalışmalarında uydu görüntüleri kullanarak random forest makine öğrenmesi algoritması ve geometrik, doku, istatistik, bitki örtüsü indisi parametreleri ile tahmin senaryoları oluşturmuşlardır. 14 farklı tahmin senaryo kombinasyonu denenerek en iyi hasar tespitinin hangisiyle sağlandığı tespit edilmeye çalışılmıştır. Bitki örtüsü indisi ve doku özellikleri (gri tonlama ve pikseller arası kontrast) kullanılarak eğitilen modelde en iyi verim alınmıştır. Mangalraj vd., (2022) çalışmalarında deprem öncesi ve sonrası elde edilen uydu ile İHA görüntüleri kullanarak derin öğrenme modeliyle bina hasar tespitini ele almışlardır. Jaccard index'i ve Dice katsayısı gibi iki farklı ölçüm değeri kullanarak modelin eğitim performansı değerlendirilmiş Jaccard index'i kullanımının model eğitiminde daha iyi verim alınmasına olanak sağladığı görülmüştür. Diğer bir çalışma (Gomroki vd., 2025) U-Net tabanlı UNet-GCViT modeli kullanılarak uydu görüntülerinden bina hasar tespitine yönelik bir çatı sunmaktadır. DDFormer modelinin geliştirildiği başka bir yayında bina hasarlarını tespit etmek için (T. Li vd.,

2023) SAR verileri kullanılarak çift alanlı Transformer tabanlı CNN yaklaşımı uygulanmıştır. Bir diğer yayında (Kalantar vd., 2020) deprem öncesi ve sonrası ortofoto verisi kullanılarak farklı CNN mimarilerinin bina hasar tespiti üzerindeki performansını değerlendirilmektedir. Geliştirilen vision transformer tabanlı EfficientViTB isimli model ile YOLOv8 tabanlı bir encoder-decoder mimarisi kullanıldığı çalışma (Gomroki vd., 2024) ise uydu görüntülerinden bina hasarlarını tespit etmeye odaklanmaktadır. Bir diğer yayında (Abdi & Jabari, 2021) ise çoklu özelliklerin füzyon yöntemiyle ele alınarak, derin transfer öğrenme teknikleriyle hava fotoğraflarından deprem kaynaklı bina hasar tespitini gerçekleştirilmektedir. Başka bir çalışmada (Seydi vd., 2023a) CoatNet tabanlı bir CNN modeli olan BDD-Net+ modeli geliştirilerek uydu görüntülerinden bina hasar tespitine çalışılmıştır. Denetimli derin öğrenme yönteminin kullanıldığı başka bir yayında (Takhtkeshha vd., 2022), deprem sonrası İHA görüntüleri kullanılarak bina hasarlarının hızlı bir şekilde tespit edilmesi amaçlanmıştır. Bir diğer makalede (Ghahrloo & Mokhtarzade, 2025), optik ve SAR verileri birleştirilerek bina hasar tespiti için CNN tabanlı bir model geliştirilmiştir. InCR isimli modelin kullanıldığı başka bir çalışmada (Tasci vd., 2023), uydu görüntüleri kullanılarak bina hasar tespiti için derin öğrenme tabanlı bir yaklaşım sunulmuştur. Bir diğer yayında (Tilon vd., 2020), İHA ve uydu görüntülerinden yararlanılarak anomali tespitine dayalı GAN modeli ile bina hasarları belirlenmektedir. xBDSet veri seti ve uydu görüntülerinin kullanıldığı başka bir çalışmada (Wiguna vd., 2024), bina hasar haritalaması için derin öğrenme modellerinin performansı değerlendirilmektedir. Bir diğer çalışma (Seydi vd., 2023b), dinamik (involution) ve sabit (convolution) katman filtreleri kullanılan teknikleri içeren bir CNN modeli ile deprem sonrası elde edilen uydu görüntülerinden bina hasar tespiti gerçekleştirmektedir ve açıklanabilir AI (XAI) kullanılmıştır. xBD veri setinin kullanıldığı bir diğer yayında (Sodeinde vd., 2024) ise çoklu afet ve çok sınıflı bina hasar tespiti üzerine derin öğrenme tabanlı bir model sunulmaktadır. Bir diğer çalışmada (Rashidian vd., 2021) da yüksek çözünürlüklü uydu görüntülerini kullanarak yıkılmış bina tespiti için değiştirilmiş bir U-Net CNN modeli uygulanmaktadır. Bir diğer yayında (Shao vd., 2020) çeşitli afet türleri için kullanılması amaçlanan, afet öncesi ve sonrası uydu görüntülerinin kullanıldığı bir BDD-Net modeli geliştirilmiştir.

Bir diğ er  alıřma (L. Wang vd., 2024), uydu g r nt leriyle afetler sonucu oluřan bina hasarlarını tespit etmek i in  eřitli derin    renme modellerinin kullanımını kapsamlı bir řekilde incelemektedir. Y ksek   z n rl kl  uzakdan algılama g r nt lerinin kullanıldı ı diğ er  alıřmada (Qiao vd., 2024) bina hasar tespiti i in sınırlı denetimli yeni bir CNN modeli denenmiřtir. Bařka bir  alıřmada (Liu vd., 2022), yer seviyesinden  ekilen foto raflar kullanılarak YOLOv5 algoritması tabanlı, hafif ve hassas bir model ile bina hasarlarının ger ek zamanlı olarak tespit edilmesi hedeflenmektedir. Bir diğ er makalede (H. Du vd., 2024), PCA ve SVM sınıflandırıcıları kullanılarak uydu ve İHA g r nt leri ile tekil bina hasar tespitine  alıřılmıřtır. Bir diğ er  alıřmada (Qing vd., 2022), CNN tabanlı bir model ile s per piksel seviyesinde de iřim tespiti y ntemiyle uydu ve İHA g r nt leri kullanılarak deprem kaynaklı bina hasarları belirlenmektedir. USADA isimli bir modelin  onerildi ı diğ er bir  alıřmada (Y. Li vd., 2020)  eřitli kasırgalarda elde edilen hava foto raflarından binalarda hasar tespitine  alıřılmıřtır. Self-attention mekanizması kullanılarak GAN temelli bir model geliřtirilmiřtir. Bir diğ er  alıřmada (Hu vd., 2023), hava video g r nt lerini kullanarak CNN modeli ile bina hasar tespiti yaparak drone rota planlamasını optimize etmek ama lanmaktadır. İHA g r nt lerinden oluřan bir veri seti ile model e itilmiřtir. Bayes sınıflandırıcı kullanılan bařka bir yayında (Jozi vd., 2024) ise deprem sonrası İHA g r nt lerinden, g r nt n n dokusundaki homojenlik, kenar gibi  zelliklerinden binaların hızlı hasar de erlendirmesi  zerine  alıřılmıřtır. Diğ er bir yayında (Wu vd., 2021) ise Siamese sinir a ı ile afet  ncesi ve sonrası uydu g r nt lerinden hasarlı bina tespiti yapılan bir model geliřtirilmiřtir. U-net tabanlı odaklanma mekanizmaları (attention mechanism) sayesinde g r nt den  zellik  ıkarımı iyileřtirilmiřtir.



2. YAPAY ÖĞRENME

Yapay öğrenme veya makine öğrenmesi, yapay zeka sistemlerinin bir parçası olan ve bilgisayar sistemlerinin insan zekasını taklit edilerek insanın yapabildiği zeka gerektiren işleri yapabilmesi için uygulanan yöntemlerdir (“Machine learning, explained”, 2024). Makine öğrenmesi sayesinde bilgisayar sistemleri insanın zekasının yapabildiği karmaşık işleri yerine getirebilir. Bu şekilde bilgisayar sistemleri görüntüdeki detayları ayırt edebilme, konuşma dilini anlayabilme gibi yeteneklere sahip olabilir.

Bilgisayar sistemleri geleneksel prosedürel programlama yöntemleriyle girilen komutlara göre işlem adımlarını gerçekleştirebilir. Belirli bir algoritmada, her adımda yapılacak işlemler tanımlanabilir veya belirli bir olay gerçekleştiğinde farklı prosedürler devreye sokulabilir. Fakat daha karmaşık problemlerde geleneksel adım adım programlama etkili olmayabilir. Bilgisayar sisteminin, bir görüntü verisindeki rakamları ve harfleri tanıması gibi bir örnek ele alınırsa, görüntüdeki piksel değerlerinden daha önce tanımlanmış piksel koordinatları ve RGB renk değerleri ancak mutlak veya yakın değerlerde olması gibi bir koşulda harf ve rakamlar tanımlanabilir. Bu şekilde bir algoritma tasarımının başarılı olması için yeterince etiketlenmiş örnek veri setiyle desteklenmesi gerekmektedir. El yazısı gibi bir yazının tanımlanması, geleneksel algoritma tasarımları ve büyük bir kural kümesi kullanılsa dahi başarılı olmayabilir (Rebala vd., 2019).

Makine öğrenmesi yöntemleri, geleneksel programlama ve detaylı algoritma tasarım yöntemlerinden farklı olarak, bir oto-programlama örneği gibi, sağlanan veri setinden çıkarım yaparak beklenen işlemi yapar. Makine öğrenmesi yöntemleri yardımıyla algoritma, girdi olarak sağlanan veriden öğrenir, sonrasında veri setinden farklı olan bir veri ile karşılaştığında hesaplanan parametreleri kullanarak tahmin sonucu üretir.

Makine öğrenmesi algoritmaları, girdi olarak aldığı verileri eğitim, doğrulama ve test adımlarında kullanır. Eğitim verisi etiketlenmiş ya da etiketlenmemiş veriler olabilir. Veri seti, belirli bir konuyla ilgili olarak etiketlenir ve eğitim verisi olarak makine

öğrenmesi algoritmalarına verilir. Bu makine öğrenme yaklaşımı denetimli öğrenme (supervised learning) olarak tanımlanır. Verilen konut özelliklerinden fiyat tahmini yapma algoritması buna örnek olarak verilebilir. Etiketleme olmadan kullanılan veri ile eğitilen makine öğrenmesi algoritması yaklaşımı ise denetimsiz öğrenme (unsupervised learning) olarak tanımlanır. Denetimsiz öğrenme yaklaşımında algoritma, veri setinin içindeki örüntüleri keşfederek bir çıkarım yapmayı hedefler. Denetimsiz öğrenme yaklaşımına ise bir müşteri verisinden müşterileri farklı özelliklerdeki gruplara ayırma örneği verilebilir.

Makine öğrenmesi eğitimi aşamaları şu şekildedir:

1. Verilerin toplanması: Büyük miktarda veri toplanır.
2. Özellik çıkarımı: Elde edilen verilerden, modelin anlamlandırılması için özellikler çıkarılır.
3. Modelin eğitilmesi: Makine öğrenme algoritması veri setinden öğrenme yaparak bir model oluşturur. Bu süreçte model örüntüleri ve ilişkileri öğrenir.
4. Model test ve doğrulama: Model daha önce görmediği veriyle test edilir ve performansı ölçülür.
5. Tahmin ve uygulama: Oluşan model yeni veriler üzerinden tahminlerde bulunarak görevleri yerine getirir.

2.1 Makine Öğrenmesi Algoritmaları

2.1.1 Doğrusal regresyon

Bir denetimli öğrenme yaklaşımı olan doğrusal regresyon (linear regression) algoritması, sürekli değişkenleri modellemek ve buna bağlı tahminleme yapmak üzere çalışır. Giriş değişken ile hedef değişken arasında doğrusal ilişki olduğunu varsayar. x değişkenlerinden y değişkeni tahmin edilmeye çalışılır (Sarker, 2021). Denklem 2.1 ile y değeri hesaplanır. Burada katsayılar (β), yitim fonksiyonunu en aza indirilerek bulunur. Yitim fonksiyonu olarak genellikle ortalama kare hata (minimum squared error) kullanılır. Sürekli değişkenleri tahmin (konut, hisse senedi tahmini), satış tahmini gibi örneklerde kullanılır.

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n \quad (2.1)$$

- y : Tahmin edilen çıktı.
- β : Kesim noktası.
- x : Bağımsız değişken.

Model eğitildikten sonra denklem 2.2’de yer alan ortalama mutlak hata (mean absolute error-MAE), denklem 2.3’de yer alan ortalama kare hata (mean squared error) ve denklem 2.4’de yer alan R-kare (R^2) metrikleriyle değerlendirilebilir (Jumin vd., 2020). Doğrusal regresyon algoritmasında hangi x değişkeninin önemli olduğu katsayıların değişkeni artırıcı ve azaltıcı olmasından anlaşılabilir. Doğrusal regresyon, makine öğrenmesi alanında sadelik ve verimlilik açısından sıkça tercih edilen bir algoritmadır.

$$MAE = \frac{1}{n} \sum_{c=1}^n |y_c - \hat{y}_c| \quad (2.2)$$

- MAE : Mean absolute error (ortalama mutlak hata)
- y_c : Gerçek değer.
- $\hat{y}$: Tahmin edilen değer.
- n : Veri noktalarının sayısı.

$$MSE = \frac{1}{n} \sum_{c=1}^n (y_c - \hat{y}_c)^2 \quad (2.3)$$

- MSE : Mean squared error (ortalama kare hata)
- y_c : Gerçek değer.
- $\hat{y}$: Tahmin edilen değer.
- n : Veri noktalarının sayısı.

$$R^2 = 1 - \frac{SS_{res}}{SS_{tot}} \quad (2.4)$$

SS_{res} : Artık toplamlar kareleri (Residual Sum of Squares), yani modelin tahmin hataları:

$$SS_{\text{res}} = \sum_{c=1}^n (y_c - \hat{y}_c)^2 \quad (2.5)$$

SS_{tot} : Toplam kareler toplamı (Total Sum of Squares), yani gerçek değerlerin ortalamadan sapmaları:

$$SS_{\text{tot}} = \sum_{c=1}^n (y_c - \bar{y})^2 \quad (2.6)$$

- y_c : Gerçek değerler.
- $\hat{y}$: Tahmin edilen değerler.
- $\bar{y}$: Gerçek değerlerin ortalaması.

2.1.2 Lojistik regresyon

Lojistik regresyon (logistic regression), ikili sınıflandırma problemlerinde kullanılan, denetimli öğrenme yaklaşımını kullanan bir algoritmadır. Girdi değişkenlerine göre sonucun gerçekleşip gerçekleşmeyeceğine yönelik ikili bir tahmin sonucu üretir. Örnek olarak öğrencinin ilk sınavdan aldığı not ve ders çalışma süresi birer değişken ve sınavda alabileceği not tahmin edilmeye çalışırsa, buradaki değişkenler bir lojistik regresyon modeline (denklem 2.7) girer ve buradan çıkan sonuç sigmoid fonksiyonda (denklem 2.8) kullanılır (Sarker, 2021). Sonrasında tanımlanan eşik değere göre (mesela 0.5 üstü geçmiş anlamındadır) 0 ile 1 arası bir yüzdelik bir tahminle sonuç elde edilmiş olur (Saidi vd., 2021).

$$z = \beta_0 + \beta_1 x_1 + \beta_2 x_2 \quad (2.7)$$

$$P(y = 1 | x) = \frac{1}{1 + e^{-z}} \quad (2.8)$$

z : Olasılık hesaplamadan önceki ara değer

x_1 : Öğrencinin ders çalışma süresi değişkeni.

x_2 : Öğrencinin önceki sınavdan aldığı not değişkeni.

β_0 : Sabit terim.

β_2 : x_1 katsayısı.

β_3 : x_2 katsayısı.

y : sınav geme durumu. (geti-geemedi: 0,1)

Lojistik regresyon algoritmasının temel amacı kategorik bir sınıfı tahmin etmektir. Her özelliğın tahmin üzerinde etkisini gösteren katsayılar bulunmaktadır. Algoritmanın anlaşılması ve karşılaşılan problemlerin giderilmesi diğerk algoritmalara nazaran kolaydır. Küçük ve orta ölçekli veri setlerinde iyi performans gösterir. Özellikle seyrek girdilerde iyi çalışır. Karmaşık ve doğrusal olmayan verilerde daha düşük performans sergileyebilir.

2.1.3 Destek vektör makineleri

Destek vektör makineleri (support vector machines – SVM) algoritması, sınıflandırma ve regresyon problemlerinde sıklıkla kullanılan geleneksel bir makine öğrenmesi algoritmasıdır. En önemli avantajı basit olması ile az bir veriyle ve düşük işlem gücüyle eğitilebilir olmasıdır (Shammi vd., 2023). Bu algoritmada bir karar sınır değeri tanımlanır. Verileri ayırım düzlemleriyle sınıflara ayırır. Bir denetimli öğrenme yaklaşımıdır. Çok boyutlu özelliğes sahip az eğitim verisiyle eğitilebilir. Önceleri ikili sınıflandırma için geliştirilmiş olsa da artık çok sınıflı verilerde de başarıyla çalışabilmektedir (C. J. Du & Sun, 2008). Farklı sınıfları birbirinden ayıran optimum düzlemi bulmaya çalışır. İki sınıf arasındaki düzlemin en uzak hale gelmesi amaçlanır. SVM doğrusal olarak ayıramayan girdi verilerini çekirdek (kernel) fonksiyonlar kullanarak daha yüksek boyutlara dönüştürür (Schölkopf, 1998). Bu boyutlarda doğrusal bir düzlemle ayırım yapılabilir. Yaygın çekirdek (kernel) fonksiyonlar; doğrusal, polinom, radyal tabanlı ve sigmoid'tir (Goswami vd., 2019).

Bu algoritma eğitim verisinin yalnızca bir bölümünü kullanarak bilgisayar hafızasını verimli kullanır. Çok boyutlu matrisler gibi yüksek boyutlu özellik içeren verilerde etkilidir. Gürültülü ve birbirine karışmış örneklerin bulunduğu verilerde performansı düşebilir. Nesne görüntülerinden sınıflandırma, metinden duygu analizi, makalelerin kategorize edilmesi, protein yapısı tespiti ve gen sınıflandırması kullanım örneklerindendir.

2.1.4 Karar ağaçları

Karar ağaçları (decision trees) denetimli öğrenme yaklaşımına sahip bir makine öğrenmesi algoritmasıdır. Deterministik cevaplarla sınıflandırma yapan bir ağaç türü veri yapısı kullanılır. Sınıflandırılmak istenen olgunun özelliklerine göre dallar ve düğümlere ayrılır. Nihai düğüm tahmin edilmek istenen sınıflardan biridir (Rebala vd., 2019). Regresyon ve sınıflandırma işlemlerinde kullanılabilir. Örnek olarak finans sektöründe kredi risk analizi, müşteri sınıflandırma kullanımları verilebilir.

Öncelikle hangi özelliğin karar işleminde kullanılacağına karar verilir. Bilgi kazancı (information gain) veya gini saflık kriteri ölçümleriyle hangi özelliğin karar işleminde kullanılacağı belirlenir. Bilgi kazancı ölçeği, sınıflara veya kategorilere ayrılan verilerde kullanılır. Gini saflık kriteri ise kişinin yaşı gibi sayısal değerler içeren verilerde kullanılır. Karar ağacının her bir düğümünde “Kredi Puanı ≥ 650 ” gibi bir karar kuralı uygulanır. Karar işlemi durma kriterinin olduğu seviyeye kadar devam eder. Karar ağacının yaprak kısımlarında ise tahmin sonuçları yer alır. Aşağıda veri üzerinde yaş ve gelir seviyesine göre sınıflandırma yapan örnek bir karar ağacı sunulmuştur:

Yaş?

— 30 > **Genç:**

| — Gelir Seviyesi?

| — Düşük: Hayır

| — Orta: Evet

| — Yüksek: Evet

— 30 < Orta < 61: Evet

— Yaşlı > 60:

| — Gelir Seviyesi?

| — Orta: Evet

| — Yüksek: Hayır

2.1.5 Rastgele ormanlar

Denetimli öğrenme yaklaşımı örneği olan rastgele ormanlar (random forests) algoritması, birden fazla karar ağacından oluşur ve bu şekilde tek bir karar ağacından daha iyi tahmin performansı sağlar. Tek ağaçta varyans değeri nedeniyle sebep olabilecek hatalı sonuçtan yerine, ağaçların tahmin ortalaması alınarak sonuç elde edilir. Sınıflandırma ve regresyon problemlerinde kullanılır. Topluluk öğrenmesi yöntemiyle her ağaç bağımsız olarak eğitilir ve sınıflandırma veya ortalama alma yoluyla bir topluluk tahmini elde edilir. Bootstrapping yöntemiyle eğitim veri setinden her ağacın ayrı ayrı eğitilmesi için farklı veriler alınır. Bu şekilde modelde aşırı öğrenme (overfitting) sorunu engellenmiş olur. Her ağaç için özelliklerin yalnızca bir alt kümesi kullanılır ve model çeşitliliği artmış olur. Tahminleme yaparken çoğunluk ağacın verdiği sonuçlar ya da ortalama değer kullanılır (Belyadi & Haghighat, 2021).

Rastgele ormanlar, diğer sınıflandırıcı algoritmalara nazaran yüksek doğrulukla çalışır (Speiser vd., 2019) ve aşırı öğrenmeye karşı dayanıklıdır (Hastie vd., 2009). Hem kategorik hem sayısal verilerle çalışabilir. Örnek olarak hem cinsiyet hem de müşteri harcaması gibi verilerdir. Hangi özelliğin önemli olduğu belirlenebilir. Büyük veri setlerinde ve çok özellik içeren verilerde yavaş çalışabilir. Müşteri segmentasyonu, tıbbi teşhis, doğal dil işleme gibi örnek çalışma alanları bulunmaktadır.

2.1.6 K- en yakın komşu

K - en yakın komşu (k-nearest neighbour), sınıflandırma ve regresyon problemlerinde kullanılan bir denetimli öğrenme algoritmasıdır. Temel prensibi birbirine yakın olan nesnelerin birbirine benzer olması fikrine dayanır. Örnek uzayındaki noktaların birbirine öklit mesafesindeki yakınlığı dikkate alınır. Bir örnek uzayındaki veriler test verisine yakın mesafedeyse, test verisinin dahil olduğu sınıfta bulunduğu karar verir. Ayrıca mesafeye göre ağırlık/puan ataması yapılarak yakın mesafede olana yüksek puan verilip dahil olduğu sınıf bulunabilmektedir (Cunningham & Delany, 2021). En yakın k adet örnek seçilerek bunların bulunduğu sınıflara göre örneğin dahil olduğu sınıf tahmin edilir. Tıbbi veriler kullanılarak hastalık teşhisinde sınıflandırma gibi kullanım örnekleri bulunmaktadır.

2.1.7 Naive bayes

Bayes teoremine (denklem 2.9) dayanan olasılık temelli bir sınıflandırma algoritmasıdır. Bayes teoremi bir olayın gerçekleşme olasılığını hesaplamada kullanılır. Naive bayes de etiketli veri kullandığı için denetimli öğrenme yaklaşımına sahiptir. Makine öğrenmesinde kullanılan oldukça basit etkili bir sınıflandırma algoritmasıdır.

$$P(A | B) = \frac{P(B | A) \cdot P(A)}{P(B)} \quad (2.9)$$

- $P(A/B)$: B olayının gerçekleşmesi durumunda A'nın gerçekleşme olasılığı (posterior probability).
- $P(B/A)$: A olayının gerçekleşmesi durumunda B'nin gerçekleşme olasılığı (likelihood).
- $P(A)$: A olayının gerçekleşme olasılığı (prior probability).
- $P(B)$: B olayının gerçekleşme olasılığı (normalizasyon faktörü).

Naïve Bayes algoritması bir veri noktasının belirli bir sınıfa ait olup olmama olasılığını Bayes teoremiyle hesaplar. Eğitim verisi analiz edilerek özellik dağılımı hesaplanır. Yeni veri noktasının her bir sınıfa göre dahil olma olasılığı Bayes teoremiyle hesaplanır. En yüksek sonuca sahip sınıfın oranı o sınıfa dahil olma olasılığı olarak bulunur ve tahmin edilen sınıf olarak belirlenir.

Naïve Bayes kolay uygulanabilir bir algoritmadır. Eğitim ve tahmin işlemleri hızlı yapılabilir. Küçük veri setlerinde bile iyi sonuç verebilir. Özellik sayısının fazla olduğu durumlarda da başarılıdır. Normal dağılım olmayan verilerde iyi performans sağlayamaması ise dezavantajları arasındadır. Metin sınıflandırması, metinden duygu analizi, spam e-posta filtrelemesi gibi problemlerde kullanılır.


2.1.8 Yapay sinir ağıları

Yapay sinir ağıları (artificial neural networks) gerçek sinir hücrelerinin çalışma prensibine dayanan bir makine öğrenme algoritmasıdır. Sinir hücreleri olan nöronların birbirleriyle kurduğu gibi bağlantı katmanlarından oluşur. Her bir katmanda farklı ağırlık katsayılarına sahip olup gelen bilgi burada bu ağırlıkla yeniden hesaplanarak bir sonraki katmana aktarılır. Bu şekilde birbirine bağlı katmanlara bilgi girişi ve çıkışı gerçekleşmiş olur (Kang vd., 2015).

Yapay sinir ağıları doğrusal olmayan karmaşık problemlerin çözümünde sıklıkla kullanılan yöntemlerdendir. Kullanım alanlarına örüntü tanımla, görüntü işleme, sınıflandırma gibi örnekler verilebilir

Bir sinir ağı konuyla ilgili özellikleri içeren verilerin sunulduğu giriş katmanından (input layer), ortada bu giriş verisi ve çıkış arasında sinaptik ağırlıklar yardımıyla bağlantıların önem tanımlamasının yapılması ile ilişki sisteminin kurulduğu gizli katmanlardan (hidden layer) ve hesaplamaların neticesinde elde edilen verilerin sunulduğu çıkış katmanından (output layer) oluşmaktadır. Şekil 2.1’de katmanlı yapı şema halinde gösterilmiştir. Bu yapıda, sinaptik ağırlıklarla tanımlanmış sinaps bağlantıları, giriş verisini birleştiren operatör, çıkış verisini belirli bir değer aralığına indirgeyen aktivasyon fonksiyonu yer alır. Aktivasyon fonksiyonu girdi değerinin sıfır olması durumunda, sinaps ağırlıklarını içeren nöronlar aktive olmazlar. Nöronları bu durumda aktive etmek amacıyla bias değeri kullanılır. Bias değeri sayesinde aktivasyon fonksiyonu giriş verisi arttırılır veya azaltılır. Sonuç olarak eklenen sabit bias değeri sayesinde bütün nöronlar işlevsel kalır ve ağıın öğrenme yeteneği iyileştirilmiş olur

Yapay sinir ağlarının öğrenme işlemleri sırasında her bir adımda üretilen çıktı ile beklenen çıktı arasındaki fark hata değeri olarak hesaplanır. Ağıın öğrenme sürecinin bir parçası olarak bu hata değerinin kabul edilebilir bir değere indirgenmesi amacıyla parametre iyileştirme adımları uygulanır.




Şekil 2.1 : Yapay sinir ağı katmanları.

2.2 Derin Öğrenme

Derin öğrenme de bir makine öğrenmesi yöntemidir. Aynı zamanda bir yapay sinir ağıdır. Ağ yapısında birden fazla gizli katman bulunur. Her bir gizli katman verideki farklı bir özelliği öğrenmeye odaklanır. Denetimsiz bir öğrenme yaklaşımıyla verideki örüntüleri ve özellikleri otomatik olarak çıkarır. Örneğin bir görüntüdeki kenarları, nesneleri otomatik olarak çıkarır. Ağın çok fazla parametreye sahip olması ve gelişmiş bir yapıda olması sayesinde büyük veri setleri üzerinde çalışabilmesine imkan verir.

Derin öğrenme sinir ağları, yapay sinir ağlarına nazaran birden daha fazla gizli katmana sahiptir, iç içe geçmiş ağ yapılarından oluşur. Ayrıca gelişmiş yapay nöronlara sahiptirler. Nöron yapılarında birden fazla aktivasyon fonksiyonları bulunabilmektedir. Bu tür gelişmiş özellikler sayesinde, derin öğrenme modelleri ham veri içindeki örüntüleri otomatik olarak tanıyıp hedeflenen öğrenme modelini gerçekleştirebilirler.

Derin öğrenme yöntemi büyük boyutlu ve çok miktarda verinin kullanıldığı işlemlerde derin olmayan makine öğrenmesi yöntemlerinden daha iyi performans sergiler. İşlenmemiş haldeki belirli bir formatta oluşturulmayan metin, görsel, video, ses gibi veri setlerinde kullanılabilir.



Şekil 2.2 : Makine öğrenmesi algoritma türleri.

2.2.1 Derin öğrenme türleri

Derin öğrenme farklı problemler için özelleşmiş yapılar bulundurabilir. Şekil 2.2’de makine öğrenmesi ve onun alt kümesi olarak derin öğrenme yöntemlerinin sınıflandırması gösterilmiştir. Temelde her yöntem her uygulama için kullanılabilir olsa da bazı yapılar bazı veri tipindeki uygulamalar için daha uyumludur. Örnek olarak zaman serisinden oluşan veriler ya da görselden oluşan veriler verilebilir. Derin öğrenme yöntemleri; katman yapıları, sinir ağı birimleri ve kullanılan bağlantılar anlamında yapısal olarak sınıflandırılabilir.

2.2.1.1 Convolutional neural network (CNN)

Daha çok bilgisayarlı görü ve konuşma tanıma gibi uygulamalarda kullanılan derin öğrenme mimarisidir. Girdi verisi olarak içinde birbiriyle ilişkisi olan ve yerleri değiştirilemeyen veri parçalarının bulunduğu veri setleri kullanılır. Görüntü tanıma gibi bir görevde basitten karmaşığa doğru görüntü algılama süreci işler. Öncelikle görüntüdeki kenarlar köşeler çıkarılır. Sonraki katmanlarda çıkarılan bu özellikler birleştirilir ve daha kompleks nesneler (insan yüzü, hayvan görüntüsü gibi) görüntüden çıkarılacak hale gelişir. VGGNet, ResNet gibi algoritmalar CNN derin öğrenme mimarilerine örnek olarak sunulabilir (J. Wang vd., 2021).

2.2.1.2 Recurrent neural network (RNN) (yinelemeli sinir ağı)

Zaman serisi, olay dizisi veya doğal dil gibi veriler için geliştirilmiş derin öğrenme yapısıdır. Girdi olarak kullanılan veriler kendi içinde birbiriyle alakalı verilerdir. Ağı yapısında bulunan hafıza sayesinde birbiriyle bağlantılı verileri sıralı bir biçimde öğrenir. Fakat basit RNN mimarileri kaybolan gradyan (vanishing gradient) problemi nedeniyle, erken katmanlarda çıkarılan bilgiler kaybolur ve sonraki katmanlarda kullanılamaz. Bu nedenle yeni gelişmiş RNN yapılarında Uzun Süreli Kısa Hafıza (Long Term Short Memory - LSTM) kullanılarak bu sorunun önüne geçilmiştir. Hisse senedi tahmini veya hava durumu tahmini gibi gerçek dünya örneklerinde kullanılabilir. Ya da doğal dil işleme (NLP) yeteneğine sahip olduğu için konuşma dilinde makine çevirisi yapabilmeyi sağlar.

2.2.1.3 Distributed representation (dağıtık temsil)

Özellikle doğal dil işleme uygulamalarında, veri içindeki anlamı çıkarma amacıyla kullanılan bir yapıdır. Dildeki metinler, ifadeler ve kelimeler word embedding adı verilen vektör matrislerine dönüştürülür. Ayrık kelimeler bir arada anlamlı olacak şekilde yoğun özellik vektörlerine kodlanır. Benzer kategorideki kelimelerin vektör uzayında birbirine yakın konumlanması sağlanır. Soru cevaplama ve duygu analizi gibi görevlerde kullanılabilir. Modern NLP'nin (doğal dil işleme) temelini oluşturur.

2.2.1.4 Autoencoders (oto kodlayıcılar)

Girdi verisini, düşük boyutlu vektörlere indirgeyip dönüştürerek tekrar benzer çıkış verisini üreten bir derin öğrenme mimarisidir. Encoder ve decoder yapılarından oluşur. Girdi verisi özelliklerinin benzer kısımlarını özet haline getirerek küçültür ve decoder kısmı ile yeniden orijinal veriyi elde eder.

Girdi verisi ile çıktı verisi arasında farklılıklar hata hesaplamasıyla tespit edilir. Bu özellik sayesinde anomali tespiti, finansal piyasalarda sahtecilik tespiti gibi uygulamalarda kullanılır (Said Elsayed vd., 2020).

2.2.2 Derin öğrenme adımları

Derin öğrenmenin otomatik öğrenme safhasında, algoritma girdi verisindeki ilişkileri ve örüntüleri öğrenmeye çalışır. Derin öğrenme harici algoritmalarda öğrenme işlemi iyi belirlenmiş süreçleri kapsar. Derin öğrenme algoritmaları ise uçtan uca bir sistem olarak ham veri üzerinden otomatik veri çıkarımı yapabilirler.

Derin öğrenmede eğitim epoch adı verilen döngülerden oluşur. İlk döngüde rastgele ağırlık parametreleri ve bias değeri atanarak model eğitimi başlar.

Derin öğrenme algoritmalarında eğitim adımları şu şekildedir:

- Veri setinin oluşturulması
- Verinin girdi olarak modele sunulması
- Rastgele ağırlık ve bias değerlerinin tanımlanması
- Katmanlardaki nöronlarda bulunan aktivasyon fonksiyonunun çalışarak veriyi sonraki katmanlara aktarması
- Çıktı katmanına ulaşan verinin gerçek veriyle karşılaştırılıp test edilmesi ve aradaki farkın hesaplanması (yitim varyansı)
- Kayıp değerine göre ağırlık ve bias değerlerinin yeniden hesaplanıp önceki katmanlardaki nöronların ağırlık değerlerin güncellenmesi (backpropagation)
- Döngünün yeni değerlerle devam edip, kayıp değerini azaltarak modelin doğruluğunun artırılması

2.2.3 Eğitim adımları ile ilgili terimler

Derin öğrenme modellerinde eğitim sürecini ve model performansını iyileştirmek için kullanılan parametreler bulunur. Bunlar hiperparametre olarak tanımlanır.

2.2.3.1 Yitim (hata) (loss)

Yitim (loss) makine öğrenme modellerinde, modelin tahminlerinin ne kadar hatalı olduğunu tespit etmeyi sağlayan fonksiyondur. Yitim fonksiyonu gerçek bulunmak istenen değer ile tahmin edilen değer arasında mesafeyi bulur. Bir makine öğrenmesi modelinin eğitim süreci, yitim fonksiyonu sonucunu minimize etmek üzerinedir. Mutlak fark ortalaması (mean absolute error-MAE) (denklem 2.2) ile fark değerlerinin ortalama karesi (mean squared error-MSE) (denklem 2.3) gibi fonksiyonlar kullanılmaktadır (“Linear regression: Loss”, 2025). Regresyon ve sınıflandırma işlemleri için farklı yitim fonksiyonları kullanılabilmektedir (Q. Wang vd., 2022).

2.2.3.2 Optimizatör (optimizers)

Optimizatörler (optimizer) derin öğrenme modelindeki ağırlık ve yatkınlık (bias) değerlerinin hangilerinin azaltılıp hangilerinin artırılması gerektiğini, modeldeki hata-yitim değerini azaltacak şekilde belirler. Yaygın olarak kullanılan optimizasyon algoritmaları arasında Stokastik Gradyan İnişi (Stochastic Gradient Descent-SGD), Uyarlanabilir Öğrenme Oranı (Adaptive Learning Rate-ADADELTA), Uyarlanabilir Momentum Tahmini (Adaptive Momentum Estimation-ADAM) ve diğerleri bulunur.

2.2.3.3 Öğrenme oranı

Derin öğrenme modelinin eğitimi sırasında ağırlık ve yatkınlık (bias) değerlerinin güncellenmesi işleminde bu değerlerin ne kadar değişeceğinin belirlenmesinde öğrenme oranı (learning rate) denen bir değer kullanılır. Hata/yitim değerini minimum seviyede tutmaya çalışılır. Öğrenme oranının yüksek olması durumunda, her bir eğitim adımı daha hızlı ilerler ve yitim değerinin optimum noktası kaçırılabilir. Öğrenme oranının düşük olması durumunda ise eğitim süresi uzar fakat minimum kayıp değerine ulaşmak daha mümkündür (“Deep neural network concepts”, 2024).

2.3 Makine Öğrenmesi Model Değerlendirmesi

Makine öğrenmesi algoritmalarında geliştirilen modelin test edilerek beklenen verimi sağlayıp sağlamadığı çeşitli ölçüm birimleriyle belirlenir. Regresyon modelleri tahminden doğan hataların hesaplanması için ortalama kare hata değeri (root mean square error - RMSE) veya ortalama mutlak hata yüzdesi (mean absolute percentage error - MAPE) yöntemleri kullanılır. Sınıflandırma modelleri ise doğru ve yanlış tahminlerin oranlarının kullanıldığı doğruluk (accuracy), duyarlılık/hassasiyet (recall), kesinlik (precision), and F1 skoru ve IoU (Intersection over Union - Kesişim Birleşim Oranı) vb. metrikler kullanılarak başarımları değerlendirilebilir.

Sınıflandırma modelleri için kullanılan değerlendirme yöntemi için bir karışıklık matrisi (confusion matrix) tanımlanır. Bu matriste doğru tahmin edilen doğrular, yanlış bilinen doğrular gibi tanımlamalar bulunur.

Bunun için öncelikle yapay öğrenmede sınıflandırma problemlerinde kullanılan, gerçek değerlerle (actual values) tahmin edilen değerler (predictive values) arasındaki ilişkileri gösteren ‘Gerçek Pozitif (True Positive, TP)’, ‘Sahte Pozitif (True Negative, TN)’, ‘Gerçek Negatif (True Negative, TN)’, ‘Sahte Negatif (False Negative, FN)’ metriklerinden oluşan bir karışıklık matrisi (confusion matrix) oluşturulmaktadır.

		True label	
		Positive $D+$	Negative $D-$
Predicted label	Positive $T+$	TP	FP
	Negative $T-$	FN	TN

Şekil 2.3 : Makine öğrenmesi model değerlendirme matrisi.

Şekil 2.3’de yer alan matrise göre TP: True-Positive, FP: False-Positive, FN: False-Negative, TN: True-Negative olarak belirtilir (D+,D- gerçek sınıf, T+,T- tahmin edilen sınıf). Örnek olarak TN değeri bu matrise göre örneklerin kendisi mevcut ve tahmin değerleri negatiftir. Bu durumda bir sağlam bir bireyin hasta olmadığını tahmin etmek gibi bir örnek ile ifade edilebilir.

Bu matris tanımlamaları kullanılarak performans hesaplamaları şu şekilde tanımlanır (Varoquaux & Colliot, 2023):

- Doğruluk (accuracy): Doğru şekilde tahmin edilen tüm örnekler. Denklem 2.10’da gösterilmiştir.

$$\text{Doğruluk} = \frac{TP+TN}{TP+FP+TN+FN} \quad (2.10)$$

- Duyarlılık (sensitivity / recall): Modelin gerçek pozitifleri ne kadar iyi bulduğunu ölçer. Denklem 2.11’de duyarlılık formülü sunulmuştur.

$$\text{Duyarlılık} = \frac{TP}{TP + FN} \quad (2.11)$$

- Kesinlik (precision): Modelin pozitif tahminlerinin ne kadar doğru olduğunu ölçer. Denklem 2.12’de kesinlik formülü sunulmuştur.

$$\text{Kesinlik} = \frac{TP}{TP + FP} \quad (2.12)$$

- F1 Skoru: Kesinlik ve duyarlılığın harmonik ortalamasıdır. Denklem 2.13’de F1 skoru formülü sunulmuştur.


$$F1 = 2 \cdot \frac{\text{Kesinlik} \cdot \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} \quad (2.13)$$

- Kesişim Birleşim Oranı (IoU- Intersection over Union): Özellikle nesne tespiti ve bölütleme (segmentasyon) uygulamalarında tespit edilen alanın tüm alana oranının ne kadar olduğu ile ilgili bir ölçümdür. Denklem 2.14’de IoU formülü sunulmuştur.

$$IoU = \frac{\text{Kesişim Alanı (Intersection)}}{\text{Birleşim Alanı (Union)}} \quad (2.14)$$

2.4 Makine Öğrenmesi Yöntemlerinde Veri Setleri

Makine öğrenmesi modellerinin eğitimi sırasında kullanılan veri eğitim verisi olarak tanımlanır. Bu veri sayesinde model parametreleri en iyi verimi sağlayacak şekilde tanımlanmaya çalışılır. Model parametrelerinin en iyi şekilde tanımlanıp tanımlanmadığını ve modelin ne kadar iyi çalıştığını anlamak için modelin test edilmesi gerekir.




Şekil 2.4 : Makine öğrenmesi algoritmalarında veri seti kullanımı (Bangert, 2021).

Bu aşamada model daha önce karşılaşmadığı bir veri ile test edilir. Bu veri test verisi olarak tanımlanır. Bazı algoritmalar model eğitim sürecinin ne zaman durması gerektiğini belirleme için fazladan bir veri seti daha kullanır. Eğitim ve test sürecinde kullanılmayan bu benzersiz veri seti ise doğrulama veri seti olarak tanımlanır. Genel olarak model eğitimlerinde veri seti %70 ile %85 arası eğitim verisi ve kalan kısmı test verisi olarak ayrılır (Bangert, 2021). Veri setinin model eğitimi sırasında kullanım şeması Şekil 2.4’de gösterilmiştir.

Makine öğrenmesi algoritmalarında model eğitimi için kullanılan girdi veri setleri daha verimli çalışması için çeşitli düzeltmelerden geçirilirler. Bu işlemler veri zenginleştirme (data augmentation) veya iyileştirme, veri normalizasyonu gibi düzeltme işlemleridir. Veri zenginleştirme işlemi makine öğrenmesi modelinin aşırı öğrenme (over-fitting) ve modelin daha farklı veri türlerinde de performansının iyi olabilmesi amacıyla, verinin farklı yöntemlerle zenginleştirilmesi işlemidir. Örnek olarak veri seti görsellerden oluştuğunda, görsellerin biçimsel olarak farklı türleri oluşturulur. Görsel veri setleri üzerinde, döndürme, kırpma, ters çevirme, bulanıklaştırma, birleştirme gibi işlemler uygulanabilir. Şekil 2.5’de veri zenginleştirme yöntemleri örneklenmiştir.

Makine öğrenmesi algoritmalarında kullanılan veri setlerinde veri setleri belirli bir örnek için daha az orantıda bulunabilir böyle bir durumda da girdi veri seti dengeli bir orantıda olmaz. Bu durumda ise model performansı sağlıklı çıkarım yapmayı engeller ve belirli bir sınıfa yatkın sonuç vermeye eğilimli olur. Böyle bir durum için yapay azınlık verisi örnekleme (Synthetic Minority Over-sampling Technique (SMOTE)) kullanılır. Bu yöntemle var olan azınlıktaki örnekler üzerinden yapay olarak farklı versiyonlar üretilir. Bu şekilde veri setinin daha dengeli hale gelmesi sağlanır ve model performansı iyileştirilir.

Görüntü sınıflandırmasında veri zenginleştirme işlemi bir temel adım olarak yer almaktadır. Eğitim veri setinin zenginleştirilmesi, modelin genelleştirme ve tahmin performansının artırılmasına yardımcı olmak açısından önemlidir. Veri zenginleştirme işlemindeki yeni gelişmeler sayesinde geometrik dönüşümler, renk parametre ayarlamaları ve gürültü ekleme gibi farklı tekniklerden faydalanılabilmektedir (“Data augmentation”, 2024).



Şekil 2.5 : Veri zenginleştirme / çoğaltma yöntemleri.

2.5 Makine Öğrenmesi Algoritmalarında Özellik Çıkarımı

Makine öğrenme algoritmalarında model oluşturma sürecinde girdi verisinden anlamlı çıkarımlar yapabilmesi, bu ilişkileri sağlayacak uygun bağlantıların kurulması ile mümkündür. Ham veri içerisinde elde edilen özellik veriye ait hedeflenen duruma yönelik tanımla ilgili örüntüdür. Özellik çıkarma ile veri içerisindeki anlamlı bilgiyi elde etme ve verideki karmaşık ve gürültü gibi varyasyonları uzaklaştırmak hedeflenir.

Örneğin bir satış platformundaki kullanıcı yorumlarının faydalılığı sınıflandırılırken yararlı özellikler tanımlanırken kullanılan kelimeler, yorumun uzunluğu, metin dilbilgisi özellikleri kullanılabilir.

Farklı veri türleri için farklı türde özellik çıkarma teknikleri geliştirilmiştir. Örnek olarak görüntü analizi için histogram bazlı eğimler (Histogram Oriented Gradients - HOG), ölçek bağımsız özellik dönüşümü (Scale-Invariant Feature Transform - SIFT); doğal dil işleme için TF-IDF vektörleri, sözcük türü (POS) etiketleme ve sözcük şekli özellikleri kullanılır (Janiesch vd., 2021).

2.6 Makine Öğrenmesi Model Eğitiminde Kullanılan Bilgi Sistemleri

Makine öğrenmesi model eğitiminde kullanılacak bilgi işlem altyapısı eğitim sürecinin karmaşıklığına, veri setinin boyutuna ve model türüne bağlıdır. Makine öğrenmesi ile bir sorunu çözme süreci sorunla ilgili veri toplamayla başlar. Ardından elde edilen veri üzerinde analiz işlemleri yapılır. Bu aşamada standart düzeyde bir bilgisayarda Jupyter notebook, Python veya R dilleri kullanılarak veri üzerinde işlem yapılabilir. Bu aşamada bilgisayar donanımının işlemci (CPU), RAM ve hard disk kapasitesi önemlidir ve grafik işlemci ünitesi (GPU) gereksinimi olmayabilir. Veri hazırlığı aşamasında veri üzerinde çeşitli düzeltme, biçimlendirme, temizleme işlemleri yapılabilir. Bu işlemler işlemci, giriş-çıkış (I/O) yoğun işlemlerdir ve çoğunlukla matris hesaplama gibi matematiksel işlem gerektirmez. Veri hazırlama işlemlerinin ardından modelin eğitim sürecine geçilir.

Model eğitimi sürecinde grafik işlemci ünitelerine (GPU) ihtiyaç duyulmaktadır. Bu noktada modelin iyileştirme adımlarında kıyaslama amacıyla bir temel (baseline) model belirlenir. Bu yolla performans çıktıları baseline modelle kıyaslanabilir. Model eğitimi sürecinde basit modeller ve küçük veri setlerinde yalnızca işlemci (CPU) yeterli olabilmekle beraber büyük ölçekli makine öğrenmesi ve derin öğrenme eğitim ve tahminleme (inference) işlemleri için yalnızca CPU kullanımı yeterli olmayabilir, gelişmiş paralel işlem yetenekleri olan GPU veya özel hızlandırıcılar kullanmak gerekir.

Makine öğrenmesi yöntemleri temelinde matris hesaplama işlemleri bulunmakta ve makine öğrenmesi yöntemleri, büyük boyutlu matrislerin işleme girmesi, matrislerle çarpma işlemi yapılmasına dayanmaktadır. Bu işlemler ise grafik kartlar üzerinde rahatlıkla yapılabilir. Grafik kartlarındaki paralel işlem birimleri sayesinde büyük boyutlu işlemler gerçekleştirilebilmektedir. Bununla beraber modern altyapılarda özellikle makine öğrenmesi işlemleri için geliştirilmiş sistemler bulunmaktadır. Ayrıca eğitilen modelin eğitildiği donanım ile çalıştığı donanım farklı olabilir. Örnek olarak eğitilen model bir mobil uygulama ise mobil donanımda çalışabilecek uyuma sahip olmalıdır. Bugün mobil cihazlarda çalışabilecek yapay zeka işlemcileri de geliştirilmiştir.

Bazı makine öğrenmesi tabanlı uygulamalar bulut ortamında grafik kartı (GPU) ile model eğitime tabi tutulup, işlemci (CPU) ile çıkarım (inference) yaparak maliyeti düşürme yoluna gidebilmektedir. Bulut platformlarında bazı büyük teknoloji şirketleri kendi yapay zekaya özel işlemcilerini geliştirmiştir. Google Tensor Processing Unit (TPU), Amazon'un Tranium olmak üzere her biri kendi içinde çeşitli yetenek avantajı ve dezavantajları barındırmaktadır (Palat, 2022).






3. İNCELENEN YAYINLAR

Deprem sonrası binaların yerlerinin belirlenmesi ve hasar tespitinde kullanılan makine öğrenmesi yöntemleri ve bu yöntemlerin performansları ile ilgili akademik çalışmalar incelenmiştir. Bu bölümde incelenen çalışmalarda kullanılan algoritmalar ve makine öğrenmesi modeli geliştirme süreçleri ile uygulanan iyileştirme yöntemleri yer almaktadır. Bu kapsamda incelenen makaleler numaralandırılarak başlık, yazar ve yayımlandığı dergilerle birlikte ekler bölümünde çizelge A.1’de sunulmuştur.


Deprem sonrası binaların yerlerinin belirlenmesi ve hasar tespiti ile ilgili makalelerin bulunması sürecinde Web of Science portalında “building damage detection” ve “machine learning” ifadeleri AND bağlacı ile birleştirilip makale filtresi kullanılarak tarama yapılmıştır. Tarama sonucu 2020 ve 2025 yılları arasında bulunan makale (article) türündeki çalışmaların çoğunluğu 2024 yılında yayınlanmış ve “Remote Sensing” kategorisinde yer almaktadır. Yayımlanan araştırmaların bulunduğu kategorilerin sıralamasına ilişkin liste Çizelge 3.1’de gösterilmiştir; ayrıca Şekil 3.1’de grafik gösterimi bulunmaktadır. Yıllara göre yayınlanan makale sayıları ise Şekil 3.2’deki grafikte gösterilmiştir. Şekil 3.3’te ise araştırma sonucu bulunan makalelerin yayımlandığı alanların gösterildiği VOSviewer aracı kullanılarak elde edilen co-occurrence analizi şeması bulunmaktadır.

Çizelge 3.1 : Yayınlarla ait araştırma kategorileri ve makale sayıları.


Web of Science Kategorisi	Makale Sayısı
Remote Sensing	33
Imaging Science Photographic Technology	24
Geosciences Multidisciplinary	20
Environmental Sciences	14
Engineering Electrical Electronic	10
Geography Physical	10
Engineering Civil	9
Construction Building Technology	5



Şekil 3.1 : Tarama sonucu bulunan yayınların kategorilere göre dağılım grafiği.



Şekil 3.2 : Tarama sonucu bulunan yayınların yıllara göre dağılımı.



Şekil 3.3 : Çalışmaların yayınlandığı alanları gösteren VOSviewer co-occurrence analizi şeması

3.1 Yayın 1: Gerçek Zamanlı Derin Öğrenme Modeli ile Hasar Tespiti

3.1.1 Amaç


Bu yayında (Y. Wang vd., 2023) bir derin öğrenme modeli geliştirilerek bu derin öğrenme modelinin insansız hava aracı (İHA) üzerinde gerçek zamanlı bir şekilde çalışarak, deprem sonrası yıkılan binaların konumunun tespit edilmesi amacıyla yeni bir derin öğrenme modeli önerilmiştir.

3.1.2 Kullanılan algoritmalar

Bu makalede derin öğrenme tabanlı bir algortima değiştirilerek Şekil 3.5'deki mimariye sahip DBYOLOv5 isminde yeni bir model geliştirilmiştir. Bu çalışmada kullanılan model U-net tabanlı bir derin öğrenme modeli olan YOLO'nun 5. Sürümüdür (YOLOv5).

3.1.3 Yöntemler

Bu çalışmada öncelikle geliştirilmek istenen modelin İHA üzerinde çalışması hedeflendiği için düşük güç gerektiren bir işlemci üzerinde çalışabilmesi amaçlanmıştır. Bu nedenle varolan YOLOv5 modelinin üzerinde çeşitli düzenlemeler yapılarak modelin amaca uygun bir yapıya ulaşmasına çalışılmıştır.




Şekil 3.4 : YOLOv5 mimarisi.

Burada yapılan iyileştirmeler; YOLOv5'in mimarisi (Şekil 3.4'de gösterilmiştir), Hibrit Artık Genişletilmiş Evrişim (Residual Dilated Convolution - Res-DConv) modülü eklenerek değiştirilmiş ve orijinal YOLOv5'te bulunan odak modülü çıkarılmıştır. Bu sayede, modelin karmaşıklığı azaltılarak gömülü cihazlarda daha verimli bir şekilde çalışabilmesi sağlanmıştır. Modelde, uzamsal ve kanal (yani görüntüdeki x-y koordinatları ve RGB renk kanallarının öne çıkarılmasıyla ilgili) dikkat mekanizmasına dayalı bir özellik birleştirme yöntemi kullanılmıştır. Bu yöntem, İHA uçuşu sırasında farklı ölçeklerdeki -farklı yükseklikteki ve farklı yüksekliklerden alınan görüntülerdeki binalara ait görüntülerin işlenmesini - daha verimli hale getirmiştir.

Hasarlı bina sınıflandırması için tam bağlı (fully connected - fc-head) ve sınırlayıcı kutu regresyonu (bounding box regression-modelin hedef pikseldeki görüntüyü diktörtgen içine alarak bina olan yerin tahmin edilmesine dayanan regresyon işlemi) için evrişimsel başlık (conv-head (CNN katmanları) kullanılmıştır. Bu değişiklikler, hasarlı bina bölgelerinin sınıflandırma ve konumlandırma doğruluğunu artırmıştır.


Modeli değerlendirme amacıyla deprem sonrası İHA görüntülerinden oluşan bir veri seti kullanılmıştır.



Şekil 3.5 : Değiştirilmiş DB-YOLOv5 mimarisi.

3.1.4 Sonuçlar

YOLOv5 mimarisi üzerinde düzenlemelerle modelin amaca uygun olarak daha az karmaşık ve düşük işlemci gücü gerektirecek şekilde çalışması sağlanmıştır. YOLOv5'te bulunan bazı modüller çıkarılıp modelin karmaşıklığı azaltılmış. Ayrıca İHA uçuşu sırasında elde edilen görüntülerde daha verimli çalışması amacıyla farklı irtifalardan alınan görüntülerdeki nesnelerin tespitini iyileştirecek özellik birleştirme yönteminden faydalanılmıştır. Yapılan düzenlemeler ve iyileştirmeler sayesinde modelin yüksek verimle çalışması sağlanabilmektedir. Test sonuçlarında %96 kesinlik (precision), %94 doğruluk (accuracy) sonucuna ulaşılmış. Geliştirilen modelin diğer YOLO versiyonlarla kıyaslandığı tablo çizelge 3.2'de verilmiştir. Şekil 3.6'da yöntemin uygulamalı olarak hasar tespit performansı gösterilmiştir.



Şekil 3.6 : Yöntemin uygulama performansı. (a: Afet öncesi, b: Afet sonrası, c: ground truth, d: yöntemin tespit ettikleri (kırmızılar doğru tespit edilenler))

Çizelge 3.2 : DB-YOLOv5 modelinin ve diğer YOLO versiyonlarının performans kıyaslaması.

YOLO Versiyonu	Kesinlik (Precision) (%)	Duyarlılık (Recall) (%)	F1 Skoru (%)	mAP
YOLOv3	84.62	90.67	87.54	98.00
YOLOv4	75.96	70.54	73.15	81.00
YOLOv4-tiny	93.10	98.18	95.58	99.00
YOLOv5s	92.75	91.47	94.08	99.50
DB-YOLOv5s	96.36	94.38	95.34	99.50

3.2 Yayın 2: Derin Öğrenme ile Bina Hasar Değerlendirmesi

3.2.1 Amaç

Bu çalışmada (Xia vd., 2023) deprem sonrası bina konumlarının tespiti ve hasar derecesinin elde edilmesi amacıyla deprem öncesi ve sonrası yüksek çözünürlüklü uydu görüntüleri kullanılarak yeni bir derin öğrenme modeli önerilmiştir. Önerilen BDANet isimli CNN (Convolution Neural Network) modeli, bina konumlarının tespiti ve bina hasar derecelerinin bulunması üzerine eğitilmiştir.

3.2.2 Kullanılan algoritmalar

Bu makalede CNN tabanlı Şekil 3.8’de görülebilen BDANet isimli iki aşamalı bir derin öğrenme modeli kullanılmıştır. İki aşamalı çalışan modelde ilk aşamada bina konumu tespit edilir. Bu aşamada U-net derin öğrenme mimarisinden faydalanılmıştır. U-net görüntü segmentasyon işlerinde kullanılmak üzere geliştirilmiş bir derin öğrenme mimarisidir (Siddique vd., 2021). İkinci aşamada ise afet öncesi ve sonrası görüntülerin analiz edilerek bina hasar derecesi üzerine CNN tabanlı farklı modüller dahil ediliyor. Bu sayede modelin veriminin artırılması mümkün olmuştur.

3.2.3 Yöntemler

Bu çalışmada Kahramanmaraş depremlerinde Islahiye bölgesinden elde edilen afet öncesi ve sonrası yüksek çözünürlüklü WorldView2 uydu görüntüleri kullanılmış. İki aşamalı BDANet CNN (Convolutional Neural Network) makine öğrenmesi modeli kullanılarak xBD metre altı bina hasar veri seti kullanılarak eğitilmiştir. xBD veri seti, bina segmentasyonu ve hasar değerlendirme için halka açık, büyük ölçekli bir uydu

görüntü veri setidir. Bu veri seti, felaketlerden önce ve sonra binaların yüksek çözünürlüklü küresel görüntü çiftlerini ve bunlara ait anotasyonları sunar. Her bir görüntü 1.024×1.024 piksel boyutunda olup, 0.8 m çözünürlükte üç RGB bandı içerir. Veri seti, 19 farklı felaket örneğinden oluşmaktadır. Veri setinin dengeli hale getirilmesi için Cutmix tekniği kullanılarak veri zenginleştirme ve çeşitlendirme yapılmıştır. Cutmix, iki farklı görüntüyü birleştirerek, bir görüntünün belirli bir kısmını kesip, diğer görüntüye yapıştırmak üzerine kuruludur. Bu yöntem, modelin daha genel özellikler öğrenmesine ve aşırı öğrenmeyi (overfitting) azaltmasına yardımcı olur.

İki aşamalı olarak gerçekleşen model eğitiminde ilk aşamada U-net mimarisi kullanılarak afet öncesi binaların tanımlamasına çalışılmıştır. Bu mimaride bulunan zıplama bağlantı katmanı (jump connection layer), orijinal görüntü özelliklerini koruyarak bunları sonraki katmanlarda çıkarılan özelliklerle birleştirebilir. Bu özellik sayesinde, gradient explosion (gradyan patlamaları gibi sorunları etkili bir şekilde önler. Bu katman (zıplama bağlantı katmanı (jump connection layer)), derin öğrenme katmanlarında, ağırlık erken katmanlarından (genellikle daha yüzeysel özelliklerin çıkarıldığı yerlerden) gelen bilgilerin, daha derin katmanlara doğrudan iletilmesini sağlar. Bu şekilde önemli ayrıntıların kaybının önlenmesi sağlanabilir.


İkinci aşamada afet öncesi ve sonrası görüntülerden oluşan veri setleri kullanılmış. İkinci aşamada, birinci aşamada elde edilen model eğitim ağırlık parametreleri kullanılmıştır. Bu kısımda BDANet modeline Çok Ölçekli Özellik Birleştirme Modülü-Multi-Scale Feature Fusion (MFF) dahil edilerek çeşitli boyutlardaki binaların karakteristiklerini ve özelliklerini anlayarak modelin dayanıklılığını artırmak amaçlanmıştır. MFF modülü farklı boyutlardaki nesnelerin tanınmasını ve segmentasyonunun başarılı bir biçimde yapılabilmesi için kullanılır. Bu modül eğitimde kullanılacak görüntünün orijinal, %50 küçültülmüş ve %25'e küçültülmüş 3 farklı boyutunun bir CNN katmanından geçirilerek, görüntüye ait nesne kenarları renkleri ve daha detaylara ait özellik haritası matrislerinin çıkarılması sağlanır. Bu şekilde farklı ölçülerde modelin öğrenme kabiliyeti geliştirilmiş olur.

Sonraki safhada BDANet modelinin ikinci aşamasında, afet öncesi ve sonrası görüntüler arasındaki ilişkileri daha derinlemesine incelemek için kullanılan bir optimizasyon yöntemi kullanılıyor. Model, Sıkıştırma Uyarımı (SE) yöntemine dayanan bir CDA (Channel and Spatial Dimension Attention) modülü kullanıyor. Bu modül, görüntülerin hem kanal (channel) hem de uzaysal (spatial) boyutlardaki


özelliklerini yeniden düzenleyerek, daha zengin bir bilgi akışı sağlıyor. Bu sayede, afet öncesi ve sonrası görüntülerdeki özellikler birleştirilip modelin doğruluğu artırılıyor. Bu modüldeki kanal yani RGB renk kanallarından hangisinin önemli olduğunu ya da uzaysal özellikler yani önemli görülen bölgeye ait piksel konumlarının ağırlıklandırılması ile hassasiyetin artırılması için kullanılıyor. Örnek olarak hasarlı bölgenin belirli bir özelliğine ait RGB kanal bilgisi ve X-Y koordinat bilgileri ağırlıklandırılıyor.

3.2.4 Sonuçlar

Bu çalışmada önerilen modelin bina konumlandırma doğruluğunu optimize edilerek bina hasar analizlerinde yüksek duyarlılıkla sonuçlar üretilmiştir. Şekil 3.7’de örnek hasarlı bina sonuç görseli bulunmaktadır. Çizelge 3.3’deki gibi diğer modellerle de kıyaslandığında benzeri sonuçların elde edildiği görülebilir. Değerlendirme sonuçlarına göre %80,43 doğruluk (accuracy) ve %84,17 duyarlılık (recall) elde edilmiştir.



Şekil 3.7 : BDANet hasarlı bina tespit sonuç görseli.



Şekil 3.8 : İki aşamalı BDANet derin öğrenme modeli mimarisi.

Çizelge 3.3 : BDANet modeli kesinlik (precision) ve hassasiyet (recall) oranlarının diğer derin öğrenme modellerine ait sonuçlarla kıyaslaması.

Derin Öğrenme Yöntemi	Kesinlik (Precision) (%)	Duyarlılık (Recall) (%)
VGG16-UNet++	81.53	86.19
ResNet50-UNet++	84.43	88.65
InceptionV3-UNet++	85.14	90.50
BDANet Stage1 (bu çalışma)	80.43	84.17

3.3 Yayın 3: SAR Verisi ve Makine Öğrenmesi Kullanılarak Hasar Tespiti

3.3.1 Amaç

Bu çalışmada (Rao vd., 2023) yüksek çözünürlüklü SAR (sentetik açıklıklı radar) verisi ve makine öğrenmesi yöntemleri kullanarak bina hasar derecesi tespiti yapılmaya çalışılmıştır. SAR görüntüleri, deprem şiddet haritaları ve bina envanteri verilerini birleştirerek hem ikili (hasarlı/hasarsız) hem de çok sınıflı hasar tahmini yapılmış. Sonuçlar, saha anket verileriyle karşılaştırılarak modelin doğruluğu değerlendirilmiştir.

3.3.2 Kullanılan algoritmalar

Çalışmada, dört büyük deprem incelenerek binaların hasar seviyelerini belirlemek için Random Forest (RF) ve Support Vector Machines (SVM) algoritmalar kullanılmış.

3.3.3 Yöntemler

Bu makalede makine öğrenmesi modellerinin performansını artırmak için çeşitli optimizasyonlar yapılmıştır. Özellikle, modelin doğruluğunu artırmak için özellik seçimi gerçekleştirilmiş, önemli olan SAR görüntü parametreleri öne çıkarılmıştır. Ayrıca, sınıflandırmada kullanılan parametrelerin dengelenmesi amacıyla veri normalizasyonu (yani farklı ölçülmüş verilerin -mesela SAR yansıma değeri- standart bir aralığa indirgenmesiyle sınıflandırma modelinin daha doğru ve dengeli sonuç vermesi) uygulanmış ve farklı sınıflandırıcılar (Random Forest ve SVM) karşılaştırılarak en iyi performans veren model seçilmiştir. Çapraz doğrulama-cross validation teknikleri kullanılarak (test verisinin farklı katmanlara ayrılarak modelin eğitilmesi - k-katlı çapraz doğrulama) modelin genellenebilirliği de artırılmıştır, aşırı öğrenmenin (overfit) önüne geçilmesi sağlanır.

3.3.4 Sonuçlar

Makalede Random Forest (RF) algoritması, bina hasar tespitinde en iyi performansı gösteren algoritma olarak öne çıkmıştır. RF, özellikle çoklu sınıflandırma görevlerinde daha yüksek doğruluk ve daha iyi genellenebilirlik sağlamıştır. Destek Vektör Makineleri (SVM) de incelenmiş olsa da, RF daha başarılı sonuçlar vermiştir.

Sonuç olarak farklı depremlerde test edildiğinde örnek olarak 2020 Zagreb depreminde modelin doğruluğu (accuracy) %73, makro ortalama F1 skoru %33, ve

ağırlıklı ortalama F1 skoru %79 olarak hesaplanmıştır. Hasar sınıflandırma görseli de Şekil 3.9’da bulunmaktadır. Buradaki makro ortalama dengesiz sınıflandırılmış veri setlerinde nadir görülen sınıfların tahminlerine yönelik performansı da anlama amacıyla kullanılır. Her sınıfın (yani hasarsız, az hasarlı vs) gibi F1 skorunun ortalaması alınarak hesaplanır.



Şekil 3.9 : Modelin Zagreb depremi sonrası 3 boyutlu hasarlı bina sınıflandırma haritası.

3.4 Yayın 4: Uydu Görüntüleri ve Derin Öğrenme ile Hasar Tespiti

3.4.1 Amaç

Deprem sonrası yüksek çözünürlüklü uydu görüntülerinin kullanıldığı bu makalede (Abdi vd., 2021) önceden eğitilmiş ve özelleştirilmiş bir ResNet-34 derin öğrenme mimarisi kullanarak hasar gören binaların tespitine çalışılmıştır. Deprem öncesi görüntülerin elde edilmesinin zor olması ve deprem öncesi ile sonrası görüntüler arasındaki hatalar nedeniyle deprem sonrası görüntüler üzerinden tespit yapılması amaçlanmıştır.

3.4.2 Kullanılan algoritmalar

Bu makalede ImageNet veri setiyle eğitilmiş ResNet 34 (34 katmanlı residual network - artık bağlantılı sinir ağı) mimarisi özelleştirilerek kullanılmıştır.


3.4.3 Yöntemler

Makalede, ResNet-34 modelinin son üç katmanı çıkarılmış ve yerine yeni bir sınıflandırıcı başlığı eklenmiştir. Bu başlık, hasar tespiti için yüksek seviyeli özellikleri öğrenmek üzere transfer öğrenme yöntemleriyle eğitilmiştir.

ResNet-34, derin öğrenme modellerinde sıkça karşılaşılan "gradyan kaybolması" problemini çözmek için katmanlar arasında kimlik kısayolu bağlantısı (identity shortcut connection) kullanır.

Yayında kullanılan modelin performansını artırmak için çeşitli yöntemler ve optimizasyonlar uygulanmış. Bu çalışmalardan bazıları şunlardır:

- Veri çoğaltma (data augmentation): Modelin öğrenme kapasitesini artırmak için veri çoğaltma teknikleri kullanılmış. Bu teknikler, eğitim verisinin genelleştirilmesine yardımcı olur. Makalede şu veri çoğaltma yöntemleri uygulanmıştır:
 - Görüntülerin sıfır dolgusu ve ölçeklendirilmesi.
 - Rastgele dönüşüm (dönüş açısı -10 ile +10 derece arasında, verinin %75'lik kısmında).
 - Görüntülerin dikey ve yatay olarak rastgele çevrilmesi (verinin %50 lik kısmında).
 - Parlaklık ve kontrastın rastgele değiştirilmesi (verinin %75 lik kısmında, maksimum 0.2 parlaklık değişikliği).
- Transfer öğrenme: Şekil 3.10'da görülebileceği gibi ResNet-34 modelinin önceden ImageNet veri seti üzerinde eğitilmiş versiyonu kullanılarak transfer öğrenme uygulanmıştır. Bu, modelin önceden öğrendiği özelliklerin, felaket sonrası hasar tespiti gibi yeni bir göreve uyarlanmasını sağlar. Özellikle, modelin gövdesi dondurulmuş (eğitim sırasında değiştirilmemiş) ve sadece yeni eklenen sınıflandırıcı başlık sıfırdan eğitilmiştir. Bu sayede, daha hızlı ve verimli bir eğitim süreci gerçekleştirilmiştir.




Şekil 3.10 : Önceden eğitilmiş ResNet-34 mimarisi ile bina hasar tespit modeli.

- Süper yakınsama (super-convergence) yöntemi: Modelin eğitimi sırasında, süper yakınsama adı verilen bir yöntem kullanılarak eğitimin daha hızlı tamamlanması sağlanmış. Bu yöntem, öğrenme oranlarının döngüsel bir şekilde değiştirilmesini içerir ve daha kısa sürede modelin optimum performansa ulaşmasına yardımcı olur.
- Kısıtlı veriyle modelin genelleme yeteneğini test etme: Model, farklı afet türlerine ve sınırlı eğitim verisiyle nasıl genelleme yapabildiğini test etmek için Woolsey yangını verileriyle de test edilmiştir. 2010 Haiti depreminden elde edilen eğitim verileri kullanılarak, sınırlı bir miktarda Woolsey yangını verisiyle ince ayar yapılmış ve modelin diğer felaket türlerinde ne kadar iyi genelleme yaptığı değerlendirilmiştir.

3.4.4 Sonuçlar

Çalışmada modelin değerlendirilmesi sonucunda, model yıkılmış ve yıkılmamış bina tespitinde dikkate değer bir avantaj sunmuştur. Çalışmada kullanılan önceden eğitilmiş ResNet-34 mimarisi ile 2010 Havai depremi görüntüleri üzerinde yapılan testlerde %90'ın üzerinde doğruluk (accuracy) elde edilmiştir. Şekil 3.11'de modelin performansına ilişkin görsel bulunmaktadır.



Şekil 3.11 : ResNet-34 yöntemin hasar sınıflandırma performansı: Yeşil renk hasarsız yapıları, sarı renk hasarlı yapıları gösteriyor.

3.5 Yayın 5: Denetimli Öğrenme Kullanılarak Hasarlı Bina Tespiti

3.5.1 Amaç

Bu yayında (Aswitha vd., 2024) denetimli öğrenme yöntemiyle makine öğrenmesi algoritmaları ve deprem sonrası uydu görüntüleri kullanılarak hasarlı binaların tespit edilmesine çalışılmıştır. Bu kapsamda kullanılan farklı makine öğrenmesi yöntemleri kullanılarak bina hasar derecelendirmesi yapılmasında kıyas yapılmıştır.

3.5.2 Kullanılan algoritmalar

Bu çalışmada denetimli öğrenme (supervised learning) yaklaşımının yer aldığı Doğrusal Regresyon (Linear Regression) ve K-En Yakın Komşu (K-Nearest Neighbors, KNN) algoritmaları kullanılmıştır.

3.5.3 Yöntemler

Uydu görüntülerinden PCA (Principal Component Analysis), wavelet transform, spatial filtering yöntemleriyle; elektromanyetik spektrum, şekil ve doku özellikleri, geometrik özellikler ve piksellerin yakınlarındaki piksellerle ilişkileri gibi özellikler çıkarılmıştır.

Doğrusal Regresyon modeli, uydu görüntülerinden elde edilen özellikler ile binaların hasar yüzdesi arasındaki ilişkiyi modellemek için kullanılmıştır. Model, hasar yüzdesini sürekli bir değişken olarak tahmin eder. Yani önceden belirlenmiş hasar sınırlandırma yapmaz; örnek olarak %20 hasarlı gibi bir sonuç verir. KNN Algoritması ise sınıflandırma tabanlı hasar tespiti için kullanılmıştır. Bu algoritma, benzer özelliklere sahip komşu veriler arasında en çok tekrar eden sınıflamayı yaparak hasar derecesini belirler.

Her iki model de uydu görüntülerinden binaların hasar durumlarını tespit etmek ve hasar yüzdesini tahmin etmek amacıyla uygulanmıştır.

Modellerden daha iyi performans elde etmek için uygulanan yöntemler arasında, veri hazırlama işlemleri, gereksiz verilerden kaynaklı gürültüler giderilerek özellik çıkarma çalışmaları, KNN ve doğrusal regresyon algoritmalarında model parametre ayarlamaları, veri setinin dengeli bir hale getirilmesi gibi işlemler bulunmaktadır.

3.5.4 Sonuçlar

Bu çalışmada K-En Yakın Komşu (KNN) algoritması en iyi performansı vermiştir. Özellikle doğrusal olmayan karar sınırlarına sahip veri kümelerinde ve karmaşık desenlerde KNN algoritması, sınıflandırma görevlerinde doğrusal regresyona kıyasla daha iyi sonuçlar göstermiştir. KNN Algoritması; doğruluk (accuracy): %85.7, kesinlik (precision): %81.2, duyarlılık (recall): %87.4, F1-skoru: %84.2 sonuçlarını verirken doğrusal regresyon; doğruluk (accuracy): %82.3 regresyon modeli ölçümünde kullanılan ortalama kare hatası (mean squared error) değeri %15.4, R-kare değeri %78.6 olarak ölçülmüştür.

3.6 Yayın 6: xBD Veri Seti ile Uydu Görüntülerinden Hasarlı Bina Tespiti

3.6.1 Amaç

Uydu görüntüleri kullanılarak deprem sonrası hasarlı bina konumlarını ve hasar derecelerini tespit etme işlemini, özellikle geniş bir bölge için otomatikleştirmenin hedeflendiği bu çalışmada (Chen, t.y.) derin öğrenme tabanlı bir model önerilerek, bu modelin çeşitli afet türlerinde de kullanılabilirliğinin sağlanması amaçlanmıştır.

3.6.2 Kullanılan Algoritmalar

Bu çalışmada derin öğrenme modelleri kullanılmış olup bina segmentasyonunda kullanılan U-net, FPN (Feature Pyramid Networks), PAN (Pyramid Attention Networks) algoritmaları birbiriyle kıyaslanmıştır. Bununla beraber sınıflandırma safhası için VGG16_bn (VGG16 model with batchnorm,) ResNet50, SE ResNeXt50 32x4d ve DenseNet121 derin öğrenme tabanlı kodlayıcılar (encoder) kullanılmıştır.

3.6.3 Yöntemler


Bina tespiti ve hasar sınıflandırılması üzerine xBDSet veri setinin kullanıldığı bu yayında ise U-net, FPN (Feature Pyramid Networks), PAN (Pyramid Attention Networks), ResNet18 modelleri VGG16 bn, ResNet50, SE ResNeXt50 32x4d ve DenseNet121 gibi kodlayıcılar kullanılarak test edilmiştir. Kodlayıcılar makine öğrenmesi mimarilerinde giriş görsel verisinden özellik çıkarma işlemlerinde kullanılıyor, örnek olarak binanın kenarları, gölgeler gibi özellikleri, modele aktarılacak hale getiriliyor. Bunu yaparken de verinin boyutunu küçültüyor ve özetlenmiş bir özellik haritasına indiriyor. Bu çalışmada da daha önceden eğitilmiş VGG16 kodlayıcısı kullanılarak bina segmentasyonunda başarı artırılmış.

Bina segmentasyon-tespitinde en iyi performans, Unet + VGG16 bn kombinasyonundan elde edilmiştir. Çeşitli hata fonksiyonları (loss functions) da denenerek segmentasyon işlemlerindeki hataların optimize edilmesi amaçlanmış, burada da Combo loss fonksiyonu en iyi sonucu sağlamıştır. Bunun yanında yine veri zenginleştirme işlemleri yapılmış ardından sinir ağının beklediği ölçülere görüntü boyutu kırılarak hazırlanmış (128x128 boyutunda ve her renk kanalı için) ve hasar sınıflandırması için U-net'in kodlayıcı kısmı ImageNet veri setinde eğitilmiş Resnet18 ile birleştirilerek hasar tespiti iyileştirilmiştir.

3.6.4 Sonuçlar

Sonuç olarak bina segmentasyonunda U-net modeli ve VGG16 bn kodlayıcısının kullanıldığı durumda, hassasiyet (precision) değeri %85.1, duyarlılık (recall) değeri %83.2 ve F1 skoru %84.1 hesaplanmıştır. Hasar tespitinde ise ortalama hassasiyet

%71, duyarlılık %58 ve F1 skoru %63 bulunmuştur. Şekil 3.12’de yöntemin tahmin performansı gösterilmiştir.



Şekil 3.12 : Unet + vgg16 bn kombinasyonunda bina maskeleme performansı görseli (sırasıyla uydu, tahmin edilen ve doğrulanmış).

3.7 Yayın 7: Derin Öğrenme Tabanlı Bina Tespit ve Sınıflandırma

3.7.1 Amaç

Afet sonrası otomatik ve doğru bir bina hasar tespiti ve hasar sınıflandırması işlemlerinde farklı afet bölgelerinde ve farklı afet türlerinde daha başarılı sonuç alabilmek için derin öğrenme tabanlı yeni bir algoritma geliştirilmiştir.

3.7.2 Kullanılan algoritmalar

Bu çalışmada (Zhao vd., 2024) derin öğrenme yöntemi olan ECADS-CNN isimli bir model öneriliyor. U-Net mimarisini temel alan bu model, bina segmentasyonu ve hasar sınıflandırması için Efficient Channel Attention (ECA) ve Depthwise Separable (DS) modüllerini birleştiriyor.

3.7.3 Yöntemler

Bu çalışmada geliştirilen ECADS-CNN modeli Efficient Channel Attention (ECA) ve Depthwise Separable (DS) modüllerinden meydana geliyor. ECA modülü, kanallar arası dikkat mekanizmasını (RGB renk kanallarından önemli olanı öne çıkarma


işlemleriyle modelin performansını arttırmak) geliştirirken, DS modülü parametre sayısını düşürerek hesaplama yükünü azaltıyor.

Bu modüller, ağın doğruluğunu artırmak ve işlem süresini kısaltmak için kullanılıyor. Ayrıca, model, Siamese sinir ağı ile çift görüntü kullanarak; afet öncesi ve sonrası görüntülerin özellikleri, aynı parametrelere sahip sinir ağından paralel bir biçimde geçirilerek özellikler arasındaki farklar hesaplanıyor ve hasar sınıflandırması yapıyor.

3.7.4 Sonuçlar

ECADS-CNN modeli ResNet tabanlı SE_ResNeXt50 modeli temel alınarak kıyaslanmış. Mevcut modellere göre daha hızlı ve yüksek doğrulukla çalışmış. Farklı afet senaryolarında test edilmiş ve genel yüksek performans göstermiştir.

ECADS-CNN modeli segmentasyon işlemi için F1 skoru %82.14, hassasiyet %84.26 ve duyarlılık %86.74 olarak hesaplanmıştır. Hasar sınıflandırmasında ise F1 skoru %75, hassasiyet %77 ve duyarlılık değeri yaklaşık %75 olarak hesaplanmıştır. Yöntemin performansı, diğer yöntemlerle karşılaştırmalı olarak Şekil 3.13’de gösterilmiştir.



Şekil 3.13 : ECADS-CNN yöntemi hasar tespit performansının diğer yöntemlerle kıyaslaması.

3.8 Yayın 8: Hava Fotoğrafları ve Makine Öğrenmesi ile Bina Hasar Tespiti

3.8.1 Amaç

Deprem sonrası elde edilen hava fotoğraflarının kullanıldığı bu çalışmada (Naito vd., 2020) 2 ayrı makine öğrenmesi modeliyle hasarlı binaların hasarsız, az hasarlı, orta hasarlı, çok hasarlı olmak üzere 4 gruba sınıflandırılması amaçlanmıştır.

3.8.2 Kullanılan algoritmalar

Bu çalışmada Bag-of-Visual-Words (BoVW) isimli makine öğrenmesi algoritması ile yapay sinir ağı tabanlı (CNN - Convolutional Neural Network) iki ayrı model geliştirilmiştir. Ayrıca BoVW algoritmasıyla hasar sınıflandırması için SVM (support vector machines) algoritması kullanılmıştır.

3.8.3 Yöntemler

Çalışmada modellerin eğitilmesi için kullanılan veri setleri hava fotoğraflarından elde edilmiş. Sonrasında bu hava fotoğrafları 80x80 piksellik parçalara bölünerek içermiş oldukları bina ve ona ait çatı görüntüsü veya bina olmayan yapılar şeklinde etiketlenerek eğitim veri seti haline getirilmiş. Ahşap binalar için önceden üretilmiş bir desen listesi referans olarak alınarak, buradan hasar tespiti için özellik çıkarımında kullanılmıştır.

Elde edilen hasar tespit modeli, sismik veriler ile ilişkilendirilip gerçek zamanlı olarak hasar tespiti için de kullanılması planlanmış.

Burada Bag-of-visual-words (BoVW) makine öğrenmesi modeli ile Visual Geometry Group (VGG) modeline dayanan bir Convolutional Neural Network (CNN) modeli denenmiştir.


Görüntülerden özellik çıkarımı için Scale-Invariant Feature Transform (SIFT) algoritması kullanılmıştır. Bu algoritma, görüntülerin ölçek, döndürme ve aydınlatma koşullarına karşı dayanıklıdır. Çıkarılan özellikler, k-means kümeleme yöntemiyle 1000 kümeli görsel kelimelere dönüştürülmüş ve bu kelimelerin frekansları ile sınıflandırma yapılmıştır. Hasar derecesi sınıflandırması içinse Support Vector Machine (SVM) algoritması kullanılmış.

CNN modeli hem doğruluk oranı hem de hız açısından Bag-of-visual-words'den daha iyi performans göstermiştir. CNN modelinde yeni katmanlar eklenerek, veri zenginleştirme (data augmentation) işlemleri yapılarak, aşırı öğrenme (overfitting)


engellenmesi, gradyan kaybolması (gradient vanishing) gibi sorunların önüne geçilmiştir.

3.8.4 Sonuçlar

Sonuç olarak Bag-of-visual-words modeline dayanan model için, farklı hasar seviyelerindeki duyarlılık (recall) oranları yaklaşık olarak %39 ile %60 arasında değişmekte, kesinlik (precision) oranları ise %45 ile %67 arasında değişmektedir ve genel doğruluk (accuracy) oranı yaklaşık %57'dir. Diğer yandan, CNN modeline dayanan modelde, farklı hasar seviyelerindeki duyarlılık (recall) oranları yaklaşık olarak %81 ile %92 arasında, kesinlik (precision) oranları ise %78 ile %92 arasında değişmekte ve genel doğruluk (accuracy) oranı yaklaşık %88'dir. Şekil 3.14 ile Şekil 3.15'te sırasıyla gerçekte tespit edilen hasarlı yapılar ile CNN yöntemiyle tespit edilmiş yapılar gösterilmiştir.



Şekil 3.14 : Gerçekte belirlenen hasarlı yapılar.



Şekil 3.15 : CNN yöntemiyle yapılan hasar tespiti.

3.9 Yayın 9: Derin Öğrenme Tabanlı Semantik Segmentasyon Modelleri

3.9.1 Amaç

Derin öğrenme tabanlı segmentasyon modellerinin uygulandığı bu çalışmada (Hacıfendioğlu vd., 2024) uydu görüntüleri üzerinden otomatik olarak 6 Şubat 2023'te Türkiye'deki depremlerin ardından yıkılan binaların tespitine çalışılmış. Farklı derin öğrenme modelleri denenerek bina konumlarının tespiti ve hasar sınıflandırılması işleminin hızlı ve doğru bir biçimde yapılması amaçlanmıştır.

3.9.2 Kullanılan algoritmalar

Derin öğrenme tabanlı semantik segmentasyon modellerinden dört farklı model U-Net, LinkNet, FPN, PSPNet değerlendirilmiştir.


3.9.3 Yöntemler

Yayında yapılan makine öğrenmesi optimizasyonları, farklı modellerin karşılaştırılması ve performanslarının iyileştirilmesi üzerine odaklanmaktadır. Optimizasyon sürecinde, veri ön işleme adımları (örneğin, görüntü normalizasyonu) uygulanmış ve farklı modellerin hiperparametre ayarları optimize edilmiştir. FPN

modelinin, daha iyi doğruluk ve kesinlik sağladığı görülmüştür. U-Net ise recall (duyarlılık) ve F1 skorlarında öne çıkmıştır. Ayrıca, çok sayıda uydu görüntüsü kullanılarak modelin performansı artırılmıştır. Bu çalışma, kodlayıcı seçiminin modellerin performansında önemli bir etkisi olduğunu göstermiştir. ImageNet ile eğitilmiş ResNet18 gibi bir modelde, kodlayıcının model performansına önemli bir katkısı olduğu görülmüştür.

3.9.4 Sonuçlar

Bu çalışmada FPN modeli sırasıyla %97 ve %77 ile en yüksek doğruluğu ve kesinliği sağlarken, U-Net modeli sırasıyla %46.6 ve %56.5 ile en iyi duyarlılık ve F1 skorlarını elde etmiştir. Şekil 3.16'da kıyaslamalı olarak hasar tespit performansları gösterilmiştir.



Şekil 3.16 : U-net, LinkNet, FPN ve PSPNet yöntemleriyle yapılmış hasar tespitleri ve IoU değerleri.

3.10 Yayın 10: Random Forest Sınıflandırıcısı ile Hasarlı Bina Tespiti

3.10.1 Amaç

Volkan tsunamisi sonrası random forest algoritması ve nesne tabanlı teknikler kullanılarak hasar gören binaların tespiti amaçlanmıştır. Bu çalışmada (Virtriana vd., 2023) geometrik, istatistik, doku, bitki örtüsü indisi türündeki tahmin sınıflandırıcıları ile random forest algoritması kombine edilerek değerlendirilmiştir.

3.10.2 Kullanılan algoritmalar

Bu çalışmada makine öğrenmesi yöntemi olarak random forest sınıflandırıcı algoritması kullanılmıştır.


3.10.3 Yöntemler

Araştırmada random forest sınıflandırıcısı ve 14 farklı senaryo ile bina hasarlarını tespit etmek için uydu görüntüleri kullanılmıştır. Bu sonuçlar xBD, Copernicus ve saha verileriyle karşılaştırılmış, random forest algoritmasının doğruluğu ölçülmüştür. Geometrik yöntem tahminçileri, binaların şekil özellikleri kompaktlık, dikdörtgensellik, çevresellik gibi parametreleri kullanarak binaların sınırlarını belirler ve hasar tespit edilmiştir. İstatistiksel yöntemle, görüntü piksellerindeki minimum, maksimum, ortalama ve standart sapma gibi istatistiksel değerler üzerinden çalışarak piksel yoğunluklarına göre hasar tespiti yapılmıştır. Doku tahminçileri; görüntünün dokusal özelliklerini, gri tonlama ve pikseller arası kontrast gibi parametrelerle analiz ederek, yüzey yapısındaki değişikliklerle bina hasarı sınıflandırılmıştır. Bitki örtüsü indisi ile de bitki örtüsü ve bina ayrımı yapılara hasar tespitinde kullanılmıştır. Örnek olarak ele alınan bir poligonda, bitki örtüsü indexi ile bitki örtüsü veya bitki örtüsü olmadığı tespit edilebilir. Random forest algoritması dört tür tahmin edici (geometrik, istatistiksel, doku ve vejetasyon indeksi) kullanarak 14 farklı senaryoda bina hasarını sınıflandırmak için eğitilmiştir. Her sınıf için veriler rastgele ayrılmış, %70'i eğitim, %30'u test için kullanılmıştır.

3.10.4 Sonuçlar

Özellikle bitki örtüsü indeksi ve doku tahminçilerinin kombinasyonu kullanılarak eğitilen modelde Copernicus uzaktan algılama verileri ile karşılaştırıldığında %95.9 doğruluk (accuracy) ve %78.3 F1 skoru elde etmiştir. Bu kombinasyon, bina

hasarlarını tespit etmede diğer algoritmalar ve senaryolardan daha başarılı olmuştur. Ayrıca, geometrik, istatistiksel ve doku tahmincileri de bazı verilerle iyi sonuçlar sağlamıştır, ancak en yüksek performans bitki örtüsü ve doku kombinasyonundan gelmiştir. Şekil 3.17’de random forest ile hasar sınıflandırması performansı gösterilmiştir.



Şekil 3.17 : Random forest ile hasar sınıflandırması performansı.

3.11 Yayın 11: Derin Öğrenme Algoritması ile Deprem Sonrası Hasar Tespiti

3.11.1 Amaç

U-net tabanlı bir derin öğrenme modelinin geliştirildiği bu çalışmada (Mangalraj vd., 2022) deprem sonrası hasarlı binaların tespitinde hızlı ve doğru sonuçlar alınarak afet sonrası müdahalenin iyileştirilmesi amaçlanmıştır.

3.11.2 Kullanılan algoritmalar

Bu çalışmada değiştirilmiş bir U-net mimarisinden geliştirilen bir derin öğrenme modeli kullanılmıştır.

3.11.3 Yöntemler

Yayında deprem öncesi ve sonrası elde edilen uydu ve insansız hava aracı görüntüleri kullanılarak U-net mimarisinin özelleştirilmiş bir versiyonu ile hasar tespiti üzerine çalışılmıştır.

U-Net, simetrik bir yapıya sahip olup, iki ana bölümden oluşur: daraltıcı yol (contractive path) ve genişletici yol (expansive path). Daraltıcı yol, görüntülerin boyutlarını küçülterek önemli özelliklerin çıkarılmasını sağlarken, genişletici yol ise bu özellikleri kullanarak yeniden görüntü boyutlarını artırır ve hassas konumlandırma sağlar.

Çalışmada modelin performansını değerlendirmek için iki farklı metrik kullanılmıştır: Jaccard Index'i (Intersection over Union – IoU) ve Dice Katsayısı (F1 Skoru). Bu metrikler, modelin doğruluk performansını artırmak için kullanılmıştır. Jaccard İndeksi, segmentasyon işlemlerinde sıkça kullanılan bir metrik olup, modelin hangi oranda doğru tahmin yaptığını ölçer. Dice Katsayısı (F1 Skoru); iki farklı segmentasyon arasındaki örtüşmeyi ölçer ve genellikle sınıflandırma problemlerinde kullanılır.

Yapılan analizler sonucunda, Jaccard İndeksi kullanılarak eğitilen modelin daha güvenilir ve verimli sonuçlar ürettiği görülmüştür. Bu, daha iyi hasar tespiti ve bina segmentasyonu sağlamıştır.

Bununla beraber model, 0.001 ve 0.01 olmak üzere iki farklı öğrenme oranı ile eğitilmiştir. Deneyler sonucunda, daha düşük öğrenme oranı (0.001) kullanıldığında modelin doğruluk oranının arttığı gözlemlenmiştir. Bu durum, daha düşük öğrenme oranının modelin kayıp eğrisinde daha dengeli ilerlemesini sağladığı ve optimum sonuçlara ulaşmasına yardımcı olduğu anlamına gelir. 0.001 öğrenme oranı ile daha yavaş ve dengeli bir öğrenme sağlayarak modelin daha doğru sonuçlar üretmesine olanak tanımıştır.

Model, farklı batch boyutları (16 ve 32) ve 15 epoch kullanılarak eğitilmiştir. Bu parametreler, modelin öğrenme hızını ve doğruluğunu doğrudan etkileyen faktörlerdir. Ayrıca, eğitim sürecinde callback fonksiyonu eklenmiştir; bu fonksiyon, validasyon

verisi doğruluğu sabit kaldığında öğrenme oranını düşürerek modelin performansını artırmıştır.

Modelin eğitimi sırasında ağırlıkların güncellenmesinde Adam (Adaptive Moment Estimation) optimizatörü kullanılmıştır. Adam optimizatörü, özellikle büyük ve karmaşık veri setlerinde iyi performans gösteren bir optimizasyon algoritmasıdır. Hızlı ve dengeli öğrenme sağlamaıyla, özellikle gürültülü görüntülerle çalışırken başarılı sonuçlar elde edilmesini sağlamıştır. Her öğrenme adımında öğrenmenin iyileştirilmesi maksadıyla ağırlık parametrelerinin güncellenmesinde kullanılır.

3.11.4 Sonuçlar

Çalışmada test ve doğrulama verisi sonuçlarında Jaccard Index'i kullanıldığında en iyi performansın elde edildiği görülmüştür. Bu durumda test verisinde %59.6 ve doğrulama verisinde %61.18 doğruluk değerine ulaşılmıştır.

3.12 Yayın 12: UNet-GCViT: Transformer Tabanlı Hasar Tespit Yöntemi

3.12.1 Amaç

Bu çalışma (Gomroki vd., 2025), doğal ve insan kaynaklı afetlerden sonra binaların hasar tespiti için yeni bir derin öğrenme tabanlı yöntem önermektedir. Amaç, yalnızca afet sonrası uydu görüntülerini kullanarak hızlı ve yüksek doğrulukta bina hasar haritaları üretmektir. Bu yöntem, öncesi-sonrası görüntü eşleştirmeye gerek kalmadan çalışarak mevcut yaklaşımlardaki veri erişimi ve işlem hatalarına çözüm getirmektedir.

3.12.2 Kullanılan yöntemler

Önerilen yöntem, UNet mimarisi üzerine kurulu olup, encoder kısmında Global Context Vision Transformer (GCViT) blokları kullanılmıştır. Bu yaklaşım üç ana adımdan oluşur:

- 1) Veri Ön İşleme Görüntü normalizasyonu, veri artırımı (rotasyon ile) ve eğitim/test ayrımı yapılır.
- 2) Ağ Eğitimi: UNet-GCViT modeli TensorFlow kullanılarak eğitilir. Modelin encoder kısmı, ImageNet üzerinde önceden eğitilmiş GCViT bloklarıdır.

- 3) Tahmin ve Değerlendirme: Eğitilen model ile hasar haritaları üretilir ve doğruluk, F1 skoru, IoU gibi metriklerle değerlendirilir.

Şekil 3.20’de önerilen modelin mimarisi görülmektedir. (a) GCViT ağ bloklarının mimarisi. Her aşamada, bir sorgu üretici, yerel anahtar ve değer temsiliyle etkileşime girerek uzun menzilli bilgileri yakalayan küresel sorgu token'larını çıkarır. Yerel ve küresel bağlam öz-dikkat katmanlarının dönüşümlü olarak kullanıldığı bloklar mevcuttur. (b) Tek bir akış ve dört aşamadan oluşan GCViT XTiny ağının yapısı (farklı renklerle temsil edilmiştir). LG-SA ve Conv, sırasıyla yerel, küresel öz-dikkat ve 3×3 evrişim katmanını ifade eder. (c) GCViT ağ bloklarını bir kodlayıcı olarak kullanan önerilen yöntemin yapısı. Kodlayıcı, beş farklı çözünürlükte (gövde, aşama1, aşama2, aşama3 ve aşama4) kod çözücüsüyle birleştirilmiştir. C-Transpose, ters evrişim (transpose convolution), concat ise birleştirme (concatenation) işlemidir.

3.12.3 Kullanılan algoritmalar

GCViT Blokları: Global ve lokal self-attention modülleriyle hem kısa hem de uzun mesafeli uzamsal ilişkileri yakalar. Fused-MBConv kullanılarak (downsampling operator) veri boyutu küçültülür. Global Query Generator ile küresel bağlam bilgisi oluşturur. U-net’in daha doğru hasar haritaları çıkarmasına yardımcı olur. Adam optimizasyon algoritması ve focal loss fonksiyonu model eğitiminde kullanılmıştır.

Veri setleri hasar etiketleme yapılarak kullanılmıştır.


- 2023 Türkiye Depremi (Nurdağı)
- 2021 Bata Patlaması (Ekvator Ginesi)
- 2010 Haiti Depremi

3.12.4 Sonuçlar


Önerilen yöntemin performans metrikleri doğruluk (OA) %96.71 (Türkiye), %98.74 (Bata), %98.75 (Haiti); kappa katsayısı 0.85 (Türkiye), 0.81 (Bata), 0.72 (Haiti) olarak belirlenmiştir. F1 skoru %99.48’e kadar çıkmaktadır.

Önerilen yöntem, FastViT, TinyViT, EfficientFormer gibi diğer derin öğrenme modellerine göre daha yüksek doğruluk ve daha hızlı eğitim süreleri sunmaktadır. Ayrıca GPU dostu olması sayesinde daha az hesaplama kaynağı gerektirir.

Bu yöntem, yalnızca afet sonrası görüntülerle çalışabilmesi, yüksek doğruluk ve hızlı sonuçlar sunmasıyla afet yönetimi için pratik bir çözüm sağlamaktadır. Ayrıca farklı doğal afet türlerinde ve 3D hasar tespiti uygulamalarında (lidar kullanılarak yapılacak




Şekil 3.18 : GCViT ground truth (doğrulanmış veri) bina maske görseli.



Şekil 3.19 : GCViT yönteminin hasarlı bina tahmin maskeleme performansı.

tespitlerde) da kullanılabileceği önerilmektedir. Şekil 3.18 ve Şekil 3.19’de sırasıyla gerçekte tespit edilen hasarlı yapılar ve yöntemin tespit ettiği yapılar gösterilmiştir.




Şekil 3.20 : Unet-GCVit mimarisi.

3.13 Yayın 13: SAR Görüntüleri Kullanarak Bina Hasar Tespiti Çalışması

3.13.1 Amaç

Bu çalışma (T. Li vd., 2023), yalnızca deprem sonrası yüksek çözünürlüklü Sentetik Açıklıklı Radar (SAR) görüntülerini kullanarak bina hasar tespitini gerçekleştirmek için Çift Alanlı Transformer (Dual Domain Transformer-DDFormer) modelini önermektedir. Mevcut bina hasar tespit yöntemlerinin çoğu, öncesi ve sonrası görüntülere dayalı değişim tespiti yapmaktadır. Ancak, öncesi görüntülerin her zaman mevcut olmaması, klasik yöntemlerin etkinliğini sınırlamaktadır. Bu nedenle, Şekil 3.21'deki gibi yansıma özellikleri analiz edilerek yalnızca tekil deprem sonrası SAR görüntülerinden hasar tespiti yapabilen bir model geliştirilmiştir.



Şekil 3.21 : SAR yansıma yayılım özellikleri analizi.

3.13.2 Yöntemler

DDFormer modeli, mekânsal ve frekans alanı bilgilerini birleştirerek çalışır ve Transformer tabanlı bir mimariye sahiptir. Modelin temel bileşenleri şunlardır:

- Mekânsal Modül: Multi-head self-attention mekanizması kullanarak bina konturlarını belirginleştirir.
- Uyarlanabilir Frekans Modülü: Yıkılmış binaların SAR yansıma yayılım özelliklerini (scattering features) iyileştirmek için düşük geçişli (low-pass) ve yüksek geçişli (high-pass) filtreler uygular. Daha hassas ve detaylı bina hasar tespiti yapmayı sağlar.

- Birleştirme Katmanı (Fusion Head): Mekânsal ve frekans bileşenlerinden gelen özellikleri birleştirerek bina hasar tespitini daha doğru hale getirir.

3.13.3 Deneyler ve sonuçlar

2023 Türkiye Depremi'nden etkilenen bölgeler (İslahiye ve Kahramanmaraş) üzerinde Capella ve GF-3 SAR görüntüleri kullanılarak test edilmiştir. Toplamda 2840 SAR görüntüsü ile oluşturulan veri kümesi, uzman görüşleri ve Maxar uydu görüntüleri temel alınarak etiketlenmiştir. Model, DeepLabv3, SegFormer ve AFormer gibi güncel derin öğrenme tabanlı yöntemlerle karşılaştırılmıştır. DDFormer modeli, %81.81 ortalama kesişim-birleşim (mIoU) ve %90 F-Skoru ile en yüksek başarıyı sağlamıştır. Modelin tespit sonuçları, Microsoft'un Türkiye Deprem Raporu ile karşılaştırıldığında 0.626 Pearson korelasyon katsayısı ile yüksek bir tutarlılık göstermiştir.

3.13.4 Sonuç

DDFormer modeli, sadece deprem sonrası SAR görüntüleri kullanarak bina hasar tespiti yapabilen, yüksek doğruluklu bir yöntem sunmaktadır. Mekânsal ve frekans bilgilerini birleştiren yaklaşımı, özellikle öncesi ve sonrası görüntüler bulunmadığında büyük avantaj sağlamaktadır. Gelecekte, daha fazla SAR görüntüsü toplanarak modelin farklı senaryolardaki başarısı detaylı olarak değerlendirilecektir. Şekil 3.22'de DDFormer ve diğer yöntemlerin iki farklı SAR görüntüsünden performans kıyaslaması gösterilmiştir.

3.14 Yayın 14: Afet Öncesi ve Sonrası Ortofoto Kullanarak Hasar Tespiti

3.14.1 Amaç


Bu çalışma (Kalantar vd., 2020), deprem sonrası binaların hasar durumlarını tespit etmek için konvolüsyonel sinir ağları (CNNs) kullanarak pre- ve post-event ortofoto görüntüleri üzerinde hasar sınıflandırması yapmayı amaçlamaktadır.

3.14.2 Yöntemler




Çalışmada 2016 Kumamoto Depremi (Japonya)'na ait pre- ve post-event ortofoto görüntüleri kullanılmıştır.

Hasar tespiti otomasyonunda doğruluğu arttırmak için farklı CNN modellerin bir arada kullanılması denenmiştir. Üç farklı yöntem CNN modeli ile test edilmiştir. Şekil 3.23’de yöntemlere ait şemalar bulunmaktadır.

- Twin Model: Aynı CNN modeli ile pre- ve post-event görüntüler analiz edilerek sonradan birleştirilir. Change detection üzerine çalışmaya odaklıdır. Değişim algılamada daha hassas bir yöntem olduğu vurgulanmaktadır.
- Fusion Model: İki farklı CNN modeli kullanılır, ancak önce ve sonra çekilen görüntüler farklı CNN ağları tarafından işlenir. Daha esnek bir yapıdır. Bina yükselti verileri de girdi sağlanarak daha yetenekli bir hasar tespit altyapısı sunar.
- Composite Model: RGB bantlarının birleşimiyle 6 kanallı görüntü oluşturulur ve tek bir CNN modeli ile analiz edilir.



Şekil 3.22 : DDFormer ve diğer yöntemlerin iki farklı SAR görüntüsünden performans kıyaslaması.



(c)


Şekil 3.23 : 3 farklı yöntemle CNN ağının kullanım şemaları. (a) composite model, (b) twin model, and (c) fusion model.

3.14.3 Sonuçlar

Genel doğruluk (OA), Üretici doğruluğu (PA), Kullanıcı doğruluğu (UA) ve F1 skoru kullanılmıştır. Twin Model, diğer modellere kıyasla en yüksek doğruluğa (OA=76.86%) ve en yüksek F1 skoruna (0.761) ulaşmıştır.

Fusion Model ikinci sırada yer alırken (OA=72.27%, F1=0.714), Composite Model en düşük doğruluk değerine sahiptir (OA=69.24%, F1=0.682).

CNN'ler, manuel görüntü işleme yöntemlerine kıyasla daha hızlı ve verimli bir bina hasar tespiti sağlayabilir, ancak gölge, ışık değişimleri gibi çevresel faktörler hata payını artırabilir. Şekil 3.24'de yöntemlerin karşılaştırmalı hasar tespiti tahmin sonuçları gösterilmiştir.



Şekil 3.24 : Hasar sınıflandırma sonuçları: (a,g,m) afet öncesi, (b,h,n) afet sonrası, (c,i,o) gerçek değerler (GT), (d,j,p) birleşik model, (e,k,q) ikiz model, ve (f,l,r) birleşim modelidir.

3.15 Yayın 15: YOLOv8 ile Afet Sonrası Görüntülerden Hasar Tespiti

3.15.1 Amaç

Bu çalışmada (Gomroki vd., 2024), post-event uzaktan algılama (RS) verileri kullanarak EfficientViTB ve Yolov8 tabanlı bir encoder-decoder mimarisi geliştirilmiş ve bina hasar tespiti için test edilmiştir. 'de geliştirilen modele ilişkin akış şeması bulunmaktadır.

3.15.2 Yöntemler

Yalnızca post-event uzaktan algılama görüntüleri kullanılmıştır (öncesi-sonrası kıyaslaması yerine yalnızca sonrası görüntüler).

Önceden (ImageNet ve MS-COCO verisetleriyle) eğitilmiş EfficientViTB ve Yolov8 ağlarının bulunduğu bir encoder-decoder mimarisi kullanılmıştır. Bu şekilde etkili bir hasar tespit imkanı sağlamaktadır. EfficientViTB, Vision Transformer (ViT) mimarisinin bir varyantıdır ve görüntü sınıflandırma görevlerinde etkilidir. EfficientViTB, ViT'nin verimliliğini artırmak için optimize edilmiştir ve encoder kısmında kullanılır.

Yolov8, "You Only Look Once" (YOLO) algoritmasının sekizinci versiyonudur; nesne tespiti için geliştirilmiş bir derin öğrenme modelidir. Bu çalışmada, Yolov8'in belirli blokları, decoder kısmında kullanılarak bina hasar tespiti yapılır.


Üç farklı doğal afet veri seti incelenmiştir. Worldview 2 ve GeoEye-1 uydularından alınan görüntüler, %60 eğitim – doğrulama ve %40 test verisi şeklinde bölümlendirilmiştir. Kullanım öncesinde veri zenginleştirme (data augmentation) işlemine tabi tutulmuştur. Kullanılan veri setleri olayları:

- 2023 Türkiye Depremi (Nurdağı)
- 2023 Fas Depremi
- 2023 Libya Sel Felaketi


3.15.3 Sonuçlar

Performans metrikleri: Genel doğruluk (OA), Kappa katsayısı (KC), Kesinlik (Precision), Intersection over Union (IoU), F1 Skoru.

CNN mimarilerinin birleştirilmesi (EfficientViTB + Yolov8), bina hasar tespitinde önemli avantajlar sağlamaktadır. Önerilen model farklı afet türlerinde başarıyla kullanılabilmiştir. Şekil 3.25’de önerilen yöntemin performansının gerçek durumla kıyaslanması gösterilmiştir.



67



Şekil 3.26 : Efficient ViTB ve YOLOv8 ile geliştirilen bina hasar tespit modelinin akış şeması.

3.16 Yayın 16: Çoklu Özellik Kullanımı ve Derin Öğrenme ile Hasar Tespiti

3.16.1 Amaç

Bu çalışma (Abdi & Jabari, 2021), farklı görüntüleme açılarından elde edilen nadir ve off-nadir görüntüleri birleştirerek bina hasar tespiti yapmayı hedeflemektedir.


3.16.2 Yöntemler

Derin transfer öğrenme (Deep transfer learning - DTL) temelli çok özellikli füzyon (multi feature fusion) yöntemi kullanılmıştır. Bu çalışmada 2010 Haiti Depremi sonrası bina hasar tespiti için deprem öncesi ve sonrası, nadir ve off-nadir uydu görüntüleri ile hava fotoğrafları kullanılmıştır.

Derin öğrenme hasar tespit altyapısı geliştirilirken dört aşamalı bir yaklaşım uygulanmıştır, bu yaklaşımlara ilişkin şema Şekil 3.27’de bulunmaktadır:

- Ön işleme (veri temizleme ve hizalama), çeşitli formattaki görüntülerin birleştirilmesi.
- Derin özellik çıkarımı (CNN modelleri ile): ImageNet verisiyle eğitilmiş ResNet18 sinir ağı modeli kullanılarak bina hasar tespitine uygun özelleştirilmiş.
- Özellik füzyonu (çoklu özellik katmanlarının birleştirilmesi). Toplama yöntemiyle afet öncesi ve sonrası özelliklerin birleştirilmesiyle derin özellikler oluşturulmuş. Çıkarma yöntemiyle öncesi ve sonrası arasındaki özellik farklar hesaplanmış. Birleştirme yöntemi ile de farklı veri kaynaklardan gelen özellikler aynı ağda birleştirilmiştir. Burada en iyi yöntem özellik farkının hesaplaması olarak bulunmuştur.
- İnce ayar (fine tune) uygulaması ile transfer öğrenme ile sınıflandırmadan faydalanılmıştır.

2010 Haiti Depreminde elde edilen, deprem öncesi veri seti kullanılmıştır.



Şekil 3.27 : ResNet -18 kullanılarak geliştirilen özellik çıkarım stratejileri şeması.

3.16.3 Sonuçlar

%83'ün üzerinde genel doğruluk elde edilmiştir. Off-nadir görüntülerin eklenmesi, bina hasar tespitinde önemli avantajlar sunmuştur. Geleneksel yöntemlerin aksine sadece nadir uydu görüntüleri yerine hem ortofoto hem de off-nadir görüntüler kullanılmıştır. Bu sayede daha fazla veri kaynağından yararlanılarak doğruluk artırılmıştır. Farklı çözünürlükteki görüntülerle eşleştirme yapılarak hataların azaltılması sağlanmıştır. Off-nadir açılar nedeniyle geleneksel yöntemlerle zor olan bina hizalaması, Patch-Wise Co-Registration (PWCR) yöntemiyle düzeltilmiştir. Geleneksel yöntemlerle kıyaslandığında (Change Vector Analysis, SVM, Random Forest), önerilen model %98 doğruluk ile çok daha başarılı bulunmuştur.

Homojen Veri Seti (aynı uydu farklı açılar): En iyi doğruluk oranı: %87 (Subtraction fusion, Fine-tuning ile)

Heterojen Veri Seti (uydu + ortofoto farklı sensörler): En iyi doğruluk oranı: %98 (Subtraction fusion, Fine-tuning ile)

Yöntemin performansına ilişkin görsel Şekil 3.28'de sunulmuştur.



Şekil 3.28 : Gerçek durum ve uygulamanın hasar tespiti performans karşılaştırması.

3.17 Yayın 18: BDDNet+: Coat-Net Tabanlı Hasar Tespit Çatısı

3.17.1 Amaç

Bu çalışma (Seydi vd., 2023a), afet sonrası görüntülerle Coat-Net tabanlı bir bina hasar tespit ağı (BDD-Net+) geliştirerek yüksek doğruluklu ve yorumlanabilir sonuçlar üretmeyi hedeflemektedir. Coat-Net (Convolution and Self-Attention Network), konvolüsyonel sinir ağları (CNN) ve transformer tabanlı dikkat mekanizmalarını (self-attention) birleştiren bir derin öğrenme mimarisidir.

3.17.2 Yöntemler


CNN ve Transformer mimarileri birleştirilerek bir model tasarlanmıştır. Yüksek çözünürlüklü (VHR) afet sonrası uydu görüntüleri kullanılmıştır.

RGB ve yakın kızılötesi spektral bantlar ile özellik seçimi ve ön işleme yapılmıştır. Bina maskeleri oluşturularak raster görüntüler üzerinde birleştirilmiştir.

Şekil 3.29’de görülebileceği gibi mimari aşamaları veri hazırlama, model eğitimi ve hasar haritası üretiminden oluşmaktadır.

BDDNet+ ile Coat-Net algoritmasındaki convolution katmanının genelleştirme ve transformer katmanlarının model kapasitesini artırması gibi avantajları kullanılarak daha iyi performans elde edilmesi amaçlanmaktadır.

BDDNet+, CoatNet'ten farklı olarak klasik 3x3 veya 5x5 kare filtreler yerine asimetrik CNN filtreler kullanılıyor. Bu sayede daha iyi öğrenme ve daha az parametre ile aynı ya da daha iyi performans sağlıyor. Ayrıca daha az parametre de hesaplama yükünü azaltmış oluyor.



Şekil 3.29 : BDDNet+ algoritma mimarisi şeması.

XAI (Explainable AI) kullanarak modelin yorumlanabilirliği artırılmıştır. Bu şekilde modelin kararlarının görselleştirilmesi sağlanmıştır. Yanlış pozitif ve yanlış negatif hataları analiz edilerek model geliştirilebiliyor. AI modelinin güvenilirliği artıyor, çünkü tahminlerini nasıl yaptığını açıklayabiliyor. BDD-Net+ modelinin hangi bölgeleri hasarlı olarak belirlediğini görselleştirmek için Grad-CAM yöntemi kullanılmıştır. Grad-CAM, modelin bir görüntü üzerinde hangi bölgeleri dikkate aldığını gösteren bir ısı haritası (heatmap) üretir. Bu yöntem sayesinde modelin neden bir binayı “hasarlı” veya “hasarsız” olarak sınıflandırdığı görsel olarak incelenebilir.

Model Haiti Depremi ve Bata Patlaması veri setleri ile test edilmiştir. Farklı afet türlerinde (deprem, patlama) modelin genelleştirme yeteneği değerlendirilmiştir.

3.17.3 Sonuçlar

BDD-Net+, mevcut yöntemlere kıyasla daha yüksek doğruluk sağlamıştır. Modelin XAI (Grad-Cam ile modelin odaklandığı yerler belirlenmiş) ile yorumlanabilir olması, sonuçları doğrulama sağladığı için acil durum ekipleri için avantaj sunmaktadır. BDD-Net+ %94 genel doğruluk değerine ulaşmıştır. Coat-Net'e kıyasla daha iyi sonuç vermiştir. Şekil 3.30'da gerçek durum ve Coat-Netle kıyaslama gösterilmiştir. Tespit edilen özellikler kenarlar, dokular CNN katmanları sayesinde hızla öğrenilerek, transformer tabanlı katmanlara işlem gücü ihtiyacı azalır. Self attention mekanizmasına gerek duyulmadığı için yüksek işlem gücü kullanılmaz.



Şekil 3.30 : Önerilen BDD-Net+ ve Coat-Net yöntemlerinin gerçek durumla kıyaslaması.

3.18 Yayın 18: İHA Verisi ve Denetimli Derin Öğrenme ile Hasar Tespiti

3.18.1 Amaç

Bu çalışma (Takhtkeshha vd., 2022), insansız hava aracı (UAV) görüntüleri kullanarak deprem sonrası bina hasar tespiti için hızlı, kendi kendini denetleyen (self-supervised) bir derin öğrenme yöntemini önermektedir. Yöntemin temel amacı, manuel veri etiketlemeye olan ihtiyacı azaltarak, hasar haritalarını hızlı ve otomatik bir şekilde oluşturmak ve kriz yönetim süreçlerini iyileştirmektir.

3.18.2 Kullanılan yöntemler

Makale, hasar tespiti için üç aşamalı bir yaklaşım sunmaktadır:

3.18.2.1 Özellik çıkarımı

Yöntemde 3 farklı özellik çıkarımı (feature extraction) uygulanmış:

- Derin olmayan (non-deep) özellikler (NDF): RGB ortofoto bantları, Triangular Greenness Index (TGI), Laplacian of Gaussian (LOG), Local nDSM (yeni önerilen normalize edilmiş dijital yüzey modeli).
- Derin özellikler (DF): "One-Epoch Convolutional Autoencoder (OECAE)" kullanılarak çıkarılan derin özellikler.
- Birleştirilmiş özellikler (FF - fused features): Hem derin hem de derin olmayan özelliklerin birleştirilmesi.

3.18.2.2 Otomatik eğitim örneklerinin seçilmesi:

EMS-98 hasar standardına dayalı fiziksel kurallarla eğitim verisi otomatik seçimi.

Çatlak tespiti için yeni bir "Roof Crack Index" ve "Edge Index" kullanımı.

3.18.2.3 Makine öğrenmesi ve derin öğrenme algoritmaları ile sınıflandırma:

Kullanılan yöntemler:

- Support Vector Machine (SVM)
- Random Forest (RF)
- Gradient Boosting (GB)
- Extreme Gradient Boosting (XGB)

- Decision Tree (DT)
- k-Nearest Neighbors (KNN)
- AdaBoost (AB)
- Multi-Layer Perceptron (MLP)

3.18.3 Sonular

Otomatik eęitim rnekleri, manuel seilenlere kıyasla daha yksek doęruluk saęlamıřtır. Manuel etiketlemeye kıyasla genel doęruluk (Overall Accuracy - OA) %22, kappa katsayısı (KC) ise %33 artmıřtır.


En yksek doęruluk, derin ve derin olmayan zelliklerin birleřtirilmesiyle (FF) elde edilmiřtir. FF yntemi, yalnızca NDF veya DF kullanımına gre sırasıyla ortalama %6.75 ve %7.19 daha yksek OA saęlamıřtır. řekil 3.31’de farklı stratejilerin tespit performansı kıyaslaması gsterilmiřtir.

Sınıflandırıcıların karřılařtırması: SVM (%82 OA, %74.01 KC) ve MLP (%82 OA, %73.98 KC) en bařarılı yntemler olmuřtur. AdaBoost (AB) en dřk performansı gstermiřtir.

nerilen yntem, CPU zerinde 4 dakika 20.6 saniye iinde alıřabilmektedir. GPU kullanımıyla bu sre daha da kısaltılabilir.

EMS-98 hasar seviyelerinin UAV grntlerine uyarlanması, eęitim rneklerinin otomatik seimi iin yeni bir yntem nerilmesi, UAV grntlerinden hızlı bir řekilde normalize edilmiř yzey modeli (nDSM) retimi, derin ve derin olmayan zelliklerin birleřtirilerek daha yksek doęruluk saęlanması olarak belirtilebilir.

Bu alıřma, deprem sonrası hasar tespiti iin yksek doęruluklu, otomatik ve hızlı bir yntem sunarak afet ynetimi srelerine nemli katkılar saęlamaktadır.



Şekil 3.31 : Tespit stratejilerine göre yöntemlerin maskeleme performansları kıyaslaması.

3.19 Yayın 19: Optik ve Radar Veri Kullanılarak Hasar Tespiti

3.19.1 Amaç

Bu çalışma (Ghahrloo & Mokhtarzade, 2025), optik ve radar verilerini birleştirerek deprem sonrası bina hasarlarını tespit eden bir uzaktan algılama yöntemi sunmaktadır. Derin öğrenme, bulanık çıkarım sistemi ve görüntü segmentasyonu tekniklerini kullanarak bina hasar haritaları oluşturulmuştur.

3.19.2 Yöntemler


Üç farklı yaklaşımla CNN modeli uygulanmıştır: CNN modeli ile doğrudan sınıflandırma, CNN modeli ile özellik çıkarımı yaparak sınıflandırma ve CNN + Destek Vektör Makineleri (SVM) + Bulanık Çıkarım Sistemi (FIS) kullanılarak sınıflandırma.

Optik ve radar görüntüleri farklı modlarda kullanılmıştır. Sadece optik veya sadece radar verisi, optik ve radar verilerinin piksel seviyesinde füzyonu ile optik görüntüye dayalı karar seviyesinde füzyon kullanılmıştır.


Sarpol-e Zahab, İran'da 2017'de gerçekleşen 7.3 büyüklüğündeki deprem veri seti olarak kullanılmıştır.

3.19.3 Sonuçlar

CNN + SVM + Bulanık Mantık Çıkarım Sistemi, diğer yöntemlere kıyasla daha yüksek doğruluk sağlamıştır. Şekil 3.32'de denenen yöntemlerin piksel ve nesne tabanlı olarak doğruluk karşılaştırılması verilmiştir. Optik ve radar verilerinin birlikte kullanılması, tek başına optik verilere kıyasla daha iyi sonuçlar vermiştir. Nesne tabanlı analiz yöntemleri %97.72 doğruluk oranıyla, piksel tabanlı yöntemlerden daha yüksek doğruluk vermiştir. Şekil 3.33'de farklı yöntemlerin görsel olarak karşılaştırılması sunulmuştur.



Şekil 3.32 : Uygulanan yöntem kombinasyonlarının doğruluk karşılaştırılması.



Şekil 3.33 : Gerçek durum ve farklı sınıflandırma yöntemlerinin tahmin karşılaştırması (a) CNN (piksel tabanlı), (b) CNN + SVM (piksel tabanlı), (c) CNN + FIS (piksel tabanlı), (d) CNN (nesne tabanlı), (e) CNN + SVM (nesne tabanlı), (f) CNN + FIS (nesne tabanlı).


3.20 Yayın 20: InCR: Derin Öğrenme Hasar Tespit Uygulaması

3.20.1 Amaç

Bu makalede (Tasci vd., 2023), uzaktan algılama görüntülerini kullanarak deprem sonrası hasar görmüş binaların tespitini otomatikleştiren yeni bir derin öğrenme modeli geliştirilmiştir. Şubat 2023'te Türkiye'de meydana gelen depremler, yapıların hızlı ve doğru bir şekilde değerlendirilmesinin önemini bir kez daha ortaya koymuştur. Bu çalışmada, hasarlı ve hasarsız binalardan oluşan yeni bir veri seti oluşturulmuş ve bu veri seti kullanılarak "Inception and Concatenation Residual (InCR)" adlı özel bir evrişimli sinir ağı (CNN) modeli tasarlanmıştır. Model, görüntülerden derin özellikler çıkarmak için global ortalama havuzlama (GAP-global average pooling) yöntemiyle eğitilmiş ve en iyi özellikleri seçmek için iteratif komşuluk bileşen analizi (INCA) uygulanmıştır. Modelin performansı, sekiz farklı sınıflandırıcı ile on kat çapraz doğrulama (10-fold CV-cross validation) yöntemi kullanılarak test edilmiş ve tüm sınıflandırıcıların %98'in üzerinde doğruluk oranı elde ettiği görülmüştür. Bu çalışma, yapay zeka tabanlı bina hasar tespitinde yeni bir yaklaşım sunarak, afet sonrası hızlı ve etkili müdahale süreçlerine katkı sağlamayı hedeflemektedir.

3.20.2 Yöntemler

Deprem sonrası bina hasar tespiti için yeni bir derin öğrenme modeli olan InCR (Inception and Concatenation Residual) CNN ağı geliştirilmiştir. İki farklı CNN bileşeni kullanılmıştır. Concatenation-based residual bloklar, modelin daha derin öğrenmesini sağlar. Şekil 3.34'deki inception bloklar, farklı ölçeklerde özellik çıkarımı yapar.




Şekil 3.34 : Farklı boyutlu inception katmanlarının kullanıldığı InCR derin öğrenme modeli.

İlk olarak, uzaktan algılama görüntülerinden oluşan yeni bir veri seti toplanmış ve bu veri seti hasarlı ve hasarsız binalar olmak üzere iki kategoriye ayrılmıştır. Modelin eğitimi için InCR ağı tasarlanmış ve bu ağ, inception blokları ile birleştirme tabanlı artık (residual) blokları kullanarak performansı artıracak şekilde yapılandırılmıştır. Model, görüntülerden özellik çıkarmak için global ortalama havuzlama (GAP-global average pooling) yöntemiyle eğitilmiş, ardından en önemli özellikleri belirlemek için iteratif mahalle bileşen analizi (INCA - Iterative Neighborhood Component Analysis) uygulanmıştır. Elde edilen özellikler, karar ağacı (DT), lojistik regresyon (LR), destek vektör makineleri (SVM), k-en yakın komşu (k-NN) gibi sekiz farklı sınıflandırıcı ile test edilmiştir. Modelin performansı, on kat çapraz doğrulama (10-fold CV) yöntemi kullanılarak değerlendirilmiş ve en iyi sonucu veren sınıflandırıcı tespit edilmiştir. Bu yöntemler sayesinde, hasar tespitinde yüksek doğruluk ve güvenilirlik sağlanmıştır.

3.20.3 Sonuçlar

Bu çalışmada önerilen Inception and Concatenation Residual (InCR) derin öğrenme modeli, deprem sonrası bina hasar tespitinde yüksek doğruluk oranları ile başarılı sonuçlar elde etmiştir. Modelin performansı sekiz farklı sınıflandırıcı ile test edilmiş

ve en iyi sonucu veren destek vektör makineleri (SVM) sınıflandırıcısı ile %99.82 doğruluk oranına ulaşılmıştır. Bunun yanı sıra, diğer sınıflandırıcılar da %98'in üzerinde doğruluk oranları elde ederek modelin güvenilirliğini kanıtlamıştır. InCR modeli, geleneksel CNN mimarilerine kıyasla daha iyi performans göstererek bina hasar tespitinde derin öğrenme tabanlı yaklaşımların etkinliğini ortaya koymuştur. Ayrıca, modelin başarısı, farklı uzaktan algılama görüntüleriyle test edilerek doğrulanmış ve bu yöntemin afet yönetimi süreçlerinde hızlı ve otomatik bir hasar tespit aracı olarak kullanılabileceği gösterilmiştir. Çalışmanın sonuçları, yapay zeka destekli afet müdahale sistemlerinin geliştirilmesine önemli bir katkı sağlamaktadır. Şekil 3.35'de modelin açıklanabilirliği için GradCAM yöntemine ilişkin örnek görsel sunulmuştur.



Şekil 3.35 : Modelin açıklanabilirliği grad cam heat map yöntemiyle gösterilmiştir.

3.21 Yayın 21: GAN Mimarisi Kullanılarak Bina Hasar Tespit Uygulaması


3.21.1 Amaç

Bu makalenin (Tilon vd., 2020) amacı, afet sonrası bina hasarlarının tespit edilmesi için denetimsiz bir derin öğrenme yöntemi sunmaktır. Çalışmada, yalnızca afet öncesi görüntülere ihtiyaç duyan Anomali Algılayan Üretici Çekişmeli Ağlar (ADGAN - Anomaly Detecting Generative Adversarial Network) kullanılarak, modelin farklı coğrafi konumlara ve hasar tiplerine transfer edilebilirliği incelenmiştir. Çalışma, büyük ölçüde denetimli öğrenme yaklaşımlarının yeterli etiketli veri gereksinimi

nedeniyle sınırlı kaldığını vurgulamakta ve modelin hızlı bir şekilde afet sonrası kullanılabilmesi için afet öncesinde eğitilebilmesini sağlamayı hedeflemektedir. xBD uydu görüntüleri ve özel bir insansız hava aracı (UAV) veri kümesi kullanılarak yapılan deneylerde, modelin farklı hasar türlerini tespit etme performansı değerlendirilmiştir. Sonuçlar, eğitim veri kümesinin içeriğine ve ön işleme tekniklerine bağlı olarak modelin başarı oranının değiştiğini göstermiştir. Makale ayrıca, modelin operasyonel olarak nasıl uygulanabileceğine dair pratik kılavuzlar sunmaktadır.

3.21.2 Yöntemler

Bu makalede, afet sonrası bina hasar tespiti için Anomali Algılayan Üretici Çekişmeli Ağlar (ADGAN - Anomaly Detecting Generative Adversarial Networks) kullanılmıştır. Şekil 3.36'daki Skip-GANomaly modeli tercih edilerek, yalnızca afet öncesi görüntülerle eğitilen, hasarlı ve hasarsız yapıları ayırt edebilen bir yaklaşım geliştirilmiştir. Model, üretici (generator) ve ayırıştırıcı (discriminator) olmak üzere iki bileşenden oluşur ve görüntülerdeki anomaliyi tespit etmek için laten kayıp (latent loss), bağlamsal kayıp (contextual loss) ve çekişmeli kayıp (adversarial loss) fonksiyonlarını kullanır. Çalışmada, xBD uydu görüntüleri ve UAV (İnsansız Hava Aracı) verileri kullanılmış, farklı ön işleme teknikleri (gölge ve bitki örtüsü temizleme, farklı görüntü boyutları, coğrafi bölgelere göre veri ayırma) ile modelin performansı değerlendirilmiştir. Sonuçlar, modelin özellikle geniş ölçekli hasar tespitinde başarılı olduğunu ve farklı coğrafi bölgeler veya afet türleri arasında transfer edilebilirliğinin değişkenlik gösterdiğini ortaya koymuştur.



Şekil 3.36 : Geliştirilen SkipGAN mimarisi.

3.21.3 Sonular

alıřmanın sonuları, Skip-GANomaly tabanlı ADGAN modelinin, zellikle geniř lekli afet hasarlarını tespit etmede bařarılı olduėunu gstermiřtir. Model, yangın ve sel gibi byk alanları etkileyen felaketlerde yksek doėruluk saėlarken (yangın verisinde rnek olarak %87 F1 skoru elde edilmiřtir), deprem gibi kk lekli hasarları tespit etmede daha dřk performans gstermiřtir (F1 skoru %17). n iřleme teknikleri (rneėin, glge ve bitki rtsnn kaldırılması) modelin bařarısını artırmıř, ancak bu durum kullanılabilir veri miktarını azaltmıřtır. Bu řekilde uydu grntlerinde F1 skoru deėeri %44 olarak hesaplanmıřtır. UAV grntlerinde modelin bařarı oranı %73 F1 skoru ile daha yksek bulunmuř ve farklı coėrafi konumlara daha iyi transfer edilebildiėi gzlemlenmiřtir. Uydu grntlerinde ise modelin transfer edilebilirliėi sınırlı kalmıř, farklı blgelerde bařarı oranı deėiřkenlik gstermiřtir. Genel olarak, alıřma denetimsiz ėrenme yntemlerinin afet sonrası hızlı mdahale srelerinde pratik ve uygulanabilir bir alternatif sunduėunu ortaya koymuřtur, ancak modelin daha kk lekli ve detaylı hasar tespiti iin geliřtirilmesi gerektiėi sonucuna varılmıřtır.

3.22 Yayın 22: Hasar Tespitinde Derin ėrenme Modellerinin Geliřimi

3.22.1 Ama


Bu alıřma (Wiguna vd., 2024), derin ėrenme modellerinin acil durum yanıt srelerinde bina hasar tespiti iin nasıl performans gsterdiėini deėerlendirmektedir. Afet sonrası hızlı karar alma srelerinde etiketli eėitim verilerinin eksikliėi gibi zorlukları gidermek iin transfer ėrenme tekniklerini inceler.

3.22.2 Yntemler ve algoritmalar

2011 Tohoku Tsunami ve 2023 Trkiye-Suriye Depremi'nden, baėımsız olarak toplanmıř test verileri ile xBD veri seti model eėitimi iin kullanılmıřtır.

Transformer tabanlı model (Swin Transformer), Siamese aė yapıları, xView-2 kazanan zm ile karřılařtırma yapılmıřtır. řekil 3.37'de geliřtirilen yntemin sreleri gsterilmiřtir. Afet ncesi ve sonrası grntlerden bina veri seti oluřturulup farklı algoritmalarla (ResNet tabanlı modeller ile Swin Transformer modeli) eėitilmiř sonu

olarak da en iyi sonucu veren Swin Transformer algorimalı model 0.3 metre çözünürlüklü Türkiye-Suriye Deprem verisi ile test edilmiştir.




Şekil 3.37 : SwinTransformer model eğitim süreci şeması.

Çapraz entropi kaybı (Cross-Entropy Loss - CEL), focal loss kayıp fonksiyonları kullanılmış ve CEL-Focal Loss kombinasyonu kayıp fonksiyonu en iyi performansı göstermiştir.

3.22.3 Sonuçlar

Transformer tabanlı model, hem piksel seviyesinde hem de bina seviyesinde yüksek genelleme kapasitesine sahip olmuştur. xView-2 kazanan çözümü ile karşılaştırıldığında, Swin Transformer modeli daha kararlı sınıflandırma yapmış ve çoklu çözünürlükte daha iyi çalışmıştır. Model, hasarsız ve tamamen yıkılmış binaları iyi sınıflandırırken, orta hasarlı sınıflarda performans düşmüştür. Hava fotoğraflarında öncesi ve sonrası veriler (bitemporal) birlikte kullanıldığında ortalama %33 F1 skoru hesaplanmıştır. Bitemporal uydu görüntülerinde ise ortalama %36 F1 skoru elde edilmiştir. Şekil 3.38’de yöntemin afet öncesi ve sonrası veriler kullanıldığında başarı performansları gösterilmiştir.



Şekil 3.38 : SwinTransformer yöntemin afet öncesi ve sonrası veriler kullanılarak elde edilmiş başarı performansları karşılaştırması.

3.23 Yayın 23: Dinamik ve Sabit Filtreli Derin Öğrenme Modeli Kullanımı

3.23.1 Amaç

Bu makalenin amacı (Seydi vd., 2023b), bina hasar tespitini daha açıklanabilir hale getirmek için involution (dinamik filtreler) ve convolution (sabit filtreler) yöntemlerini birleştiren yeni bir derin öğrenme modeli çatısı geliştirmektir. Geleneksel bina hasar tespit yöntemleri genellikle afet öncesi ve sonrası uydu görüntülerine dayanırken, bu çalışma yalnızca olay sonrası (post-event) uzaktan algılama görüntüleri kullanarak bina hasarlarını tespit etmeyi amaçlamaktadır. Geleneksel yöntemlerde manuel özellik mühendisliği ve görüntü kayıt süreçleri gerekliyken, bu çalışmada derin öğrenme tabanlı bir yöntem önerilerek sürecin tamamen otomatik hale getirilmesi hedeflenmiştir.

Bu çalışmanın en önemli katkılarından biri, Explainable AI (XAI) yaklaşımlarını kullanarak modelin kararlarını açıklanabilir hale getirmesidir. Böylece, modelin hangi özelliklere dayanarak karar verdiği anlaşılabilir ve yanlış tahminlerin nedenleri daha iyi analiz edilebilir.

Önerilen model, bina ayak izleri (footprints) ve yüksek çözünürlüklü uydu görüntülerini kullanarak hasarlı ve hasarsız binaları sınıflandırmayı hedeflemektedir. Modelin performansı, geleneksel derin öğrenme yaklaşımlarına kıyasla değerlendirilmiş ve özellikle daha yüksek doğruluk ve işlem süresinde verimlilik sağlaması amaçlanmıştır.


3.23.2 Yöntemler

Önerilen çerçeve, beş temel adımdan oluşmaktadır: (1) Veri ön işleme, (2) model eğitimi ve parametre optimizasyonu, (3) hasar haritasının oluşturulması (prediction), (4) doğruluk değerlendirmesi ve (5) model tahminlerinin görsel açıklamaları. Şekil 3.39'da modelin eğitim ve uygulama sürecini gösteren bir şema bulunmaktadır. Çalışmada, Haiti depremi ve Bata patlaması olmak üzere iki gerçek dünya veri kümesi kullanılarak yöntemin performansı test edilmiştir. Sonuçlar, önerilen yöntemin %84'ün üzerinde bir genel doğruluk (OA) oranı ile diğer derin öğrenme tabanlı yöntemlerden daha üstün olduğunu göstermektedir.

Bu çalışma, derin öğrenme modellerinin açıklanabilirlik eksikliğini gidermek için Explainable AI (XAI) yaklaşımlarını da içermektedir. Bu bağlamda, model tahminlerinin açıklanabilirliğini artırmak için Grad-CAM (Gradient-weighted Class Activation Mapping) yöntemi kullanılmıştır. Bu yöntem, modelin hangi özellikleri ve bölümleri kullanarak hasarlı binaları tespit ettiğini görselleştirmeye olanak tanımaktadır.

Önerilen model, geleneksel convolution katmanlarının yanı sıra, farklı ölçeklerde filtreler içeren multi-scale convolution katmanları ve daha gelişmiş özellik çıkarımı sağlayan involution katmanlarını içermektedir. Ayrıca, modelin hassasiyetini artırmak için odaklanma (attention) mekanizmaları entegre edilmiştir.

Çalışmada kullanılan metodoloji, modelin farklı parametre ayarlarıyla optimize edilmesini de kapsamaktadır. Model, bina ayak izleri (footprints) ve uzaktan algılama görüntülerini birleştirerek hasarlı ve hasarsız binaları sınıflandırmaktadır. Modelin performansı, farklı derin öğrenme modelleri (CNN, Res-CNN, Vision Transformer gibi) ile karşılaştırılmış ve önerilen modelin daha yüksek doğruluk ve genelleme kapasitesine sahip olduğu belirlenmiştir.



Şekil 3.39 : Bina hasar sınıflandırılması için önerilen derin öğrenme modeli yönteme ait akış şeması.

3.23.3 Sonuç

Sonuç olarak, bu çalışma, bina hasar tespitinde daha verimli, yüksek doğruluklu ve açıklanabilir bir model önermektedir. %84 ortalama doğruluk ile %85 F1 skoru değeri elde edilmiştir. Şekil 3.40’da modelin diğer yöntemlere göre performansı gösterilmiştir. Geleneksel yöntemlere kıyasla yalnızca olay sonrası verilerle çalışabilmesi, işlem sürecini hızlandırmakta ve operasyonel kullanım için daha uygun hale getirmektedir. Ayrıca, modelin açıklanabilir olması, sonuçların güvenilirliğini artırarak afet yönetimi ve sigorta gibi alanlarda daha etkin bir şekilde kullanılmasını sağlamaktadır.

Class	Non-Damage				Damaged	
Method						
CNN						
ResCNN						
JAG						
VGG						
VIT						
PROPOSED						
GT						

Şekil 3.40 : Önerilen derin öğrenme modeli yöntemin diğer algoritmalarla göre performans kıyaslaması.

3.24 Yayın 24: Çeşitli Afet Türleri için Ortak Derin Öğrenme Modeli

3.24.1 Amaç

Bu makale (Sodeinde vd., 2024), farklı doğal afetlerden kaynaklanan bina hasarlarını tespit etmek için derin öğrenme modellerinin nasıl optimize edilebileceğini incelemektedir. Çalışma, özellikle xBD veri setinin kalitesini değerlendirerek, farklı afet türlerinden gelen verileri birleştirmenin avantajlarını ve sınıflandırma

doğruluğunu artırmak için veri işleme tekniklerini araştırmaktadır. Veri dengesizliğinin model performansına etkisi analiz edilmiş ve sınıflandırma doğruluğunu artırmak için öneriler sunulmuştur.

3.24.2 Yöntemler

Veri Seti ve Dengeleme: Çalışmada xBD veri seti kullanılmıştır. Bu veri seti yedi farklı doğal afet türü (deprem, yangın, sel, kasırga, hortum, tsunami, volkan patlaması) içeren 19 farklı olaydan oluşmaktadır. Ancak, veri dengesizliği nedeniyle belirli afet türleri (deprem ve volkan) yeterince temsil edilmemiştir. Bu sorunu çözmek için rastgele aşırı örnekleme (oversampling) ve eksik örnekleme (undersampling) yöntemleri uygulanmıştır.

Derin Öğrenme Modeli ve Modifikasyonlar: Çalışmada ResNet50 modeli temel alınmış ve transfer öğrenme yöntemi kullanılmıştır. Model, başlangıçta ImageNet ağırlıkları ile eğitilmiş olup, ancak "hasarsız" sınıfına aşırı uyum sağladığı görülmüştür. Bunu önlemek için:


- Beş yeni konvolüsyon bloğu, Batch Normalization ve Max Pooling katmanları eklenmiştir.
- Dropout (0.5 oranında) eklenerek aşırı öğrenme engellenmiştir.
- Erken durdurma (early stopping) ve uzun dönem eğitim (80-100 epoch) ile model iyileştirilmiştir.

Sınıflandırma Performansının Değerlendirilmesi: Modelin başarımı F1 skoru ile ölçülmüştür. Çok sınıflı (multiclass) ve ikili (binary) sınıflandırma modelleri karşılaştırılmıştır. Çıkan sonuçlara göre, çok sınıflı sınıflandırma modeli özellikle "hafif hasar" ve "büyük hasar" sınıflarında düşük performans göstermiştir. İkili sınıflandırma modelinde "hasarsız" ve "hasarlı" olarak iki kategori kullanılarak doğruluk artırılmıştır.

3.24.3 Sonuçlar

Rüzgar hasarı (hortum ve kasırga) en iyi çok sınıflı modelle tespit edilmiştir; %70 F1 skoru belirlenmiştir. Yangın, sel ve tsunami hasarları için ikili sınıflandırma modeli daha iyi sonuç vermiştir; F1 skoru sırasıyla %81, %54, %75 belirlenmiştir. Deprem ve volkan hasarı için xBD veri seti yetersizdir ve daha fazla veri gereklidir. Modelin

eđitimi sırasında erken durdurma ve uzun dđnemli eđitim teknikleri kullanılarak aşırı öğrenme önlenmiştir. Veri dengesizliđi giderilmezse, çok sınıflı yerine ikili sınıflandırma modeli tercih edilmelidir. Bu çalışma, bina hasar tespiti için derin öğrenme modellerinin nasıl geliştirilebileceđini kapsamlı bir şekilde analiz etmiş ve farklı dođal afet türleri için en uygun modelleme yaklaşımlarını belirlemiştir. Şekil 3.41’de modelin tespit performansı gösterilmiştir.



Şekil 3.41 : ResNet-50 temelli modelin tespit performansı.

3.25 Yayın 25: RGB Uydu Verisinden U-Net Modeli ile Hasar Tespiti

3.25.1 Amaç

Bu çalışma (Rashidian vd., 2021), dođal afetler sonrasında yıkılmış binaların tespit edilmesini hızlandırmak amacıyla yüksek çözünürlüklü uydu görüntülerini ve derin öğrenme yöntemlerini kullanarak otomatik bir sınıflandırma modeli geliştirmeyi hedeflemektedir. Hızlı ve dođru bir şekilde hasar tespiti yaparak arama-kurtarma


operasyonlarını desteklemek ve afet yönetimini iyileştirmek amaçlanmaktadır. Şekil 3.42’de modelin tespit performansı gösterilmiştir.

3.25.2 Yöntemler

Çalışmada, xView adlı yüksek çözünürlüklü uydu görüntüleri içeren etiketli bir veri seti kullanılmıştır. Yapılar, yıkılmış ve sağlam olarak etiketlenmiş, bu veri seti kullanılarak değiştirilmiş U-Net tabanlı bir konvolüsyonel sinir ağı (CNN) eğitilmiştir. Veri seti, 30 cm mekansal çözünürlüğe sahip RGB uydu görüntülerinden oluşmaktadır. Modelin performansı, 19 Eylül 2017’de M7.1 büyüklüğündeki Puebla, Meksika depremi sonrası Google Earth görüntüleri üzerinde test edilerek değerlendirildi. Model eğitimi sırasında veri dengesizliği önlenmiş, veri artırma (augmentation) teknikleri ve düzenleme yöntemleri (batch normalization ve dropout) uygulanmıştır.

3.25.3 Sonuçlar

Önerilen model, xView veri setinde yıkılmış binaları %76, sağlam binaları %95 duyarlılıkla tespit etmiştir. Puebla depremi sonrası yeni bir veri setinde test edildiğinde ise yıkılmış binalar için %60, sağlam binalar için %89 duyarlılık elde edilmiştir. Model, yıkılmış binaları yanlışlıkla sağlam olarak sınıflandırma oranını düşük tutarken, bazı yıkılmış binaları tespit edememiştir. Sonuçlar, geliştirilen derin öğrenme tabanlı modelin yüksek çözünürlüklü uydu görüntülerinden yararlanarak hızlı ve doğru bir şekilde yıkılmış bina tespiti yapabileceğini göstermektedir.



Şekil 3.42 : Uydu verisinden işaretlenen ve U-net modeli ile tahmin edilen hasarlı yapılar. Kırmızı çarpı ile işaretliler yanlış tahmin edilenler. (Kırmızı kutu içindekiler yıkılmış, mavi kutu olanlar sağlam binaları gösteriyor.)

3.26 Yayın 26: Çeşitli Afet Türleri için Derin Öğrenme Model Önerisi

3.26.1 Amaç


Bu çalışma (Shao vd., 2020), farklı türdeki doğal afetlerden etkilenen binaların hasar tespitini otomatikleştirmek için BDD-Net adlı bir derin öğrenme tabanlı model önermektedir. Mevcut yöntemlerin belirli afet türlerine odaklanması nedeniyle, farklı afet senaryolarında etkili olabilecek genel bir model geliştirme ihtiyacı doğmuştur. BDD-Net, uzaktan algılama verileriyle her pikselin hasarlı bina, hasarsız bina veya arka plan olarak sınıflandırılmasını sağlamayı amaçlamaktadır.

3.26.2 Yöntemler ve Kullanılan Algoritmalar

Model, Maxar/DigitalGlobe Open Data Programı aracılığıyla elde edilen, öncesi ve sonrası yüksek çözünürlüklü (VHR) uydu görüntüleri ile eğitilmiştir. xBD veri seti kullanılarak, sel, deprem, volkanik patlama, kasırga ve yangın gibi beş afet türü için test edilmiştir.

BDD-Net Modeli, U-Net mimarisine dayalı olup EfficientNet-B0 modeli temel alınarak geliştirilmiştir. Modelin girişine afet öncesi ve sonrası görüntüler birlikte verilerek hasarın daha doğru tespit edilmesi sağlandı. Mobil ters dar boğaz

konvolüsyonu (MBConv) gibi teknikler kullanılarak modelin öğrenme kapasitesi artırıldı. Modelin şeması Şekil 3.43’de gösterilmiştir.



Şekil 3.43 : BDD-Net modeli şeması.


Veri artırma teknikleri (çevirme, döndürme, ölçekleme, renk kaydırma) uygulanmıştır. Giriş verileri normalize edilerek model eğitiminin daha hızlı ve dengeli olması sağlanmıştır. Sınıf dengesizliği sorununu çözmek için Dice Loss ve Focal Loss kayıp fonksiyonu kombinasyonu kullanılmış; böylece küçük veya nadir hasar örneklerinin model tarafından daha iyi öğrenilmesi sağlanmıştır.

Model eğitiminde stokastik gradyan inişi (SGD) ve ADAM optimizasyon yöntemi kullanılmıştır. Önceden ImageNet veri seti üzerinde eğitilmiş EfficientNet ağı, transfer öğrenme yöntemiyle kullanılmıştır.

3.26.3 Sonuçlar

BDD-Net, farklı afet türleri için yüksek doğrulukta hasar tespiti gerçekleştirmiştir. Öncesi ve sonrası görüntülerin birlikte kullanılması, yalnızca sonrası görüntülerin kullanılmasına göre F1-skorunu önemli ölçüde artırmıştır. Model, hurricane (kasırga) senaryosunda en yüksek F1-skoruna (87.9%) ulaşmıştır. Dice Loss ve Focal Loss

kombinasyonu, diğer kayıp fonksiyonlarına kıyasla daha iyi sonuçlar vermiştir. BDD-Net, binaların yok olduğu veya büyük ölçüde zarar gördüğü senaryolarda bile etkili şekilde hasar tespiti yapmıştır. Şekil 3.44’de modelin afet öncesi ve sonrası verisi kullanımına göre performansı gösterilmiştir.



Şekil 3.44 : Yöntemin afet öncesi ve sonrası görüntülerin kullanımına göre hasar tespit performansı.

3.27 Yayın 27: Hasar Tespitinde Kullanılan Çeşitli Derin Öğrenme Modellerinin İncelemesi

3.27.1 Amaç

Bu çalışma (L. Wang vd., 2024), uzaktan algılama verileri kullanılarak derin öğrenme modelleriyle afet sonrası bina hasar tespitine dair yapılan araştırmaları kapsamlı bir şekilde gözden geçirmektedir. Çalışma, literatürdeki 242 makaleyi analiz ederek kullanılan veri kümeleri, derin öğrenme modelleri ve uygulama alanlarını ele almaktadır. Ayrıca, hasar tespit modellerinin doğruluk seviyelerini ve karşılaşılan temel zorlukları tartışarak gelecekteki araştırmalara yönelik öneriler sunmaktadır.

3.27.2 Yöntemler

Veri Kümesi Analizi: Çalışma, bina hasarı tespitinde kullanılan kamuya açık 13 veri kümesini belirlemiş ve bunları uydu, hava ve yer görüntüleri olarak sınıflandırmıştır.

Derin öğrenme modellerinde iki temel yaklaşıma odaklanılmıştır:

- İki Zamanlı (Bitemporal) Yaklaşım: Afet öncesi ve sonrası görüntüler karşılaştırılarak hasar tespiti yapılır.
- Tek Zamanlı (Single-Temporal) Yaklaşım: Sadece afet sonrası görüntüler kullanılarak bina hasarı belirlenir.

Çalışma, bina hasar tespitinde yaygın olarak kullanılan dört ana derin öğrenme modelini detaylı şekilde incelemiştir:

- Konvolüsyonel Sinir Ağları (CNN): Görüntü sınıflandırma ve özellik çıkarımı için kullanılmıştır.
- DeconvNet: Görüntü segmentasyonu ve detaylı rekonstrüksiyon için tercih edilmiştir.
- Dikkat Mekanizmaları (Attention Mechanisms - AM): Modelin belirli alanlara odaklanmasını sağlayarak doğruluğu artırmıştır.
- Üretken Karşıt Ağlar (Generative Adversarial Network - GAN): Hasarlı bina görüntülerinin kalitesini artırmak ve eğitim için eksik veri oluşturmak amacıyla kullanılmıştır.

Modeller, doğruluk, hassasiyet (precision), duyarlılık (recall) ve F1 skoru gibi metrikler kullanılarak değerlendirilmiştir.

3.27.3 Sonuçlar

Hasarlı bina tespiti için kamuya açık veri kümelerinin azlığı, model eğitimi için büyük bir engeldir. Çift zamanlı yöntemler daha yüksek doğruluk sağlasa da veri işleme açısından zorluklar barındırmaktadır. Tek zamanlı yöntemler ise daha hızlı uygulanabilir ancak doğruluk açısından sınırlıdır. CNN tabanlı yöntemler yaygın şekilde kullanılmaktadır, ancak DeconvNet ve AM destekli modeller daha yüksek doğruluk seviyelerine ulaşabilmektedir. İki seviyeli sınıflandırmada (hasarlı/hasarsız) doğruluk %52.2 ile %95.82 arasında değişirken, dört seviyeli sınıflandırmada (hafif, orta, ağır hasar ve yıkılmış) doğruluk %14 ile %86.5 arasında değişmektedir. Uydu,

hava ve yer görüntülerinin birleştirilmesi, model performansını artıran önemli bir faktör olarak belirlenmiştir.

3.28 Yayın 28: Hasar Tespiti için Sınırlı Denetimli Derin Öğrenme Modeli

3.28.1 Amaç

Bu makale (Qiao vd., 2024), yüksek çözünürlüklü uzaktan algılama (HRRS) görüntülerini kullanarak afet sonrası bina hasarını hızlı ve doğru bir şekilde tespit etmek için zayıf denetimli (weakly supervised) yeni bir yöntem önermektedir. Şekil 3.45’de modele ilişkin şema bulunmaktadır. Geleneksel yöntemlerin bina sınırlarını belirlemede zorlanması ve yanlış değişiklikleri tespit etme riskleri nedeniyle, hem afet öncesi hem de sonrası görüntüleri kullanan bir model geliştirilmiştir.

3.28.2 Yöntemler


Çift Zamanlı (Pre/Post-Disaster) Görüntü Kullanımı: Afet öncesi görüntülerden bina sınırları belirlenerek, afet sonrası hasar tespitinde daha hassas sonuçlar elde edilmektedir.

Tam Konvolüsyonel Ağ (FCN-Fully Co) ve Süperpiksel Segmentasyonu: Afet öncesi bina bölgeleri, FCN modeli ve süperpiksel segmentasyonu ile ince alt-bina seviyesine kadar detaylandırılmaktadır.

Zayıf Denetimli Yapay Zeka Yaklaşımı: Afet sonrası görüntülerde yalnızca etiketlenmiş görüntü yama (patch) bilgisine dayanarak piksel seviyesinde bina hasarı haritası çıkarılmaktadır.

Geniş Çok Ölçekli (Wide Multi-Scale - WMS) Bloğu: Çeşitli genişlik ve ölçeklerde derin özellikleri öğrenerek modelin bina hasarlarını daha iyi tanıyabilmesini sağlamaktadır.

CNN Modeli ile Güvenilirlik Vektörü Üretimi: Post-disaster görüntüler için CNN modeli kullanılarak her görüntü yaması için güvenilirlik vektörleri oluşturulmuş ve nihai bina hasar haritası bir oylama mekanizması ile üretilmiştir.




Şekil 3.45 : Önerilen zayıf denetimli - weakly supervised model.

3.28.3 Sonuçlar

2010 Haiti Depremi veri seti kullanılarak yapılan deneyler, önerilen yöntemin mevcut metodolojilere kıyasla daha yüksek doğruluk sağladığını göstermektedir. %95.31 doğruluk (OA) ve %75.69 MIoU skoru ile en iyi zayıf denetimli yöntem olduğu kanıtlanmıştır.

U-Net gibi tam denetimli modeller ile karşılaştırıldığında, önerilen modelin yalnızca az bir performans kaybı yaşadığı ancak çok daha az etiketleme gerektirdiği görülmüştür. Pre-disaster bina sınırlarının kullanılması, sahte pozitiflerin azaltılmasına ve daha hassas hasar tespiti yapılmasına önemli katkı sağlamıştır. Şekil 3.46'de yöntemin hasar tespit performansı gösterilmiştir.



Şekil 3.46 : Yöntemin hasar tespit performansı.

3.29 Yayın 29: Yerden Alınan Görüntüler ve YOLOv5 ile Hasar Tespiti

3.29.1 Amaç

Çalışmada önerilen yöntem, deprem sonrası bina hasar tespiti ve acil durum müdahalelerinin zamanında ve etkili bir şekilde gerçekleştirilmesini sağlamayı amaçlamaktadır. Uydu ve drone görüntüleri büyük ölçekli hasar tespiti için kullanışlıdır, ancak detaylı küçük çaplı hasarları tespit etmekte yetersiz kalır. Yer seviyesinden çekilen yüksek çözünürlüklü görüntüler, bina yüzeyindeki çatlaklar ve dökülmeler gibi ayrıntılı hasarları tespit etmek için uygun bir alternatif sunar. Bu çalışmada (Liu vd., 2022), deprem sonrası bina hasarlarını tespit etmek için YOLOv5 modelini optimize eden hafif ve hızlı bir model önerilmiştir.


3.29.2 Yöntemler

Çalışmada YOLOv5s modeli temel alınarak optimize edilmiş ve LA-YOLOv5 (Lightweight and Accurate YOLOv5) modeli geliştirilmiştir. Modelin iyileştirilmesi için şu bileşenler eklenmiştir:

- Ghost Bottleneck: Modelin boyutunu küçültmek ve gereksiz parametreleri azaltmak için YOLOv5'in omurga (backbone) ve boyun (neck) katmanlarına entegre edilmiştir.
- CBAM (Convolutional Block Attention Module): Modelin bina hasarlarını daha iyi öğrenmesini sağlamak için dikkat mekanizması eklenmiştir.
- Bi-FPN (Bi-Directional Feature Pyramid Network): Farklı ölçeklerdeki hasarları daha iyi algılayabilmek için çok ölçekli özellik füzyonu gerçekleştirilmiştir.
- DSCONV (Depthwise Separable Convolution): Hesaplama maliyetini azaltmak ve modelin gömülü sistemlerde çalışabilirliğini artırmak için boyun katmanına dahil edilmiştir.

3.29.3 Sonuçlar

Önerilen modelin hasar tespit doğruluğu %90'ın üzerindedir ve önceki YOLOv5 tabanlı modellerden daha hızlı ve daha hafiftir. Model, diğer hafif nesne tespit algoritmaları (MobileNet-SSD, Nanodet, MobileDets) ile karşılaştırıldığında daha yüksek doğruluk ve daha düşük işlem süresi sunmuştur. LA-YOLOv5 modeli, bina hasar tespiti için hızlı, doğru ve hafif bir çözüm sunmaktadır. Model, düşük donanım gereksinimiyle akıllı telefonlar ve gömülü cihazlara entegre edilebilir. Hırvatistan ve Luxian deprem verileri üzerinde yapılan testlerde modelin farklı bölgelerde de iyi performans gösterdiği görülmüştür. Şekil 3.47'de LA-YOLOv5 yönteminin hasar tespit performansı gösterilmiştir.



Şekil 3.47 : LA-YOLOv5 yönteminin hasar tespit performansı.

3.30 Yayın 30: Çoklu Özellik Kullanımı ile Hasar Tespiti

3.30.1 Amaç

Çin'deki büyük şehirlerin çoğu yüksek deprem riski altında bulunuyor ve deprem sonrası hasar tespiti, kayıpların değerlendirilmesi ve acil müdahale için kritik önem taşıyor. Ancak görüntü tabanlı değişim tespiti, bina dışındaki çevresel faktörlerin ve çeşitli doku özelliklerinin neden olduğu karmaşıklık nedeniyle zorluklarla karşılaşılıyor. Bu bağlamda, çoklu özellik füzyonuna dayalı tek bina hasar tespiti için yeni bir model önerilmektedir. Model, normalleştirilmiş Dijital Yüzey Modeli (nDSM) kullanarak bina konturlarını çıkarır ve görüntü verilerinden elde edilen optimum doku özelliklerini birleştirerek daha doğru sonuçlar elde etmeyi amaçlar. Çalışmada (H. Du vd., 2024), modelin performansı farklı yöntemlerle karşılaştırılarak Yangbi ve Honghe depremlerinde test edilmiştir.

3.30.2 Kullanılan yöntemler

Makale, deprem sonrası bina hasarlarının hızlı ve doğru bir şekilde tespit edilmesi amacıyla çoklu özellik füzyonuna dayalı bir model önermektedir. Bu modelin

oluşturulması için öncelikle insansız hava aracı (UAV) ve uydu görüntüleri kullanılarak deprem öncesi ve sonrası yüksek çözünürlüklü veri toplanmıştır. Hasarın daha iyi tespit edilebilmesi için Dijital Yüzey Modeli (DSM) işlenerek, yükseklik değişimlerini belirleyen Normalleştirilmiş Dijital Yüzey Modeli (nDSM) elde edilmiştir. Bu süreçte iteratif filtreleme ve nokta bulutu seyreltme teknikleri kullanılarak gereksiz bilgiler ayıklanmış, ardından morfolojik işlemler ve küçük alan temizleme yöntemleri ile bina konturları netleştirilmiştir.


Modelin doğruluğunu artırmak için bina bölgesi bazlı görüntü işleme (ROI – Region of Interest) yöntemi kullanılmıştır. Bu yöntemde nDSM'den elde edilen bina konturları referans alınarak farklı veri kaynaklarından gelen görüntülerde ilgili binalar belirlenmiş ve hassas eşleştirme algoritmalarıyla hizalanmıştır. Binalardaki yapısal değişiklikleri analiz etmek amacıyla gri-seviye ortaklık matrisi (GLCM) ile mean (ortalama), entropy (entropi) ve dissimilarity (benzerlik farkı) gibi önemli doku özellikleri çıkarılmıştır. Bu özelliklerin çoklu zamanlı değişim analizi yapılmış ve bina bazlı hasar tespiti için özellik füzyonu gerçekleştirilmiştir.

Modelin bilgi fazlalığını azaltarak daha doğru sonuçlar üretmesi için Ana Bileşen Analizi (PCA) uygulanmıştır. PCA sayesinde çok sayıda doku özelliği arasındaki ilişkiler optimize edilerek gereksiz bilgiler filtrelenmiş ve görüntüdeki gürültü bastırılmıştır. Daha sonra korelasyon değişim analizi kullanılarak deprem sonrası binalarda meydana gelen yapısal değişiklikler değerlendirilmeye alınmış ve binalar “temel olarak sağlam”, “orta derecede hasarlı” ve “ağır hasarlı” olarak sınıflandırılmıştır.

3.30.3 Sonuçlar

Önerilen model, deprem sonrası bina hasarlarını tespit etmek için geliştirilmiş ve çoklu özellik füzyonu yaklaşımıyla doğruluğu artırılmıştır. Modelin uygulanması sonucunda, nDSM kullanılarak bina konturlarının hassas bir şekilde çıkarılabildiği, doku özelliklerinin füzyonu sayesinde değişim tespitinin daha güvenilir hale getirildiği ve PCA ile bilgi fazlalığının azaltılarak gürültünün bastırıldığı görülmüştür. Modelin farklı deprem bölgelerinde test edilmesi, yöntemin genellenebilirliğini ve taşınabilirliğini doğrulamış, uydu ve UAV görüntülerinin birleştirilmesinin tespit doğruluğunu artırdığı belirlenmiştir. Test değerlendirmesinde %88 üzerinde ortalama doğruluk ve 0.8 kappa değeri elde edilmiştir. Şekil 3.48’de uygulamanın performans

kıyaslaması görsel olarak verilmiştir. Yapılan karşılaştırmalar, modelin makine öğrenmesi tabanlı geleneksel yöntemlerden daha yüksek başarı sağladığını ve hasar tespit sürecini hızlandırarak afet sonrası müdahaleyi destekleyebileceğini göstermiştir. Sonuç olarak, bu modelin, büyük ölçekli deprem bölgelerinde tekil bina hasarlarını doğru şekilde tespit etmek için etkili bir araç olduğu kanıtlanmış ve acil durum yönetimi ile afet risk azaltma çalışmalarına katkı sağlayabileceği vurgulanmıştır.



Şekil 3.48 : Çoklu özellik füzyonuna dayanan modelin, yalnızca İHA görüntüsü kullanarak ve uydu - İHA görüntülerinin bir arada kullanılmasıyla yapılan performans karşılaştırılması.

3.31 Yayın 31: Derin Öğrenme ve Superpiksel Düzeyinde Değişim Tespiti ile Hasar Tespiti


3.31.1 Amaç

Makalenin (Qing vd., 2022) amacı, deprem sonrası bina hasar değerlendirmesini hızlı ve doğru bir şekilde gerçekleştirmek için CNN tabanlı doğrudan uzaktan algılama değişim tespiti yöntemini kullanarak operasyonel bir değerlendirme çerçevesi önermektir. Mevcut yöntemlerin düşük verimlilik ve hassasiyet sorunlarına çözüm

getirmek amacıyla, çalışma, süperpiksel düzeyinde doğrudan değişim tespiti stratejisini benimseyerek, hem bina lokalizasyonunu hem de hasar sınıflandırmasını entegre eden tek aşamalı bir süreç sunmaktadır. Önerilen yöntem, Ludian depremi sonrası saha çalışmalarıyla doğrulanmış olup, gelecekteki afet yönetimi ve acil durum müdahalelerine katkı sağlamayı hedeflemektedir.

3.31.2 Kullanılan yöntemler


Makale, deprem sonrası bina hasar tespiti için CNN tabanlı doğrudan değişim tespiti yöntemini kullanmaktadır. Çalışma, Şekil 3.49'daki gibi üç aşamalı bir hiyerarşik iş akışı önermektedir. İlk aşamada, Ekstra Özellik Geliştirme Bantları (EFEBs) kullanılarak depremden etkilenme olasılığı yüksek bina bölgeleri belirlenir. İkinci aşamada, süperpiksel tabanlı doğrudan değişim tespiti (PreSC - Pre-event Superpixel Constraint) stratejisi ile bina hasar analizi gerçekleştirilir. Son aşamada ise, hızlı uzaktan algılama deprem hasar indeksi (rRSEDI) kullanılarak bölgesel hasar değerlendirilmesi yapılır. Derin öğrenme tabanlı CECNN modeli (Channel-Expanded CNN) ile çok bantlı görüntü analizi gerçekleştirilerek, bina sınırlarının korunması ve hasar derecesinin hassas bir şekilde belirlenmesi sağlanmaktadır. Modelin doğruluğu, saha çalışmalarıyla kıyaslanarak değerlendirilmiş ve önerilen yöntemin mevcut yöntemlerden daha hızlı ve etkili olduğu gösterilmiştir.



Şekil 3.49 : CECNN modeli kullanılarak uygulanan bina hasar tespit adımları şeması.

3.31.3 Sonular

Önerilen CNN tabanlı doğrudan deęişim tespiti yöntemi, deprem sonrası bina hasarlarını hızlı ve doğru bir şekilde tespit etmede başarılı bulunmuştur. Deneysel alışmalar, yöntemin mevcut tek aşamalı ve iki aşamalı yöntemlere kıyasla daha yüksek doğruluk ve daha az işlem süresi sunduğunu göstermiştir. CECNN modeli ve EFEBs kullanımı, bina bölgelerinin daha net belirlenmesini ve hata oranlarının azaltılmasını sağlamıştır. Deęerlendirme sonucunda ortalama doğruluk %89 ve 0.78 kappa deęeri belirlenmiştir. PreSC stratejisi, binaların orijinal sınırlarının korunmasına yardımcı olarak, hasar sınıflandırmasının doğruluğunu artırmıştır. Ludian depremi sonrası elde edilen sonuçlar, resmi hasar raporlarıyla büyük ölçüde örtüşerek yöntemin güvenilirliğini kanıtlamıştır. Şekil 3.50’de yöntemin performansı ve dięer yöntemlerle kıyaslaması verilmiştir. Genel olarak, bu yaklaşımın, afet yönetimi ve hızlı müdahale süreçlerine etkin bir katkı sağlayabileceęi sonucuna varılmıştır.




Şekil 3.50 : PreSC stratejisi kullanılarak yapılan performans testi ve diğer yöntemlerle karşılaştırılması.

3.32 Yayın 32: Denetimsiz Derin Öğrenme Yöntemiyle Hasar Tespiti

3.32.1 Amaç

Makalenin (Y. Li vd., 2020) amacı, denetimsiz alan uyarlama (unsupervised domain adaptation) yöntemlerini kullanarak afet sonrası bina hasar tespitini daha hızlı ve doğru bir şekilde gerçekleştirmektir. Özellikle, etiketlenmiş veri eksikliğinin büyük bir problem olduğu bu tür durumlar için makale, Şekil 3.51’de gösterilen Generative Adversarial Networks (GAN) ve self-attention mekanizmasını birleştiren USADA (Unsupervised Self-Attention Domain Adaptation) modelini önermektedir. Bu model, kaynak alan görüntülerini hedef alan görüntülerine piksel düzeyinde uyarlayarak, etiketlenmemiş veriler üzerinde daha başarılı bir hasar tespiti sağlamayı amaçlamaktadır. USADA’nın, geleneksel piksel seviyesinde alan uyarlama yöntemlerine kıyasla bina hasar tespitinde daha iyi performans gösterdiği deneysel sonuçlarla ortaya konulmuştur.



Şekil 3.51 : USADA modeli şeması.

3.32.2 Yöntemler

Makale, denetimsiz alan uyarlama için Generative Adversarial Networks (GAN) ve self-attention mekanizmasını birleştiren USADA (Unsupervised Self-Attention Domain Adaptation) modelini önermektedir. Model üç bileşenden oluşur: (1) GAN

tabanlı bir çevirici, kaynak alan görüntülerini hedef alan görüntülerine piksel düzeyinde dönüştürerek, hedef alana daha iyi uyarlanmasını sağlar, (2) self-attention mekanizması, önemli yapısal bilgileri koruyarak modelin bina hasarlarını daha iyi ayırt etmesine yardımcı olur, (3) sınıflandırıcı, hem kaynak hem de üretilen görüntülerden öğrenerek hasarlı ve hasarsız binaları ayırt etmek için eğitilir. Model, L1 düzenleme kaybı ile orijinal görüntülerin önemli yapılarını korurken, spektral normalizasyon gibi tekniklerle GAN eğitimini dengeli hale getirir. Yöntemin etkinliği, farklı kasırga afetlerine ait hava görüntüleri üzerinde test edilerek, geleneksel alan uyarlama yöntemlerine kıyasla daha yüksek sınıflandırma doğruluğu ile gösterilmiştir.

3.32.3 Sonuçlar

Makale sonuçlarında, önerilen USADA modelinin, bina hasar tespitinde geleneksel denetimsiz alan uyarlama yöntemlerine kıyasla daha yüksek doğruluk sağladığı gösterilmiştir. Model, Hurricane Sandy, Maria ve Irma afetlerinden elde edilen hava görüntüleri üzerinde test edilerek, USADA'nın PixelDA gibi önceki yöntemlere göre %2.0 ila %3.6 arasında daha iyi sınıflandırma doğruluğu elde ettiği tespit edilmiştir. Ortalama F1 skoru %72 ve doğruluk değeri %76 olarak hesaplanmıştır. Özellikle self-attention mekanizmasının, üretilen görüntülerde bina ön plan bilgisini koruyarak modelin daha başarılı sonuçlar üretmesini sağladığı belirlenmiştir. T-SNE ile yapılan görselleştirmeler, modelin özellik alanında kaynak ve hedef verileri daha iyi hizaladığını göstermiştir. Genel olarak, USADA'nın, etiketlenmiş veri ihtiyacını ortadan kaldırarak afet sonrası bina hasar tespitini daha hızlı ve etkili hale getirdiği sonucuna varılmıştır.

3.33 Yayın 33: Afet Bölgesinde Dron Rota Planlamasında Hasar Tespiti Algoritmalarından Faydalanılması


3.33.1 Amaç

Bu makalenin (Hu vd., 2023) amacı, doğal afetler sonrası bina hasar tespitini hızlandırmak ve optimize etmek için drone tabanlı otomatik bir keşif yöntemi geliştirmektir. Çalışma, dronlar tarafından toplanan görüntülerin derin öğrenme yöntemleriyle analiz edilerek bina hasarlarını tespit ve sınıflandırmasını sağlamayı hedefler. Ayrıca, elde edilen hasar bilgilerini drone görev planlamasına entegre ederek arama ve kurtarma operasyonlarının etkinliğini artırmayı amaçlamaktadır. Makale,

Tennessee'de bir kasırga sonrası gerçekleştirilen vaka çalışmasıyla önerilen yöntemin doğruluğunu ve pratik uygulanabilirliğini test etmektedir.

3.33.2 Yöntemler

Bu çalışmada bina hasar tespiti ve sınıflandırması için Şekil 3.52’de şeması verilen derin öğrenme tabanlı bir yöntem geliştirilmiştir. YOLOv5 (You Only Look Once) mimarisi kullanılmıştır. YOLO, hızlı ve doğruluk oranı yüksek bir nesne tespit algoritması olup, bu çalışmada YOLOv5s (small) modeli tercih edilmiştir. Ayrıca modelin performansını artırmak için koordinat tabanlı dikkat mekanizması (Coordinate Attention) ve Alpha-IoU loss (Alpha Intersection over Union Loss) gibi optimizasyon teknikleri uygulanmıştır.



Şekil 3.52 : YOLOv5s kullanılan yöntem adımları şeması.

Bu çalışmada Enhanced Fujita Scale Building Damage (EFSBD) veri seti oluşturulmuş ve kullanılmıştır. Veri seti, büyük kasırgalar sonrasında hasar gören binaların havadan çekilmiş görüntülerini içerir ve şu özelliklere sahiptir:

Toplam 3.045 hava görüntüsü içerir. Görüntüler, ABD ve Kanada’daki 25 farklı şehirde meydana gelen kasırgalardan toplanmıştır. 34 farklı hava videosundan elde edilen görüntüler kullanılmıştır. 32 video çevrimiçi kaynaklardan toplanmış, 2 video ise araştırmacılar tarafından 2020 Nashville kasırgası sonrasında çekilmiştir. Şekil 3.53’de EFSBD veri seti ile yapılan bir hasar tespit testi görülmektedir.

Görüntüler Federal Acil Durum Yönetim Ajansı (FEMA) ve Ulusal Hava Durumu Servisi (NWS) tarafından belirlenen Enhanced Fujita (EF) ölçeği ile etiketlenmiştir.

24.496 bina hasar örneği içermektedir. Hasar seviyeleri 7 farklı sınıfa ayrılmıştır:

- Minor (Hafif)
- Moderate (Orta)
- Considerable (Önemli)
- Severe (Ağır)
- Devastating (Yıkıcı)
- Incredible (Felaket Boyutunda)
- Tarp (Çatı Örtüsü ile Kaplı – hasar seviyesi belirlenemeyen binalar)

Bu veri seti, drone görüntülerinden binaların hasar derecelerini tespit etmek için YOLOv5 tabanlı modelin eğitilmesinde kullanılmıştır.

Drone görev planlaması için ise Optimizasyon Algoritmaları kullanılmıştır:

- Genetik Algoritma (GA)
- Karınca Kolonisi Optimizasyonu (ACO)
- Parçacık Sürü Optimizasyonu (PSO)
- BITEOPT (BITmask Evolution OPTimization)

Deneyler sonucunda, bina hasar tespitinde YOLOv5s modeli kullanılarak %71.9 mAP (mean average precision) elde edilmiştir. BITEOPT algoritması, drone görev planlaması için en iyi performansı gösteren optimizasyon yöntemi olmuştur.

3.33.3 Sonuçlar

Mevcut manuel değerlendirme yöntemlerine kıyasla daha hızlı ve daha doğru bina hasar tespiti sağlanmış. Drone görev planlamasında otomasyon ve optimizasyon sağlanarak operasyon verimliliği artırılmıştır. Derin öğrenme tabanlı sistem, geleneksel görüntü analiz yöntemlerinden daha başarılı sonuçlar üretmiştir.

Daha geniş ve çeşitli bir veri seti ile modelin genel geçerliliği artırılabilir. Hasar seviyelerinin daha detaylı ayrıştırılması için farklı derin öğrenme yaklaşımları (örneğin Transformer tabanlı modeller) test edilebilir. Drone görev planlamasında gerçek zamanlı veri entegrasyonu sağlanarak süreçler daha dinamik hale getirilebilir.

Sonuç olarak, çalışma afet yönetimi süreçlerinde drone ve yapay zeka tabanlı otomatik sistemlerin büyük bir potansiyele sahip olduğunu kanıtlamaktadır. Özellikle arama-

kurtarma ekipleri ve afet müdahale birimleri için zaman kazandırıcı ve hayat kurtarıcı bir teknoloji sunmaktadır.



Şekil 3.53 : EFBSD veri seti kullanılarak yapılan test.


3.34 Yayın 34: Afet Sonrası İHA Görüntüleriyle Hızlı Hasar Tespiti

3.34.1 Amaç

Bu makalenin (Jozi vd., 2024) amacı, insansız hava araçları (UAV) kullanarak afet sonrası hasar görmüş konutların hızlı bir şekilde değerlendirilmesini sağlamaktır. Geleneksel yöntemlerin yavaş ve erişim açısından kısıtlı olması nedeniyle, bu çalışma, UAV ile elde edilen görüntüleri kullanarak otomatik hasar tespitine yönelik bir görüntü işleme tabanlı yaklaşım önermektedir. Yöntemin çalışma şeması Şekil 3.54’de sunulmuştur. Çalışma, doku analizi (düzensizlik ve homojenlik) ve kenar analizi (Canny kenar tespiti ile düzensizlik ve açı dağılımı) gibi özellikleri çıkararak, bu verileri Naïve Bayes Sınıflandırıcısı ile işleyerek binaları hasarlı veya hasarsız olarak sınıflandırmaktadır. Gerçek afet sonrası görüntüler üzerinde test edilen bu yöntem, %89.3 doğruluk oranına ulaşarak UAV görüntülerinin ve gelişmiş görüntü işleme tekniklerinin hızlı ve güvenilir hasar tespiti için büyük bir potansiyele sahip olduğunu göstermektedir.

3.34.2 Kullanılan yöntemler

Makale, afet sonrası bina hasar tespiti için görüntü işleme teknikleri ve Makine Öğrenmesi (ML) algoritmalarını bir araya getiren bir yöntem önermektedir.



Şekil 3.54 : Naive Bayes kullanılarak geliştirilen yöntemin işlem adımları.

Doku ve kenar analizi gibi görüntü işleme teknikleri kullanılarak çeşitli özellik çıkarımı işlemleri uygulanmıştır.

Gri Düzey Eş Olabilirlik Matrisi (GLCM) kullanılarak benzemezlik (dissimilarity) ve homojenlik (homogeneity) özellikleri çıkarılmıştır.

Kenar analizi için, Canny Kenar Algılama yöntemi ile kenar entropisi hesaplanarak düzensizlik tespiti yapılmıştır. Hough Dönüşümü ile kenar çizgileri belirlenmiş ve kenar açısı dağılımı incelenmiştir.

Naïve Bayes sınıflandırıcısı ile hasarlı ve hasarsız binaları sınıflandırmak için olasılıksal bir model geliştirilmiştir. Doku ve kenar analizlerinden elde edilen dört özellik (düzensizlik, homojenlik, kenar entropisi, açı dağılımı) sınıflandırıcıya girdi olarak verilmiştir. Normal dağılıma uygun olasılık fonksiyonları oluşturulmuş ve Bayes Teoremi kullanılarak olasılık hesaplanmıştır.

Derin öğrenme (CNN, GAN, Transformer gibi modeller) yerine daha az hesaplama gücü gerektiren bir özellik tabanlı sınıflandırma yöntemi kullanılmıştır. Görüntü işleme tabanlı model, öğrenme süreci gerektirmeden doğrudan özellik çıkarımı yaparak hızlı karar almayı sağlamaktadır.

Önerilen Naïve Bayes sınıflandırma modeli, %89.3 doğruluk oranına ulaşarak gerçek afet sonrası görüntülerde başarılı bir şekilde hasarlı binaları tespit etmiştir.

Sonuç olarak, çalışma, görüntü işleme teknikleriyle özellik çıkarımı ve Naïve Bayes modeliyle olasılıksal sınıflandırma yaparak, hızlı ve hesaplaması düşük bir hasar tespit sistemi geliştirmiştir.

3.34.3 Sonuçlar

Bu çalışma, insansız hava araçları (UAV) ile elde edilen görüntüler üzerinden hızlı ve otomatik afet sonrası bina hasar tespiti için görüntü işleme tabanlı bir yöntem geliştirmiştir. Doku analizi (benzemezlilik ve homojenlik) ve kenar analizi (kenar entropisi ve açı dağılımı) kullanılarak belirlenen özellikler, Naïve Bayes sınıflandırıcısı ile işlenerek hasarlı ve hasarsız binaların tespiti sağlanmıştır. Gerçek afet sonrası görüntüler üzerinde yapılan testlerde %89.3 doğruluk oranı elde edilerek yöntemin etkinliği kanıtlanmıştır. Şekil 3.55’de önerilen yöntem kullanılarak İHA görüntüsünden hasar tespiti yapılması gösterilmiştir. Geleneksel yöntemlere kıyasla daha hızlı, erişilebilir ve düşük maliyetli bir değerlendirme sunan bu model, afet sonrası acil müdahale ve kaynak yönetimi süreçlerinde önemli bir katkı sağlayabilir. Gelecekte daha büyük ve çeşitli veri setleriyle test edilerek hasarın derecesini belirleyebilen daha kapsamlı bir sistem haline getirilebilir.



Şekil 3.55 : Yöntem kullanılarak yapılan hasar tespit uygulaması: U: Undamaged ve D: Damaged.


3.35 Yayın 35: U-Net Kullanılarak Afet Öncesi ve Sonrası Verilerle Hasar Tespiti

3.35.1 Amaç

Bu çalışmanın (Wu vd., 2021) amacı, afet sonrası bina hasar tespitinde U-Net tabanlı bir derin öğrenme modelinin performansını değerlendirmektir. Çalışma, afet öncesi ve sonrası uydu görüntülerini kullanarak bina hasarlarının konumlandırılması ve hasar derecelerinin sınıflandırılmasını hedeflemektedir. Geleneksel yöntemlerin genellikle ikili sınıflandırmaya (hasarlı/hasarsız) odaklandığı göz önüne alındığında, bu araştırma, birden fazla hasar seviyesini tespit edebilen ve modelin odak mekanizmasını optimize eden bir Siamese U-Net mimarisi önermektedir. Çeşitli geri besleme (backbone) ağları ile deneyler yapılarak en iyi performansı veren model belirlenmiştir. Şekil 3.56’da modelin işlem adımları sunulmuştur. Model, xBD veri kümesiyle eğitilmiş ve farklı felaket senaryoları üzerinde test edilmiştir. Sonuçlar, odak mekanizmasının modelin doğruluğunu artırdığını ve SEresNeXt tabanlı modelin en iyi F1 skoru ile en başarılı performansı sergilediğini göstermektedir. Ayrıca modelin taşınabilirliği ve sağlamlığı, Beyrut patlaması ve Laura Kasırgası gibi yeni afet olayları üzerinde test edilerek doğrulanmıştır.

3.35.2 Kullanılan yöntemler

Afet öncesi ve sonrası görüntüleri karşılaştırmak için çift ağırlık paylaşan bir Siamese sinir ağı kullanılmıştır. Bina hasarlarını tespit etmek için U-Net tabanlı tam konvolüsyonel ağ (FCN) kullanılmıştır. U-Net, yüksek seviye bilgileri konumlandırma ile birleştirerek ayrıntılı segmentasyon sağlar.



Şekil 3.56 : Önerilen U-Net tabanlı yöntemin aşamaları.

Modelin önemli özelliklere odaklanmasını sağlamak için dikkat mekanizması eklenmiştir. Spatial attention (mekansal dikkat), görüntüde önemli alanlara daha fazla odaklanarak gereksiz bilgilerin etkisini azaltmak için kullanılmıştır. Channel-wise attention (kanal bazlı dikkat), farklı kanal özelliklerini seçici olarak vurgulamak için kullanılmıştır (SE-Net yapısında uygulanmıştır).


Çalışmada çeşitli CNN (Convolutional Neural Network) tabanlı mimariler kullanılmış ve karşılaştırılmıştır. ResNet-34, SE-ResNeXt, SENet, DPN (Dual Path Network) mimarileri denenmiştir.

Veri setinde dengeleme uygulanması amacıyla büyük sınıflardan veri azaltılarak dengesizlik önlenmiştir. Hata-yitim fonksiyonu farklı sınıflar için ağırlıklandırarak modelin öğrenme dengesini iyileştirmeye çalışılmıştır. Veri zenginleştirme uygulanarak görüntü çevirme, döndürme, kaydırma, ölçekleme, renk değişimi, gürültü ekleme gibi yöntemler ile modelin genelleme yeteneği artırılmıştır.

Transfer öğrenme (Transfer Learning) ile xBD veri kümesi ile önceden eğitilmiş model ağırlıkları kullanılmıştır. Adam optimizasyonu (Adaptive Moment Estimation - Adam) kullanılarak modelin verimli öğrenmesi sağlanmıştır. Sınıflandırma kaybını azaltmak için F1 skoru bazlı özel bir yitim fonksiyonu kullanılmıştır. Farklı modellerin çıktıları ağırlıklandırılarak birleştirilmiş ve genel doğruluk artırılmıştır.

3.35.3 Sonuçlar

Sonuç olarak, bina hasar tespiti için önerilen Siamese U-Net modeli, dikkat mekanizması (attention mechanism) ve çeşitli derin öğrenme mimarileri (ResNet, SE-ResNeXt, SENet, DPN) ile test edilmiştir. SE-ResNeXt tabanlı model, F1 skoru 0.787 ile en iyi performansı göstermiştir. Farklı modellerin sonuçları birleştirilerek (fusion) genel doğruluk artırılmış ve en iyi toplam F1 skoru 0.792 olarak elde edilmiştir. Şekil 3.57’de füzyon yönteminin test sonuçları gösterilmiştir. Modelin transfer edilebilirliği ve sağlamlığı, Beyrut Patlaması ve Laura Kasırgası gibi yeni afetler üzerinde test edilerek doğrulanmıştır. Dikkat mekanizmasının özellikle sınıflandırma doğruluğunu artırdığı gözlemlenmiş, ancak küçük hasarlı binaların tespitinde hala bazı zorluklar olduğu belirlenmiştir. Gelecekte, farklı afet türlerine özel modeller geliştirilerek doğruluğun daha da artırılması hedeflenmektedir.



Şekil 3.57 : Doğruluk performansını arttıran model füzyonu yöntemi ile elde edilen test sonuçları. (a: Kasırga verisi ground truth, b,c: attention mekanizmasını içeren ve içermeyen sonuçlar)



4. DEĞERLENDİRMELER

4.1 Çalışmaların Değerlendirilmesi

Yıkıcı özellikteki deprem afetlerine dönem dönem maruz kalan ülkemizde, deprem sonrası acil müdahale planlanması amacıyla uzaktan algılama verileri ve yapay öğrenme yöntemlerinin birlikte kullanılması önemlidir. Yapay öğrenme yöntemlerinden faydalanılarak, uydu görüntüleri ve hava fotoğraflarından bina segmentasyonu ve hasar sınıflandırması yapılır, böylece en az çaba ile hızlı ve doğru acil müdahale planlaması yapılabilir.

3. bölümde değerlendirilen akademik çalışmalarda, uydu verisi ve hava görüntüleri ile yapay öğrenme yaklaşımları kullanılarak önerilen hasar tespit yöntemlerinde, yıllar içinde farklı afetler üzerinde yapılan denemelerin olumlu sonuçlar sunduğu ve zamanla yapay öğrenme yöntemlerinin başarımları ölçütleri (performance metrics) açısından da giderek iyileşen doğruluk, kesinlik, F1 ve IoU skoru verdiği görülmüştür. Çizelge 4.1’de yayınlarda kullanılan yapay öğrenme yöntemlerinin mevcut başarı ölçüt değerleri sunulmuştur. Değerlendirilen çalışmalarda kullanılan yapay öğrenme yöntemlerinin başarımlarının artırılması hususunda çeşitli algoritma iyileştirmelerinin yanı sıra, eğitim verisi olarak kullanılan veri setleri üzerinde veri zenginleştirme (data augmentation) işlemleri yapılmıştır. Ayrıca genelleştirme problemi olarak tanımlanan ve modelin farklı afetler için de kullanılabilirliği için de çalışmalar yapılmıştır. Yapay öğrenme yöntemlerinin eğitim süresi ve ihtiyaç duyulan işlem gücü de model verimliliği konusunda değerlendirilen önemli noktalardandır. Bu konularda yapay öğrenme yönteminde belirlenen hiperparametreler ve kullanılan optimizasyon algoritmaları etkili olmuştur. Derin öğrenme modellerinin kullanıldığı modellerde, modelin bileşiminde tercih edilen kodlayıcıların seçiminin de model verimini arttıran diğer bir olgu olduğu görülmüştür.

Türkiye’deki deprem afetlerini değerlendirme amacıyla afet sonrası hasar tespitinde kullanılmak üzere geliştirilecek yapay öğrenme yöntemleri, belirlenecek makine

öğrenme algoritması ve tercih edilen bu algoritmanın eğitim sürecinde kullanılacak veri setlerinin belirlenmesi aşamalarından oluşmalıdır.

Değerlendirilen çalışmalarda değerlendirilen afet alanına göre seçilen yapay öğrenme algoritmaları değişebilmektedir. Uydu veya hava platformlarından elde edilen görüntülerden yapılacak değerlendirmelerde derin öğrenme algoritmaları kullanılmasının başarımları sağladığı görülmüştür. Ayrıca bu şekilde daha kısa bir eğitim süreci ile daha geniş alandaki afet bölgesinde hasar tespiti yapılabilmektedir.

Derin öğrenme algoritmalarında CNN tabanlı mimariler kullanılarak farklı boyutlardaki katmanlarla verideki özelliklerin detaylı olarak işlenmesi ve saklanması sağlanmıştır. Değerlendirilen çalışmalarda farklı boyut ve ölçeklerdeki görüntülerden özellik çıkarımı problemine yönelik öneriler de ön plana çıkmaktadır. Makale 20’de (Tasci vd., 2023) değinildiği gibi derin öğrenme modelinde, GoogleNet ve DenseNet gibi ağlarda kullanılan inception katmanları kullanarak detaylı özelliklerin çıkarılması ve modelin vanishing gradient problemine karşı dayanıklılığının artması sağlanmıştır. Makale 23’de (Seydi vd., 2023b) de çok ölçekli convolution katmanları (3x3, 5x5, 7x7 gibi) kullanılmıştır.

Geliştirilebilecek modelde vanishing gradient ve exploding gradient gibi problemler göz önünde bulundurularak sunulan örneklerdeki inception ve residual tabanlı mimariler tasarlanabilir.

İHA gibi kaynaklardan elde edilen optik görüntülerde yıkıntı tespiti yaparken binaların farklı boyutlarda olması ve alınan görüntünün irtifasının değişebilmesi durumları için segmentasyon başarısını iyileştirecek modüller eklenmiştir. Makale 2’de (Xia vd., 2023) değinildiği gibi farklı boyutlardaki nesneler üzerinde başarımın artırılması için Multi-Feature Fusion (MFF) modülü sayesinde görüntünün çeşitli boyutlarının CNN ağı üzerinden geçirilerek nesne karakteristiklerinin çıkarılmasına çalışılmıştır. Bu şekilde modelin öğrenme kabiliyetinin artırılması sağlanmıştır.

Bununla beraber farklı boyutlardaki nesneleri tanımak üzere, makale 33’de (Hu vd., 2023) YOLOv5 modeline Feature Pyramide Network tabanlı PANet modülü dahil edilmiştir. Deprem sonrası afet verilerinde, İHA görüntüleri veya farklı ölçeklerdeki uydu görüntülerinin kullanılması durumunda, bina boyutlarındaki farklılıklar önemli bir sorun oluşturabilir. Bu problemi dikkate alarak yapılan bir algoritma tasarımı, modelin başarımını artıracaktır.

Deprem sonrası geliştirilmesi planlanan bina hasarı tespit uygulamalarında öne çıkan diğer bir husus ise transfer öğrenmedir. Makale 4 (Abdi vd., 2021) ve makale 24 (Sodeinde vd., 2024) yayınlarında değinildiği gibi önceden eğitilmiş sinir ağıları kullanılarak modelin eğitim süresinin hızlandırılması ve daha etkili eğitim yapılabilirdiği görülmüştür. ResNet tabanlı sinir ağıları, ImageNet veya xBDSet gibi veri setleriyle önceden eğitilerek kullanılmıştır. Değerlendirilen yayınlarda ekseriyetle bu uygulamanın, encoding işlemlerinin yapıldığı katmanlarda kullanıldığı görülmüştür. Geliştirilecek bir derin öğrenme modelinde etiketli veri eksikliği gibi durumunda bu yöntemle başvurulması uygun olacaktır.

Değerlendirilen çalışmalarda afet sonrası görüntüler üzerinde özellik çıkarımı yapılarak bina ve hasar tespiti yöntemlerinin iyileştirilmesine odaklanılmıştır. Bu kapsamda bazı çalışmalarda uydu görüntüsünden RGB ve spektral özellikler işlenerek NDVI gibi indisler kullanılarak görüntüdeki bitki örtüsü, arkaplan detayı ve diğer bina harici yapılar ayırt edilmeye çalışılmış ve sonuç olarak binaların segmentasyonu yapılabilmektedir. Bazı çalışmalarda semantik segmentasyon sayesinde daha iyi sonuç alındığı görülmüştür. Çatı ve çatı harici olan görüntüler kullanılarak veri seti oluşturulmuş ve bu görüntüler kullanılarak segmentasyon modeli geliştirilmiştir. Makale 8 (Naito vd., 2020) yayınında değinildiği gibi ahşap yapıların tespiti için daha önce geliştirilen, ahşap yapı görüntü indisinden faydalanılmıştır. Makale 10'da (Virtriana vd., 2023) değindikleri gibi farklı özellik çıkarımı senaryolarıyla da görüntünün analizinde, bina sınırları için diktörtgensellik, dairesellik incelemesi, görüntünün piksellerinde gri tonlama, kontrast değerlendirmeleri de yapay öğrenme modeli geliştirilmesinde etkili olabilmektedir. Ayrıca makale 13'de (T. Li vd., 2023) değinildiği gibi elde edilen radar görüntülerinden de yansıma özellikleri incelenerek, yansımanın miktarına göre yıkılmış bina tespiti ile başarıyla hasar sınıflandırması yapılmasına olanak sağlamaktadır.

İncelenen yayınlarda yapay öğrenme yöntemlerinin eğitim süreçlerinde kullanılan hiperparametrelerin belirlenmesinde kullanılan yöntemler de etkin model geliştirme konusunda dikkate alınması gereken bir unsurdur. Birçok yapay öğrenme yönteminde karşılaşılan aşırı öğrenme (overfitting) sorununun çözümü için de modelin katman ve nöron sayısı ile dropout oranı gibi parametreler bu sorunun giderilmesi için kullanılmaktadır. Ayrıca model eğitimi sırasında çapraz doğrulama (cross validation) uygulanması da aşırı öğrenme sorununu bertaraf etmek için başvurulmuş yöntemlerden

biridir. Model geliştirilmesi sırasında seçilen optimizasyon algoritmaları doğru ağırlıkların belirlenmesinde ve modelin eğitim sürecinin iyileştirilmesinde etkili olmuştur. Makale 11'deki (Mangalraj vd., 2022) gibi bir çok çalışmada büyük ve karmaşık veri setlerinde etkili olan ADAM en iyileyicisi (optimizer) kullanılmıştır. Değerlenen çalışmalarda hasar sınıflandırma işlemleri sırasında kullanılan veri seti hasar derecesi sınıfları dengesiz olabilmektedir. Bu nedenle modelin hasar sınıflandırma işlemi sırasında bazı hasar gruplarında daha az başarılı olduğu görülmektedir. Özellikle tam yıkılmış bina tespitlerinde çok daha az başarılı sonuçlar elde edilebilmiştir. Bu sorunun giderilmesi amacıyla çeşitli çalışmalarda bu soruna uygun hata fonksiyonları kullanılmıştır. (Sha vd., 2024) yayınında, veri setindeki sınıf dengesizliği sorunu gidermek için focal loss fonksiyonundan faydalanılmıştır.

Şekil 4.1'de afet sonrası bina hasar tespiti için kullanılabilecek otomatik yapay öğrenme yöntemi geliştirme adımları şeması gösterilmiştir.

4.2 Türkiye İçin Öneriler

Türkiye özelinde deprem afeti sonrası bina segmentasyonu ve hasar tespiti için geliştirilmesi düşünülen modeller, incelenen yayınlarda değinilen sorunlar göz önünde bulundurularak belirlenmeli ve gerekli optimizasyonlar uygulanmalıdır. Çoğunlukla CNN tabanlı modeller geliştirilmesiyle beraber son dönemde yapılan yayınlarda transformer mimarisi tabanlı (vision transformer) modellerin kullanımı da göze çarpmaktadır. Bu mimari, günümüzde Büyük Dil Modellerinin (Large Language Models) temelini oluşturmaktadır. Transformer mimarisine dayalı modeller, büyük veri setlerinde çok fazla parametreyle çalışabilmektedir. Bu sayede görüntüde, yüksek kapasitede bilgisayarlı görü görevlerini gerçekleştirmek mümkün olmaktadır. Dezavantajı çok fazla işlem gücü gerektirmesidir. Bununla beraber Makale 12'de (Gomroki vd., 2025) değinildiği gibi vision transformer tabanlı encoder ile U-net mimarisinin bir arada kullanıldığı verimli çalışan yapılar da geliştirilmiştir. Bu nedenle geliştirilmesi düşünülen modelde vision transoformer tabanlı mimari de iyi bir seçenek olarak görünmektedir.

İncelenen çalışmaların birçoğunda yapay öğrenme yöntemlerinin eğitilmesinde kullanılan veri setleri, önceden üretilmiş ImageNet veya xBDset veri setleridir. Bazı yayınlarda elde edilen hava görüntülerinden poligonlar çıkarılarak da veri setleri üretilmiştir. Her ne kadar kullanılan algoritmalar farklılık gösterse de xBDset veya

ImageNet kullanmadan araştırmacıların kendilerinin ürettiği veri setleri ile eğitilen modellerde başarımlar daha yüksek gözükmemektedir. Yalnızca kodlayıcı kısmının hazır veri setleri kullanılarak eğitildiği durumlarda da normalden daha iyi başarımlar görülmektedir.

Değerlendirilen yayınlarda eğitim verisi ve test verisi oranı sırasıyla; %60, %40 veya %70, %30 görülmektedir. Bazı yayınlarda nadir de olsa doğruluk verisi de eklenerek sırasıyla eğitim, doğruluk ve test verileri %80, %10, %10 ayrılmıştır.

Veri setlerinin geliştirilmesi için büyük çoğunlukla data augmentation işlemi uygulanmıştır. Veri setlerinde bulunan görüntülerin geometrik ve piksel tabanlı rastlantısal (random) değişikliklerle çeşitlendirilmesi sağlanmıştır. Örnek olarak veri setinin rastlantısal biçimde; %50'sine döndürme, %25'ine çevirme gibi işlemler ile; kırpma, blur, kontrast değişimi gibi işlemlerden geçirilerek veri setinin örnek sayısı artırılmıştır. Bu sayede geliştirilen modelin daha iyi eğitilmesi ve farklı görüntülerde başarımlarının artmasının sağlanması amaçlanmıştır. Türkiye'de deprem sonrası uygulanan yapay öğrenme yöntemlerinde zaman zaman özellikle kırsal bölgelerde yaşanan yıkımların tespitinde sorunlar yaşanmıştır. Örnek olarak, çatı rengi beklenen turuncu tonda renkte olmayan köy evlerinin yıkıldıklarında tespiti mümkün olamamış, toprak rengi olarak atıldığı durumlar olmuştur. Bununla beraber bir kısmı ağaçla kaplı binaların görüntülerinden tespit de zaman zaman mümkün olamamaktadır. Böyle durumlar için de veri zenginleştirme işleminde mozaikleme yani birden fazla görüntünün bir araya getirilerek benzer yeni örnekler elde edilmesi, başarımları arttırabilecektir. Ayrıca incelenen çalışmalarda SAR verisi kullanımının çeşitli analiz yöntemleriyle hasarlı bina tespitinde, özellikle gece ve bulut kaplı bölgelerde acil bir veri kaynağı olarak tercih edilmesi de önemlidir.

İncelenen yayınlarda elde edilen uydu görüntülerinin elde edilme açıları (nadir/off-nadir) segmentasyon ve hasar tespitinde başarımları etkilediği öne sürülmüştür. Makale 16'da (Abdi & Jabari, 2021) off-nadir görüntüler de kullanılarak doğruluk artırılmıştır. Bununla beraber yine aynı yayında ortofoto ve uydu görüntülerinin bir arada kullanıldığı durumlarda ise çok daha yüksek bir doğruluk yakalanmıştır. Bazı yayınlarda da kullanılan İHA görüntülerinin, farklı açılardan elde edilebilmesi sayesinde iyi bir veri kaynağı olduğu görülmüştür.

Ülkemizde afet sonrası hasar tespiti amaçlı bir yapay öğrenme sistemi geliştirilmesi için geniş kapsamlı bir veri seti üretilmelidir. Üretilen veri seti, hem kırsalda hem de şehir merkezinde yer alan yapı örneklerini içermelidir. Farklı veri kaynaklarından elde edilen verilerle hibrit bir hasar değerlendirme çatısı geliştirilmelidir. Siamese network kullanılan çalışmalarda afet öncesi ve sonrası veriler de kullanılarak daha etkin bir model geliştirilmesi sağlanmıştır.

Geliştirilecek modelin çalıştırılması için deprem öncesi ve sonrası yüksek çözünürlüklü uydu görüntülerinin temin edilmesi gerekmektedir. Türkiye’de yerel veya uluslararası uydu operatörlerinden (örneğin, Türkiye Uzay Ajansı, NASA veya ESA) veri alınabilir. Bu görüntüler, geniş alanların ilk taraması için kullanılarak hasar yoğunluğunu belirlemede yardımcı olur. Hasarın detaylı incelenebilmesi için bölgesel İHA görüntülerinin elde edilmesi önemlidir. İHA’lar, özellikle erişilmesi güç veya yoğun hasarlı bölgelerde yüksek çözünürlüklü görüntü sağlamaktadır. Görüntülerdeki binaların durumları (örneğin, hasarsız, hafif hasarlı, ağır hasarlı, yıkılmış) belirlenip etiketlenmelidir. Bu aşamada, inşaat ve afet yönetimi konusunda uzmanların katkısı, doğru etiketlemenin sağlanması için kritik öneme sahiptir.

Farklı kaynaklardan (uydu ve İHA) gelen verilerin geometrik ve radyometrik uyumunu sağlamak için ön işleme teknikleri uygulanmalıdır. Bu işlemler, görüntü kayıt (image registration) ve normalizasyon adımlarından oluşur. Farklı kaynaklardan veya farklı zamanlarda elde edilen görüntülerin, aynı jeodezik koordinat sistemi içinde doğru şekilde hizalanması (registration and alignment) gereklidir. Örneğin, uydu ve İHA görüntüleri farklı açılardan veya farklı zamanlarda üretildiğinden, aynı bölgeyi karşılaştırabilmek için bu görüntülerdeki ortak referans noktalarının belirlenip hizalanması gerekir. Bu sayede, her iki veri seti de aynı coğrafi konumda birleşir ve detaylı analiz, hasar tespiti gibi işlemler daha doğru şekilde gerçekleştirilebilir. Uydu ve İHA verileri zaman ve konum koordinasyonu ile birleştirilerek, modelin hem geniş alan taramasında hem de yerel detaylarda etkin sonuçlar üretmesi sağlanabilir.

Afet sonrası hasar tespiti altyapısı için, bulut tabanlı çözümler ve yüksek performanslı hesaplama kaynakları kullanarak, modelin gerçek zamanlı veya hızlı analiz yapabilmesi sağlanmalıdır. Model çıktılarının, acil müdahale planlaması ve kaynak dağılımı için kullanılabileceği bir arayüz veya raporlama sistemi geliştirilmelidir. Afet yönetimi, inşaat mühendisliği, geomatik mühendisliği ve yer bilimi uzmanlarının birbirleriyle işbirliği yaparak, hem veri etiketlemesi hem de model doğrulaması

süreçleri desteklenmelidir. Afet sonrası hasar tespiti için geliştirilen model, yeni veri setleri geldikçe güncellenmeli ve performansı artıracak gerekli iyileştirmeler yapılmalıdır. Geliştirilen modelin AFAD ve belediyelerin coğrafi bilgi sistemi entegrasyonunda kullanılmak üzere web servis ve API arayüzleri üretilmelidir.





Şekil 4.1 : Afet sonrası bina hasar tespiti için yapay öğrenme işlemleri akış şeması.

Çizelge 4.1 : İncelenen yayınlarda kullanılan yapay öğrenme yöntemlerinin hesaplanmış ve sunulmuş performans metrikleri.

MAKALE NO	KESİNLİK (%)	DUYARLILIK (%)	F1 (%)	DOĞRULUK (%)	IoU	KAPPA KATSAYISI	AFET ÖNCESİ VERİ	AFET SONRASI VERİ	VERİ SETİ BÜYÜKLÜĞÜ
1	96.36	94.38	95.34					SONRA	3784
2	-	84.17		80.43			ÖNCE	SONRA	
3	87	73	79				ÖNCE	SONRA	83675
4								SONRA	1900
5	71	58	63				ÖNCE	SONRA	5598
6								SONRA	
7	77	76	76		0.65		ÖNCE	SONRA	5598
8				78.4				SONRA	132574
9	77	46	55	97				SONRA	377
10			78	95			ÖNCE	SONRA	
11				60			ÖNCE	SONRA	
12	99		99	97	0.99	0.85		SONRA	
13			90		0.81			SONRA	2840
14			71	72			ÖNCE	SONRA	
15				98		0.86		SONRA	2233
16				98		0.91	ÖNCE	SONRA	
17	92	91	91	94	0.84	0.87		SONRA	645
18				82		0.74		SONRA	

Çizelge 4.1 (devamı) : İncelenen yayınlarda kullanılan yapay öğrenme yöntemlerinin hesaplanmış ve sunulmuş performans metrikleri.

MAKALE NO	KESİNLİK (%)	DUYARLILIK (%)	F1 (%)	DOĞRULUK (%)	IoU	KAPPA KATSAYISI	AFET ÖNCESİ VERİ	AFET SONRASI VERİ	VERİ SETİ BÜYÜKLÜĞÜ
19				93		0.89		SONRA	12200
20				99				SONRA	2735
21	11	33	17				ÖNCE	SONRA	162787
22			77				ÖNCE	SONRA	181254
23			86	91		0.79		SONRA	2085
24			70					SONRA	22068
25		85						SONRA	19318
26			83				ÖNCE	SONRA	2283
27				14-86			ÖNCE	SONRA	
28	71	73	72	95	0.76		ÖNCE	SONRA	2000
29	91	91	91	92				SONRA	8192
30				88		0.8	ÖNCE	SONRA	
31				89		0.78	ÖNCE	SONRA	2000
32			72	76				SONRA	10000
33	72							SONRA	24496
34				89				SONRA	315
35			79		0.55		ÖNCE	SONRA	15890

5. SONUÇLAR

Bu tez kapsamında uzaktan algılama verileri ve makine öğrenmesi yöntemleri kullanılarak deprem sonrası afet planlamasında ihtiyaç duyulan, hasarlı binaların otomatik tespitinin hızlı ve doğru biçimde yapılması amacıyla kullanılan yapay öğrenme yaklaşımları araştırılmıştır. Bu alanda yapılan akademik çalışmalar incelenerek bina segmentasyonu ve hasar tespiti işlemleri için kullanılan makine öğrenmesi mimarileri, uygulanan yöntemler, makine öğrenmesi modelleri oluşturulurken yapılan iyileştirmeler ve sonuçlar analiz edilmiştir.

İncelenen çalışmalarda, doğruluk, kesinlik, duyarlılık, F1 skoru gibi başarımlar ölçütleri karşılaştırılmıştır. Bu çalışmalarda yapay öğrenme yöntemleri kullanılarak uygulanan bina segmentasyon işlemlerinde genel olarak yüksek başarımlar gözlenmektedir. Hasar tespitinde belirli hasar sınıflarında (az hasarlı, orta hasarlı vb.) bina hasarının tespiti de başarılı bir şekilde yapılabilmektedir. Bu noktada derin öğrenme yöntemlerinin doğruluk, duyarlılık gibi oranlar açısından daha verimli ve hızlı olduğu görülmektedir. Birbirine yakın doğruluk değerlerine sahip olan çalışmalarda, duyarlılık veya F1 skorunun düşük olduğu sonuçların olduğu modellerde, modelin yetersiz veri seti ile eğitilmesi nedeniyle böyle bir sonuç alındığı görülmüştür. Veri setinin yeterli olmadığı, farklı sınıflara ait örnek sayısının dengeli olmadığı durumlarda çoğunlukla veri zenginleştirme (data augmentation) işlemine başvurulmuştur. Eldeki bina görüntüleri biçimsel düzenlemelere tabi tutularak, ilgili görüntülerin farklı çeşitleri üretilmiştir. Bu sayede geliştirilen makine öğrenmesi modelinin duyarlılık ve F1 skoru açısından daha sağlıklı çalışması sağlanmıştır. Ayrıca modelin farklı olay örneklerine ait görüntülerde de başarılı olması sağlanmıştır.

Farklı tür algoritmaların kullanıldığı çalışmalarda U-net modelinin veya U-net tabanlı modellerin genellikle daha iyi performans sergilediği görülmüştür. Ayrıca seçilen modellerle beraber kodlayıcı (encoder) seçimi de model performansını etkilemiştir. Sınıflandırıcı türde makine öğrenmesi modellerine kıyasla derin öğrenme modellerinin, sağladığı başarımların yanı sıra, eğitim ve çıkarım yapma sürelerini de kısalttığı örnekler görülmüştür.

Model eğitimi sırasında uygulanan katman-nöron sayıları, yığın eğitim sayısı (epoch), her yığın eğitiminde işlenecek örnek sayısı (batch), öğrenme oranı gibi hiperparametre ayarlamaları ile hata fonksiyonu seçimi gibi optimizasyonlar da model performanslarının iyileşmesi ve eğitim süresinin kısaltılmasında rol oynamıştır.

İncelenen çalışmalar değerlendirildiğinde, deprem sonrası hasarlı bina tespiti amacıyla otomatik bir segmentasyon ve hasar sınıflandırma sistemi geliştirilmesi için U-net tabanlı derin öğrenme modeli geliştirilmesi önerilebilir. Model eğitiminde önceden oluşturulmuş xBDSet veya ImageNet hasarlı bina veri setleri ile önceden eğitilmiş VGG veya ResNet tabanlı kodlayıcılar kullanılması önemlidir. Önceden eğitilmiş bu kodlayıcılarla transfer öğrenme uygulanarak ham veri üzerinde özellik çıkarma işlemi gerçekleştirilebilmektedir. Burada elde edilen özelliklerin bina segmentasyonu ve hasar sınıflandırılması için kullanılması amaçlanmaktadır. Segmentasyon ve sınıflandırma için seçilen hata fonksiyonları ile her eğitim adımında model ağırlıkları güncellenerek model eğitimi tamamlanır. Bina bölütleme (segmentasyon) için Dice ve Binary Cross-Entropy fonksiyonlarının bir arada kullanıldığı Combo Loss fonksiyonu tercih edilmesi uygun olmaktadır. Sınıflandırma işlemi içinse Cross-Entropy Loss fonksiyonunun kullanımının daha uygun olduğu görülmüştür. Model performansını değerlendirmek için Jaccard Index'i (IoU) metriği önerilmektedir. En uygun duruma getirici (optimizer) olarak daha hızlı ve verimli optimizasyon sağlaması açısından ADAM en iyileycisi önerilmektedir.

Deprem afetiyle sıkça yüzleşen Türkiye'de afet sonrası koordinasyon kaynaklı sorunların giderilmesi, doğru bir afet sonrası müdahale planlamasının yapılması ile mümkündür. Afet sonrası karar vericilere ve saha personeline rehberlik edecek etkin bir planlama, doğru veri kaynaklarından hızlı bilgi alınması ile etkin bir biçimde gerçekleştirilebilir. Geniş bir alana yayılabilen afet bölgelerinde, özellikle uydu verisinden elde edilen uzaktan algılama verilerinin işlenmesi ile hızlı ve etkin bir şekilde bölgedeki hasar gören yapıların yerlerinin ve hasarların tespiti, yapay öğrenme yöntemleri ve derin öğrenme modellerinin kullanımıyla mümkün olmaktadır. Bu amaçla Türkiye'de afet sonrası acil müdahale planlamasının, hızlı ve etkin bir biçimde gerçekleştirilebilmesi için derin öğrenme tabanlı otomatik hasar tespit sistemleri geliştirilmelidir. Bu nedenle derin öğrenme modellerinin eğitiminde kullanılmak üzere yerel depremlere ait uydu görüntülerinden yeni veri setleri üretilmesi, geliştirilen modellerin eğitim sürecinde başarıyı arttırabilecektir. Bu noktada afet sonrası yüksek

özünürlüklü uydu verisinin hızlı bir şekilde elde edilmesi amacıyla, yerli uyduların da açık veri olarak veri setleri paylaşması planlanmalıdır.





KAYNAKLAR

- Abdi, G., Esfandiari, M., & Jabari, S.** (2021). BUILDING DAMAGE DETECTION IN POST-EVENT HIGH-RESOLUTION IMAGERY USING DEEP TRANSFER LEARNING. *International Geoscience and Remote Sensing Symposium (IGARSS)*, 2021-July, 531-534. <https://doi.org/10.1109/IGARSS47720.2021.9553720>
- Abdi, G., & Jabari, S.** (2021). A Multi-Feature Fusion Using Deep Transfer Learning for Earthquake Building Damage Detection. *Canadian Journal of Remote Sensing*, 47(2), 337-352. <https://doi.org/10.1080/07038992.2021.1925530>
- Aswitha, N., Adari, M., Varshitha, M., Saritha, B., & Padmaja, T.** (2024). LEARNING EFFICIENT SUPERVISED SATELLITE IMAGE-BASED BUILDING DAMAGE DETECTION. *International Research Journal of Modernization in Engineering*, 16. www.irjmets.com
- Bangert, P.** (2021). Machine Learning. *Machine Learning and Data Science in the Oil and Gas Industry: Best Practices, Tools, and Case Studies*, 37-67. <https://doi.org/10.1016/B978-0-12-820714-7.00003-0>
- Belyadi, H., & Haghighat, A.** (2021). Supervised learning. *Machine Learning Guide for Oil and Gas Using Python*, 169-295. <https://doi.org/10.1016/B978-0-12-821929-4.00004-4>
- Chen, X.** (t.y.). *Using Satellite Imagery to Automate Building Damage Assessment: A case study of the xBD dataset.*
- Cunningham, P., & Delany, S. J.** (2021). 28 k-Nearest Neighbour Classifiers-A Tutorial. *ACM Comput. Surv*, 54. <https://doi.org/10.1145/3459665>
- Data augmentation - Wikipedia.** (t.y.). Geliş tarihi 19 Aralık 2024, gönderen https://en.wikipedia.org/wiki/Data_augmentation
- Deep neural network concepts - Training | Microsoft Learn.** (t.y.). Geliş tarihi 19 Aralık 2024, gönderen <https://learn.microsoft.com/en-us/training/modules/train-evaluate-deep-learn-models/2-deep-neural-network-concepts>
- Du, C. J., & Sun, D. W.** (2008). Object Classification Methods. *Computer Vision Technology for Food Quality Evaluation*, 81-107. <https://doi.org/10.1016/B978-012373642-0.50007-7>
- Du, H., Lin, X., Jiang, J., Lu, Y., Du, H., Zhang, F., Yu, F., Feng, T., Wu, X., Peng, G., Deng, S., He, S., & Bai, X.** (2024). A single-building damage detection model based on multi-feature fusion: A case study in Yangbi. *iScience*, 27(1), 108586. <https://doi.org/10.1016/J.ISCI.2023.108586>
- Ghahrloo, M., & Mokhtarzade, M.** (2025). Earthquake-induced building damage detection using the fusion of optical and radar data in intelligent systems. *Earth Science Informatics*, 18(1), 1-17. <https://doi.org/10.1007/S12145-024-01557-3/FIGURES/16>

- Gomroki, M., Hasanlou, M., Chanussot, J., & Hong, D.** (2024). EMYNet-BDD: EfficientViTB Meets Yolov8 in the Encoder–Decoder Architecture for Building Damage Detection Using Postevent Remote Sensing Images. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 17, 13120-13134. <https://doi.org/10.1109/JSTARS.2024.3427017>
- Gomroki, M., Hasanlou, M., Chanussot, J., & Hong, D.** (2025). UNet-GCViT: a UNet-based framework with global context vision transformer blocks for building damage detection. *International Journal of Remote Sensing*. <https://doi.org/10.1080/01431161.2025.2454531>
- Goswami, J., Sharma, V., Chaudhury, B. U., & Raju, P.** (2019). RAPID IDENTIFICATION OF ABIOTIC STRESS (FROST) IN IN-FILED MAIZE CROP USING UAV REMOTE SENSING. <https://doi.org/10.5194/isprs-archives-XLII-3-W6-467-2019>
- Hacıfendioğlu, K., Başağa, H. B., Kahya, V., Özgan, K., & Altunışık, A. C.** (2024). Automatic Detection of Collapsed Buildings after the 6 February 2023 Türkiye Earthquakes Using Post-Disaster Satellite Images with Deep Learning-Based Semantic Segmentation Models. *Buildings* 2024, Vol. 14, Page 582, 14(3), 582. <https://doi.org/10.3390/BUILDINGS14030582>
- Hastie, T., Tibshirani, R., & Friedman, J.** (2009). *Random Forests*. 587-604. https://doi.org/10.1007/978-0-387-84858-7_15
- Hu, D., Li, S., Du, J., & Cai, J.** (2023). Automating Building Damage Reconnaissance to Optimize Drone Mission Planning for Disaster Response. *Journal of Computing in Civil Engineering*, 37(3), 04023006. [https://doi.org/10.1061/\(ASCE\)CP.1943-5487.0001061/ASSET/A467CD34-F969-4FF7-839A-F12664F0AD21/ASSETS/IMAGES/LARGE/FIGURE13.JPG](https://doi.org/10.1061/(ASCE)CP.1943-5487.0001061/ASSET/A467CD34-F969-4FF7-839A-F12664F0AD21/ASSETS/IMAGES/LARGE/FIGURE13.JPG)
- Janiesch, C., Zschech, P., & Heinrich, K.** (2021). Machine learning and deep learning. *Electronic Markets*, 31(3), 685-695. <https://doi.org/10.1007/S12525-021-00475-2/TABLES/2>
- Jozi, D., Shirzad-Ghaleoudkhani, N., Luhadia, G., Abtahi, S., & Gül, M.** (2024). Rapid post-disaster assessment of residential buildings using Unmanned Aerial Vehicles. *International Journal of Disaster Risk Reduction*, 111, 104707. <https://doi.org/10.1016/J.IJDRR.2024.104707>
- Jumin, E., Zaini, N., Ahmed, A. N., Abdullah, S., Ismail, M., Sherif, M., Sefelnasr, A., & El-Shafie, A.** (2020). Machine learning versus linear regression modelling approach for accurate ozone concentrations prediction. *Engineering Applications of Computational Fluid Mechanics*, 14(1), 713-725. <https://doi.org/10.1080/19942060.2020.1758792>
- Kalantar, B., Ueda, N., Al-Najjar, H. A. H., & Halin, A. A.** (2020). Assessment of Convolutional Neural Network Architectures for Earthquake-Induced Building Damage Detection based on Pre- and Post-Event Orthophoto Images. *Remote Sensing* 2020, Vol. 12, Page 3529, 12(21), 3529. <https://doi.org/10.3390/RS12213529>
- Kang, J., Schwartz, R., Flickinger, J., & Beriwal, S.** (2015). Machine Learning Approaches for Predicting Radiation Therapy Outcomes: A Clinician's

- Perspective. *International Journal of Radiation Oncology*Biological*Physics*, 93(5), 1127-1135. <https://doi.org/10.1016/J.IJROBP.2015.07.2286>
- Li, T., Wang, C., Zhang, H., Wu, F., & Zheng, X.** (2023). DDFormer: A Dual-Domain Transformer for Building Damage Detection Using High-Resolution SAR Imagery. *IEEE Geoscience and Remote Sensing Letters*, 20. <https://doi.org/10.1109/LGRS.2023.3288007>
- Li, Y., Lin, C., Li, H., Hu, W., Dong, H., & Liu, Y.** (2020). Unsupervised domain adaptation with self-attention for post-disaster building damage detection. *Neurocomputing*, 415, 27-39. <https://doi.org/10.1016/J.NEUCOM.2020.07.005>
- Linear regression: Loss | Machine Learning | Google for Developers.** (t.y.). Geliş tarihi 06 Ocak 2025, gönderen <https://developers.google.com/machine-learning/crash-course/linear-regression/loss>
- Liu, C., Sui, H., Wang, J., Ni, Z., & Ge, L.** (2022). Real-Time Ground-Level Building Damage Detection Based on Lightweight and Accurate YOLOv5 Using Terrestrial Images. *Remote Sensing* 2022, Vol. 14, Page 2763, 14(12), 2763. <https://doi.org/10.3390/RS14122763>
- Machine learning, explained | MIT Sloan.** (t.y.). Geliş tarihi 19 Aralık 2024, gönderen <https://mitsloan.mit.edu/ideas-made-to-matter/machine-learning-explained>
- Mangalraj, P., Duddela, S. P., Kirubanantham, P., & Iniyan, S.** (2022). Post-earthquake Building Damage Detection Using Deep Learning. 123-133. https://doi.org/10.1007/978-981-16-1249-7_13
- Naito, S., Tomozawa, H., Mori, Y., Nagata, T., Monma, N., Nakamura, H., Fujiwara, 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. https://doi.org/10.1177/8755293019901309/ASSET/IMAGES/LARGE/10.1177_8755293019901309-FIG12.JPEG
- Palat, J.** (2022). *A Hitchhiker's Guide to ML Training Infrastructure*. <https://insights.sei.cmu.edu/blog/a-hitchhikers-guide-to-ml-training-infrastructure/>
- Qiao, W., Shen, L., Wen, Q., Wen, Q., Tang, S., & Li, Z.** (2024). Revolutionizing building damage detection: A novel weakly supervised approach using high-resolution remote sensing images. *International Journal of Digital Earth*, 17(1). <https://doi.org/10.1080/17538947.2023.2298245>
- Qing, Y., Ming, D., Wen, Q., Weng, Q., Xu, L., Chen, Y., Zhang, Y., & Zeng, B.** (2022). Operational earthquake-induced building damage assessment using CNN-based direct remote sensing change detection on superpixel level. *International Journal of Applied Earth Observation and Geoinformation*, 112, 102899. <https://doi.org/10.1016/J.JAG.2022.102899>
- Rao, A., Jung, J., Silva, V., Molinario, G., & Yun, S. H.** (2023). Earthquake building damage detection based on synthetic-aperture-radar imagery and machine learning. *Natural Hazards and Earth System Sciences*, 23(2), 789-807. <https://doi.org/10.5194/NHESS-23-789-2023>

- Rashidian, V., Baise, L. G., Koch, M., & Moaveni, B.** (2021). Detecting Demolished Buildings after a Natural Hazard Using High Resolution RGB Satellite Imagery and Modified U-Net Convolutional Neural Networks. *Remote Sensing* 2021, Vol. 13, Page 2176, 13(11), 2176. <https://doi.org/10.3390/RS13112176>
- Rebala, G., Ravi, A., & Churiwala, S.** (2019). *An Introduction to Machine Learning*. Springer International Publishing. <https://doi.org/10.1007/978-3-030-15729-6>
- Said Elsayed, M., Le-Khac, N. A., Dev, S., & Jurcut, A. D.** (2020). Network Anomaly Detection Using LSTM Based Autoencoder. *Q2SWinet 2020 - Proceedings of the 16th ACM Symposium on QoS and Security for Wireless and Mobile Networks*, 37-45. <https://doi.org/10.1145/3416013.3426457>
- Saidi, A., Ben Othman, S., Dhouibi, M., & Ben Saoud, S.** (2021). FPGA-based implementation of classification techniques: A survey. *Integration*, 81, 280-299. <https://doi.org/10.1016/J.VLSI.2021.08.004>
- Sarker, I. H.** (2021). Machine Learning: Algorithms, Real-World Applications and Research Directions. *SN Computer Science*, 2(3), 1-21. <https://doi.org/10.1007/S42979-021-00592-X/FIGURES/11>
- Schölkopf, B.** (1998). SVMs - A practical consequence of learning theory. *IEEE Intelligent Systems and Their Applications*, 13(4), 18-21. <https://doi.org/10.1109/5254.708428>
- Seydi, S. T., Hasanlou, M., Chanussot, J., & Ghamisi, P.** (2023a). BDD-Net+: A Building Damage Detection Framework Based on Modified Coat-Net. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 16, 4232-4247. <https://doi.org/10.1109/JSTARS.2023.3267847>
- Seydi, S. T., Hasanlou, M., Chanussot, J., & Ghamisi, P.** (2023b). Leveraging involution and convolution in an explainable building damage detection framework. *European Journal of Remote Sensing*, 56(1). <https://doi.org/10.1080/22797254.2023.2252166>
- Shammi, S., Sohel, F., Diepeveen, D., Zander, S., & Jones, M. G. K.** (2023). A survey of image-based computational learning techniques for frost detection in plants. *Information Processing in Agriculture*, 10(2), 164-191. <https://doi.org/10.1016/J.INPA.2022.02.003>
- Shao, J., Tang, L., Liu, M., Shao, G., Sun, L., & Qiu, Q.** (2020). BDD-Net: A General Protocol for Mapping Buildings Damaged by a Wide Range of Disasters Based on Satellite Imagery. *Remote Sensing* 2020, Vol. 12, Page 1670, 12(10), 1670. <https://doi.org/10.3390/RS12101670>
- Siddique, N., Paheding, S., Elkin, C. P., & Devabhaktuni, V.** (2021). U-Net and Its Variants for Medical Image Segmentation: A Review of Theory and Applications. *IEEE Access*, 9, 82031-82057. <https://doi.org/10.1109/ACCESS.2021.3086020>
- Sodeinde, O. R., Koch, M., Moaveni, B., & Baise, L. G.** (2024). One versus all: identifiability with a multi-hazard and multiclass building damage imagery dataset and a deep learning neural network. *Natural Hazards*, 120(9), 8337-8366. <https://doi.org/10.1007/S11069-024-06500-9/FIGURES/20>
- Speiser, J. L., Miller, M. E., Tooze, J., & Ip, E.** (2019). A comparison of random forest variable selection methods for classification prediction modeling. *Expert*

- Takhtkeshha, N., Mohammadzadeh, A., & 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* 2023, Vol. 15, Page 123, 15(1), 123. <https://doi.org/10.3390/RS15010123>
- Tasci, B., Acharya, M. R., Baygin, M., Dogan, S., Tuncer, T., & Belhaouari, S. B.** (2023). InCR: Inception and concatenation residual block-based deep learning network for damaged building detection using remote sensing images. *International Journal of Applied Earth Observation and Geoinformation*, 123, 103483. <https://doi.org/10.1016/J.JAG.2023.103483>
- Tilon, S., Nex, F., Kerle, N., & Vosselman, G.** (2020). Post-Disaster Building Damage Detection from Earth Observation Imagery Using Unsupervised and Transferable Anomaly Detecting Generative Adversarial Networks. *Remote Sensing* 2020, Vol. 12, Page 4193, 12(24), 4193. <https://doi.org/10.3390/RS12244193>
- Varoquaux, G., & Colliot, O.** (2023). Evaluating Machine Learning Models and Their Diagnostic Value. *Neuromethods*, 197, 601-630. https://doi.org/10.1007/978-1-0716-3195-9_20/TABLES/2
- Virtriana, R., Harto, A. B., Atmaja, F. W., Meilano, I., Fauzan, K. N., Anggraini, T. S., Ihsan, K. T. N., Mustika, F. C., & Suminar, W.** (2023). Machine learning remote sensing using the random forest classifier to detect the building damage caused by the Anak Krakatau Volcano tsunami. *Geomatics, Natural Hazards and Risk*, 14(1), 28-51. <https://doi.org/10.1080/19475705.2022.2147455>
- Wang, J., Sun, K., Cheng, T., Jiang, B., Deng, C., Zhao, Y., Liu, D., Mu, Y., Tan, M., Wang, X., Liu, W., & Xiao, B.** (2021). Deep High-Resolution Representation Learning for Visual Recognition. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 43(10), 3349-3364. <https://doi.org/10.1109/TPAMI.2020.2983686>
- Wang, L., Wu, J., Yang, Y., Tang, R., & Ya, R.** (2024). Deep Learning Models for Hazard-damaged Building Detection Using Remote Sensing Datasets: A Comprehensive Review. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*. <https://doi.org/10.1109/JSTARS.2024.3449097>
- Wang, Q., Ma, Y., Zhao, K., & Tian, Y.** (2022). A Comprehensive Survey of Loss Functions in Machine Learning. 9, 187-212. <https://doi.org/10.1007/s40745-020-00253-5>
- Wang, Y., Feng, W., Jiang, K., Li, Q., Lv, R., & Tu, J.** (2023). Real-Time Damaged Building Region Detection Based on Improved YOLOv5s and Embedded System From UAV Images. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 16, 4205-4217. <https://doi.org/10.1109/JSTARS.2023.3268312>
- Wiguna, S., Adriano, B., Mas, E., & Koshimura, S.** (2024). Evaluation of Deep Learning Models for Building Damage Mapping in Emergency Response Settings. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 17, 5651-5667. <https://doi.org/10.1109/JSTARS.2024.3367853>

- Wu, C., Zhang, F., Xia, J., Xu, Y., Li, G., Xie, J., Du, Z., & Liu, R.** (2021). Building Damage Detection Using U-Net with Attention Mechanism from Pre- and Post-Disaster Remote Sensing Datasets. *Remote Sensing* 2021, Vol. 13, Page 905, 13(5), 905. <https://doi.org/10.3390/RS13050905>
- Xia, H., Wu, J., Yao, J., Zhu, H., Gong, A., Yang, J., Hu, L., & Mo, F.** (2023). A Deep Learning Application for Building Damage Assessment Using Ultra-High-Resolution Remote Sensing Imagery in Turkey Earthquake. *International Journal of Disaster Risk Science*, 14(6), 947-962. <https://doi.org/10.1007/S13753-023-00526-6/FIGURES/11>
- Zhao, Z., Wang, F., Chen, S., Wang, H., & Cheng, G.** (2024). Deep object segmentation and classification networks for building damage detection using the xBD dataset. *International Journal of Digital Earth*, 17(1). <https://doi.org/10.1080/17538947.2024.2302577>



EKLER

EK A: Çizelgeler



Çizelge A.1: İncelenen yayınlar tablosu.

MAKALE	ML MODELİ	VERİ SETİ	YAYINLANDIĞI YER ve YILI
1 Real-Time Damaged Building Region Detection Based on Improved YOLOv5s and Embedded System From UAV Images	DBYOLOv5	İHA Fotoğrafları (10-15 cm çözünürlük)	IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2019
2 A Deep Learning Application for Building Damage Assessment Using Ultra-High-Resolution Remote Sensing Imagery in Turkey Earthquake	BDANet	xBD Veriseti (0.5 m çözünürlük)	International Journal of Disaster Risk Science, 2023
3 Earthquake building damage detection based on synthetic-aperture-radar imagery and machine learning	Random Forest, SVM	SAR Verisi (Damage Proxy Map) (30 m çözünürlük)	Natural Hazards and Earth System Sciences, 2023
4 Building Damage Detection in Post-Event High-Resolution Imagery Using Deep Transfer Learning	ResNet34	Hava Fotoğrafı (27 cm çözünürlük)	IGARSS 2021 - 2021 IEEE International Geoscience and Remote Sensing Symposium, 2021
5 Using Satellite Imagery to Automate Building Damage Assessment: A case study of the xBD dataset	U-Net	xBD Veriseti	Department of Civil and Environmental Engineering Stanford University
6 Learning Efficient Supervised Satellite Image-Based Building Damage Detection	Linear Regression, KNN	Uydu Görüntüsü	International Research Journal of Modernization in Engineering Technology and Science, 2024

Çizelge A.1 (devam): İncelenen yayınlar tablosu.

	MAKALE	ML MODELİ	VERİ SETİ	YAYINLANDIĞI YER ve YILI
7	Deep object segmentation and classification networks for building damage detection using the xBD dataset	ECADS-CNN	xBD Veriseti	International Journal of Digital Earth, 2024
8	Building-damage detection method based on machine learning utilizing aerial photographs of the Kumamoto earthquake	Bag-of-Visual-Words, SVM	Hava Fotoğrafları (20 cm çözünürlük)	Earthquake Spectra, 2020
9	Automatic Detection of Collapsed Buildings after the 6 February 2023 Türkiye Earthquakes Using Post-Disaster Satellite Images with Deep Learning-Based Semantic Segmentation Models	U-Net, LinkNet, PSPNet, FPN	Uydu Görüntüsü	Buildings, MDPI, 2024
10	Machine learning remote sensing using the random forest classifier to detect the building damage caused by the Anak Krakatau Volcano tsunami	Random Forest	xBD Veriseti	Geomatics, Natural Hazards and Risk, 2022
11	Post-earthquake Building Damage Detection Using Deep Learning	U-net Temelli Model	Hava Fotoğrafları (2.25 km ² 'yi kapsayan fotoğraf)	Soft Computing and Signal Processing, 2022
12	UNet-GCViT: A UNet-based framework with global contextvision transformer blocks for building damage detection	U-net Temelli Model	Uydu Görüntüsü	INTERNATIONAL JOURNAL OF REMOTE SENSING 2025

Çizelge A.1 (devam): İncelenen yayınlar tablosu.

MAKALE	ML MODELİ	VERİ SETİ	YAYINLANDIĞI YER ve YILI
13 DDFormer: Yüksek Çözünürlüklü SAR Görüntüleri Kullanarak Bina Hasar Tespiti için Çift Alanlı Transformer	Transformer Tabanlı CNN	Uydu SAR Verisi (0.5-1 m çözünürlük)	IEEE GEOSCIENCE AND REMOTE SENSING LETTERS 2023
14 Assessment of Convolutional Neural Network Architectures for Earthquake-Induced Building Damage Detection based on Pre- and Post-Event Orthophoto Images	CNN Modeli	Hava Fotoğrafları (16-25 cm çözünürlük)	REMOTE SENSING 2020
15 EMYNet-BDD: EfficientViTB Meets Yolov8 in the Encoder-Decoder Architecture for Building Damage Detection Using Postevent Remote Sensing Images	YOLO Tabanlı Model	Uydu Görüntüsü	SCIENTIFIC REPORTS 2023
16 A Multi-Feature Fusion Using Deep Transfer Learning for Earthquake Building Damage Detection	CNN Modeli	Uydu Görüntüsü (2 m çözünürlük) Hava Fotoğrafları (0.25 cm çözünürlük)	CANADIAN JOURNAL OF REMOTE SENSING 2021
17 BDD-Net+: A Building Damage Detection Framework Based on Modified Coat-Net	CNN Modeli (CoatNet tabanlı)	Uydu Görüntüsü (0.5 m çözünürlük)	IEEE JOURNAL OF SELECTED TOPICS IN APPLIED EARTH OBSERVATIONS AND REMOTE SENSING 2023
18 A Rapid Self-Supervised Deep-Learning-Based Method for Post-Earthquake Damage Detection Using UAV Data	CNN Modeli	İHA Görüntüsü (25 cm çözünürlük)	REMOTE SENSING 2023

Çizelge A.1 (devam): İncelenen yayınlar tablosu.

	MAKALE	ML MODELİ	VERİ SETİ	YAYINLANDIĞI YER ve YILI
19	Earthquake-Induced Building Damage Detection Using the Fusion of Optical and Radar Data in Intelligent Systems	CNN Modeli	Uydu Görüntüsü (0.5 m çözünürlük) SAR Verisi (3 m çözünürlük)	EARTH SCIENCE INFORMATICS 2025
20	InCR: Inception and Concatenation Residual Block-Based Deep Learning for Damaged Building Detection Using Remote Sensing Images	CNN Modeli	Uydu Görüntüleri	INTERNATIONAL JOURNAL OF APPLIED EARTH OBSERVATION AND GEOINFORMATION 2023
21	Post-Disaster Building Damage Detection from Earth Observation Imagery Using Unsupervised and Transferable Anomaly Detecting Generative Adversarial Networks	GAN CNN Modeli	xBDSet, İHA ve Uydu Görüntüleri (1.25 m – 3.25 m çözünürlük)	REMOTE SENSING 2020
22	Evaluation of Deep Learning Models for Building Damage Mapping in Emergency Response Settings	CNN Modeli	xBDSet, Uydu Görüntüleri (0.5 m çözünürlük)	IEEE JOURNAL OF SELECTED TOPICS IN APPLIED EARTH OBSERVATIONS AND REMOTE SENSING 2024
23	Leveraging involution and convolution in an explainable building damage detection framework	CNN Modeli	Uydu Görüntüleri (0.5 m çözünürlük)	EUROPEAN JOURNAL OF REMOTE SENSING 2023
24	One versus All: Identifiability with a Multi-Hazard and Multiclass Building Damage Imagery Dataset and a Deep Learning Neural Network	CNN Modeli	xBD Veri seti	NATURAL HAZARDS 2024

Çizelge A.1 (devam): İncelenen yayınlar tablosu.

MAKALE	ML MODELİ	VERİ SETİ	YAYINLANDIĞI YER ve YILI	
25	Detecting Demolished Buildings after a Natural Hazard Using High Resolution RGB Satellite Imagery and Modified U-Net Convolutional Neural Networks	U-net CNN	Uydu Görüntüleri (30 cm çözünürlük)	REMOTE SENSING 2021
26	BDD-Net: A General Protocol for Mapping Buildings Damaged by a Wide Range of Disasters Based on Satellite Imagery	BDDnet CNN	Uydu Görüntüleri (0.8 m çözünürlük)	REMOTE SENSING 2020
27	Deep Learning Models for Hazard-Damaged Building Detection Using Remote Sensing Datasets: A Comprehensive Review	CNN Modeli	Uydu Görüntüleri (30 m-0.2 m çözünürlük) Hava Fotoğrafları (0.25 m- 0.025 m çözünürlük)	IEEE JOURNAL OF SELECTED TOPICS IN APPLIED EARTH OBSERVATIONS AND REMOTE SENSING 2024
28	Revolutionizing Building Damage Detection: A Novel Weakly Supervised Approach Using High-Resolution Remote Sensing Images	CNN Modeli	Uydu Görüntüleri (0.28 m çözünürlük)	INTERNATIONAL JOURNAL OF DIGITAL EARTH 2024
29	Real-Time Ground-Level Building Damage Detection Based on Lightweight and Accurate YOLOv5 Using Terrestrial Images	YOLO CNN	Yer Fotoğrafları	REMOTE SENSING 2022
30	A single-building damage detection model based on multi-feature fusion: A case study in Yangbi	PCA ve SVM Sınıflandırıcı	Uydu ve İHA Görüntüleri	ISCIENCE 2024

Çizelge A.1 (devam): İncelenen yayınlar tablosu.

	MAKALE	ML MODELİ	VERİ SETİ	YAYINLANDIĞI YER ve YILI
31	Operational earthquake-induced building damage assessment using CNN-based direct remote sensing change detection on superpixel level	CNN Model	Uydu (8 m-0.6 m çözünürlük) İHA Görüntüleri (0.2 m çözünürlük)	INTERNATIONAL JOURNAL OF APPLIED EARTH OBSERVATION AND GEOINFORMATION 2022
32	Unsupervised domain adaptation with self-attention for post-disaster building damage detection	CNN Modeli	Hava Fotoğrafları	NEUROCOMPUTING 2020
33	Automating Building Damage Reconnaissance to Optimize Drone Mission Planning for Disaster Response	CNN Modeli	Hava video görüntü	JOURNAL OF COMPUTING IN CIVIL ENGINEERING 2023
34	Rapid post-disaster assessment of residential buildings using Unmanned Aerial Vehicles	Bayes Sınıflandırıcı	İHA Görüntüsü	INTERNATIONAL JOURNAL OF DISASTER RISK REDUCTION 2024
35	Building Damage Detection Using U-Net with Attention Mechanism from Pre- and Post-Disaster Remote Sensing Datasets	U-Net	xBD Veri seti Uydu Görüntüleri (0.3 m çözünürlük)	REMOTE SENSING 2021



ÖZGEÇMİŞ

Ad-Soyad : Serhat Mürsel KÖROĞLU

ÖĞRENİM DURUMU:

- **Lisans** : 2010, Mersin Üniversitesi, Uygulamalı Teknoloji ve İşletmecilik Yüksekokulu, Bilgisayar Teknolojisi ve Bilişim Sistemleri

MESLEKİ DENEYİM VE ÖDÜLLER:

- 2011 yılından itibaren İstanbul Teknik Üniversitesi Mustafa İnan Kütüphanesinde Bilgi İşlem personeli olarak çalışmaktadır.

YÜKSEK LİSANS TEZİNDEN TÜRETİLEN YAYINLAR, SUNUMLAR VE PATENTLER:

- **Köroğlu S.M., Güney C., 2024.** Deprem Sonrasında Yıkılan Binaların Belirlenmesinde Kullanılan Yapay Öğrenme Yöntemlerinin Karşılaştırılması. *Türkiye Mimarlar Mühendisler Odası Harita ve Kadastro Mühendisleri Odası 8. Coğrafi Bilgi Sistemleri Kongresi 20-22 Kasım, 2024 Ankara, TÜRKİYE*