

**AFET SONRASI YAPI HASARLARININ UZAKTAN ALGILAMA
GÖRÜNTÜLERİ İLE SEMANTİK SEGMENTASYON TABANLI
DEĞERLENDİRİLMESİ**

SERHAT ALPERGİN

HAZİRAN 2025

DİYARBAKIR

DİCLE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**AFET SONRASI YAPI HASARLARININ UZAKTAN ALGILAMA
GÖRÜNTÜLERİ İLE SEMANTİK SEGMENTASYON TABANLI
DEĞERLENDİRİLMESİ**

SERHAT ALPERGİN

DİCLE ÜNİVERSİTESİ LİSANSÜSTÜ EĞİTİM-ÖĞRETİM VE SINAV
YÖNETMELİĞİNİN BİR PARÇASI OLARAK
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANA BİLİM DALINDA
YÜKSEK LİSANS TEZİ
OLARAK HAZIRLANMIŞTIR

HAZİRAN 2025

DİYARBAKIR

**AFET SONRASI YAPI HASARLARININ UZAKTAN ALGILAMA
GÖRÜNTÜLERİ İLE SEMANTİK SEGMENTASYON TABANLI
DEĞERLENDİRİLMESİ**

Serhat ALPERGİN tarafından Dicle Üniversitesi Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliği'nin bir parçası olarak hazırlanan bu çalışma, aşağıda bilgileri yazılı jüri üyeleri tarafından değerlendirilerek **Elektrik-Elektronik Mühendisliği Ana Bilim Dalı**'nda **Yüksek Lisans Tezi** olarak kabul edilmiştir.

Prof. Dr. Neslihan DALKILIÇ
Müdür, **Fen Bilimleri Enstitüsü**

Prof. Dr. Mehmet Sıraç ÖZERDEM
Danışman, **Elektrik-Elektronik Mühendisliği Bölümü,**
Dicle Üniversitesi


Doç. Dr. Hasan POLAT
İkinci Danışman, **Elektrik ve Enerji Bölümü,**
Bingöl Üniversitesi

Sınav Jürisi:

Prof. Dr. Mehmet Sıraç ÖZERDEM (*,**)
Elektrik-Elektronik Mühendisliği Bölümü, Dicle Üniversitesi

Dr. Öğr. Üyesi Hüseyin ACAR
Elektrik-Elektronik Mühendisliği Bölümü, Dicle Üniversitesi

Doç. Dr. Emrullah ACAR
Elektrik-Elektronik Mühendisliği Bölümü, Batman Üniversitesi



Savunma Tarihi: 19 / 06 / 2025

(*) Jüri Başkanı.
(**) Tez Danışmanı.



Aileme...

Dicle Üniversitesi Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak hazırlanan bu tez çalışmasında yer alan tüm bilgilerin akademik kurallara ve etik ilkelere uygun olarak elde edildiğini ve sunulduğunu beyan ederim. Ayrıca, bahse konu bu kural ve ilkelerin gerektirdiği üzere, bu çalışmada özgün olmayan tüm bilimsel içerikleri kurallara uygun biçimde alıntılıyıp kaynak gösterdiğimi beyan ederim. Beyanımınla çelişen herhangi bir delil bulunduğu takdirde tüm sorumluluğu üstleneceğimi kabul ederim.

Ad, Soyad: Serhat ALPERGİN

İmza:

TEŞEKKÜR

Öncelikle danışmanım Prof. Dr. Mehmet Sıraç ÖZERDEM'e ve ikinci danışmanım Doç. Dr. Hasan POLAT'a çalışmanın daha fikir aşamasından, örnekleme, deney setlerini oluşturma, analizlerin yorumlanması ve tez taslağındaki düzeltmeler konularına kadar gösterdikleri destek ve sabırdan dolayı teşekkür ederim. Jüri üyelerime de bu tezin daha nitelikli bir hale gelmesi için yaptıkları eleştiri ve önerileri için teşekkür ederim.

Çalışma kapsamında görüntüleri temin etme noktasında Çevre, Şehircilik ve İklim Değişikliği Bakanlığı Yapı İşleri Genel Müdürlüğü, Coğrafi Bilgi Sistemleri Genel Müdürlüğü, Eğitim ve Yayın Dairesi Başkanlığı ile Milli Savunma Bakanlığı Harita Genel Müdürlüğü'ne gerekli verilerin kullanılması amacıyla verdikleri izin için şükranlarımı sunarım.

En önemlisi, beni araştırma hevesiyle coşturdukları ve kendime bazı zamanlar inanmasam da bana inandıkları için tüm aile fertlerine teşekkür ederim.

İÇİNDEKİLER

TEŞEKKÜR.....	v
İÇİNDEKİLER	vi
ŞEKİLLER LİSTESİ	viii
TABLolar LİSTESİ.....	ix
SİMGELER VE KISALTMALAR LİSTESİ	x
ÖZET.....	xii
ABSTRACT	xiii
1. GİRİŞ	1
1.1 Uydu ve Drone Görüntüleri Üzerinden Hasar Tespiti	1
1.2 Çatlak Segmentasyonu	4
1.3 Hava ve Yersel Görüntüler Üzerinden Hasar Tespiti	6
2. ÖNCEKİ ÇALIŞMALAR.....	8
2.1 Hava Görüntüleri Kullanılan Çalışmalar	9
2.1.1 Geleneksel Yöntemler Kullanılan Çalışmalar.....	9
2.1.2 ESA Kullanılan Çalışmalar	12
2.1.3 Transfer Öğrenimi Kullanılan Çalışmalar.....	19
2.2 Bina Cepheleri Alanında Kullanılan Çalışmalar.....	23
2.3 Çatlak Segmentasyonu Alanında Yapılan Çalışmalar	25
3. MALZEME VE YÖNTEM.....	34
3.1 Beton Yapılarda Çatlak Tespiti	34
3.1.1 Veri Seti	35
3.1.2 DeepCrack.....	36
3.1.3 CrackForest	36
3.1.4 Ağın Eğitimi.....	36
3.1.5 DeepLabV3+	36
3.1.6 Kodlayıcı Modülü	38

3.1.7 ResNet	39
3.1.8 Xception	41
3.1.9 MobileNet	43
3.1.10 Inception-ResNet.....	44
3.1.11 Geniřletilmiş (atrous) Evriřim ve ASPP	45
3.1.12 Kod Çözücü Modül	46
3.1.13 Model Başarım Metrikleri.....	47
3.2 Uydu ve Drone Görüntüleri Kullanılarak Hasar Tespiti	49
3.2.1 Kahramanmarař Veri Seti	49
3.2.2 xBD Veri Seti	52
3.2.3 Ağın Eğitimi ve Test Edilmesi	54
4. BULGULAR VE TARTIřMA	56
4.1 Çatlak Segmentasyonu Sonuçları.....	56
4.2 Kahramanmarař Veri Seti Segmentasyon Sonuçları	63
4.3 xBD Veri Seti Segmentasyon Sonuçları	66
4.4 Ön Görüntü Poligonlarına Dayalı Sınıflandırma Sonuçları	70
4.5 Hesaplama Karmařıklığı Analizi	72
4.6 Tartıřma.....	73
4.6.1 Çatlak Segmentasyonu	73
4.6.2 Uydu ve Drone Görüntüleri	76
5. SONUÇLAR VE ÖNERİLER	79
5.1 Sonuçlar	79
5.1.1 Çatlak Segmentasyonu	79
5.1.2 Uydu ve Drone Görüntüleri	81
5.2 Öneriler	83
KAYNAKLAR	88
ÖZGEÇMİř	99

ŞEKİLLER LİSTESİ

Şekil 3.1 Önerilen Genel Segmentasyon Çerçevesi	35
Şekil 3.2 Her İki Veri Setine Ait Örnekler (a-DeepCrack, b-CrackForest)	35
Şekil 3.3 Özgenel Tarafından Sunulmuş Veri Setine Ait Örnekler	36
Şekil 3.4 DeepLabV3+ Mimarisi	38
Şekil 3.5 ResNet50 Mimarisi	41
Şekil 3.6 ResNet18 Mimarisi	41
Şekil 3.7 Inception Modülünün Kanonik Gösterimi	42
Şekil 3.8 MobileNetV2 Evrişimsel Blokları	44
Şekil 3.9 Inception-Resnet-V2 Modeli/Bloğu	45
Şekil 3.10 Genişletilmiş Evrişim İle Uzamsal Çözünürlüğün Korunması.....	46
Şekil 3.11 10-Katlı Çapraz-Doğrulama İşlemi.....	49
Şekil 3.12 Kahramanmaraş Veri Seti Alanları	50
Şekil 3.13 Kahramanmaraş Veri Seti Alanları Ortofoto Görüntüleri	51
Şekil 3.14 Her Bir Veri Setinden Örnek Görüntüler (a-Joplin b- Kahramanmaraş)..	53
Şekil 3.15 Arka Plan, Hasarsız Ve Tahrip Edilmiş Sınıflar Yüzde Dağılımı	54
Şekil 4.1 DeepCrack Veri Seri İlişkin Eğitim Ve Kayıp Fonksiyonları	59
Şekil 4.2 CrackForest Veri Seri İlişkin Eğitim Ve Kayıp Fonksiyonları.....	60
Şekil 4.3 Farklı Mimarilere İlişkin Elde Edilen Görsel Segmentasyon Çıktıları.....	61
Şekil 4.4 Farklı Mimarilere İlişkin Segmentasyon Performanslarının Kutu Grafiği .	62
Şekil 4.5 Kahramanmaraş Deprem Veri Seti Üzerinde Her Bir Segmentasyon Ağı İçin Eğitim Doğruluğu Ve Kayıp Eğrileri.....	64
Şekil 4.6 K.Maraş Depremi Veri Seti İçin Seg. Sonuçlarının Görselleştirilmesi	65
Şekil 4.7 Joplin Kasırgası Felaketi Veri Kümesi Üzerinde Her Bir Segmentasyon Ağı İçin Eğitim Doğruluğu Ve Kayıp Eğrileri.....	68
Şekil 4.8 xBD (Joplin Tornado Felaketi) Veri Kümesi İçin Segmentasyon Sonuçlarının Görselleştirilmesi.....	69
Şekil 4.9 Joplin Tornado Veri Setinden Örnek Görüntüler İçin Her Bir Segmentasyon Ağının Bina Düzeyinde Sınıflandırma Sonuçları	71
Şekil 4.10 Farklı Omurga Tabanlı Modeller İçin Parametre Boyutu (Parametre Sayısı), Çıkarım Süresi Ve Segmentasyon Performansının Görsel Karşılaştırması ..	73

TABLÖLAR LİSTESİ

Tablo 2.1 Hava Görüntüleri Üzerinden Hasar Tespiti Alanında Geleneksel Yöntemler Kullanılan Modellerin Performans Değerlendirmesi.....	12
Tablo 2.2 Hava Görüntüleri Üzerinden Hasar Tespiti Alanında ESA Kullanılan Modellerin Performans Değerlendirmesi.....	18
Tablo 2.3 Hava Görüntüleri Üzerinden Hasar Tespiti Alanında Transfer Öğrenimi Kullanılan Modellerin Performans Değerlendirmesi.....	22
Tablo 2.4 Hava Görüntüleri Üzerinden Hasar Tespiti Alanında Bina Cepheleri Kullanılan Modellerin Performans Değerlendirmesi.....	25
Tablo 2.5 Çatlak Segmentasyonu Alanında Literatürde Önerilen Modellerin Performans Değerlendirmesi.....	32
Tablo 4.1 DeepCrack Veri Setine İlişkin Segmentasyon Sonuçları.....	56
Tablo 4.2 Crackforest Veri Setine İlişkin Segmentasyon Başarımları.....	57
Tablo 4.3 Kahramanmaraş Depremi İçin Beş Kat Çapraz Doğrulama Sonrasında Elde Edilen Segmentasyon Sonuçları.....	63
Tablo 4.4 Joplin Kasırgası Felaketinin Beş Kat Çapraz Doğrulamasından Sonra Elde Edilen Segmentasyon Sonuçları.....	67
Tablo 4.5 Her Bir Segmentasyon Ağı İçin Bina Poligon Tabanlı Sınıflandırmanın Performansı.....	70
Tablo 4.6 Farklı Modeller İçin Toplam Öğrenilebilir Parametrelerin (M), Ortalama Çıkarım Süresinin (ms) ve Segmentasyon Performansının Karşılaştırılması.....	72

SİMGELER VE KISALTMALAR LİSTESİ

Simge	Açıklama
μ	Ortalama Değer
σ	Standart Sapma
f/s	Frame per second
ms	Miliseconds
TP	True Positive
FP	False Positive
TN	True Negative
FN	False Negative

Kısaltma	Açıklama
İHA	İnsansız Hava Aracı
CBS	Coğrafi Bilgi Sistemleri
MAKS	Mekânsal Adres Kayıt Sistemi
ESA	Evrişimsel Sinir Ağı
IoU	Intersection over Union
mIoU	Mean Intersection Over Union
DSC	Dice Similarity Coefficient
ML	Makine Öğrenmesi
DVM	Destek Vektör Makineleri
KNN	K-En Yakın Komşu
SAR	Sentetik Açıklıklı Radar
RF	Rastgele Orman
LiDAR	Işık Tespiti ve Uzaklık Ölçümü
ELD	Yükseklik Farkı
TD	Doku Farkı
CD	Tutarlılık Farkı

VHR	Yüksek Çözünürlüklü
Mask R-ESA	Maskeli Bölgesel Evrişimsel Sinir Ağı
YOLO	You Only Look Once
FCN	Tam Evrişimli Ağ
ASPP	Atrous Spatial Pyramid Pooling
ResNet	Residual Network
BOW	Bag of Words
DEM	Sayısal Yükseklik Modeli
ViT	Vision Transformer
MLP	Çok Katmanlı Algılayıcı
OECAE	One-Epoch Convolutional Autoencoder
OSM	Open Street Map
AP	Ortalama Hassasiyet
GB	Gradyan Artırımı
XGB	Aşırı Gradyan Artırımı
DT	Karar Ağacı
SSD	Single-Shot Multibox Detector
HoG	Histogram of Oriented Gradients
GIoU	Generalized Intersection over Union
ICC	Intra-Cluster Classification
SKM	Seçmeli Çekirdek Modülü

ÖZET

AFET SONRASI YAPI HASARLARININ UZAKTAN ALGILAMA GÖRÜNTÜLERİ İLE SEMANTİK SEGMENTASYON TABANLI DEĞERLENDİRİLMESİ

ALPERGİN, Serhat

Yüksek Lisans, Elektrik-Elektronik Mühendisliği Bölümü

Danışman: Prof. Dr. Mehmet Sıraç ÖZERDEM

İkinci Danışman: Doç. Dr. Hasan POLAT

Haziran 2025, 113 sayfa

Doğal afetler sonrası yapıların çatı, cephe ve bina içi hasar görüntüleri üzerinden hasar bilgisini çıkarmak için hava görüntüleri ve bina içi görüntülerin entegrasyonundan faydalanmak, uzaktan algılama ile hasar tespitinde en etkili ve güvenilir yöntem olacaktır. Bina içi hasar tespitinde yapıların taşıyıcı elemanları üzerinden inceleme yapılmakta olup, bina dışından yapılacak incelemede cephe ve çatı incelenebilmektedir. Bu tezin birinci çalışmasında, betonarme yapıların deprem sonrası hasar tespiti ve çatlak segmentasyonu amacıyla geleneksel makine öğrenimi yöntemlerinin sınırlamalarını aşmak üzere geliştirilen derin öğrenme tabanlı segmentasyon yaklaşımları ele alınmıştır. Beton yüzeylerindeki çatlakların piksel düzeyinde tespiti amacıyla önerilen DeepLabV3+ tabanlı semantik segmentasyon mimarisi kapsamında, kodlayıcı blokta kullanılan farklı ön eğitilmiş omurga mimarilerinin performansları karşılaştırmalı olarak analiz edilmiştir. Söz konusu mimarilerin, düşük ve yüksek seviyeli özellik çıkarımı üzerindeki etkinliklerini değerlendirmek üzere DeepCrack ve CrackForest adlı açık erişimli veri setleri kullanılmıştır. Gerçekleştirilen deneysel çalışmalar sonucunda, MobileNetV2 mimarisinin hem parametre verimliliği hem de segmentasyon doğruluğu açısından diğer omurga yapılarından üstün performans sergilediği tespit edilmiştir. İkinci çalışma, doğal afetler sonrası yapı hasar tespiti amacıyla geliştirilen derin öğrenme tabanlı semantik segmentasyon modellerinin doğruluk, genelleme kabiliyeti ve hesaplama verimliliği açısından kapsamlı bir analizi sunulmuştur. Çalışma kapsamında, özgün hazırlanan Kahramanmaraş depremi veri seti ile birlikte Joplin Kasırgası ve xBD'ye ait yüksek çözünürlüklü drone ve uydu görüntülerinden oluşan veri kümeleri kullanılarak bina yıkım derecelerinin tespiti hedeflenmiştir. DeepLabV3+ segmentasyon mimarisi farklı omurga (backbone) ağları ile yapılandırılarak değerlendirilmiştir. Ayrıca, bina bazlı sınıflandırma için Joplin Kasırgasına ait afet öncesi görüntülerden çıkarılan poligon sınırları ile segmentasyon çıktıları birleştirilerek, bina düzeyinde hasar durumu belirlenmiştir. Deneysel sonuçlar, ResNet50 ve Xception mimarilerinin genel segmentasyon doğruluğu açısından en başarılı modeller olduğunu, buna karşılık MobileNetV2'nin daha az hesaplama maliyetiyle özellikle hızlı ve hafif uygulamalarda avantaj sağladığını göstermektedir. Öte yandan, sınıf dengesizliği ve karmaşık enkaz yapısı nedeniyle tüm modellerin yıkılmış binaların tespitinde zorluk yaşadığı, bu durumdan en çok etkilenen modellerin daha düşük katman derinliğine sahip yapılar olduğu gözlemlenmiştir. Bu çalışma, afet sonrası hızlı ve doğru hasar değerlendirmesi için derin öğrenme tabanlı bir çerçeve sunmaktadır.

Anahtar Kelimeler: Hasar Tespiti, Yapısal Sağlık İzleme, Derin Öğrenme, Uydu ve Drone Görüntüleri, DeepLabV3+, Semantik Segmentasyon

ABSTRACT

POST-DISASTER STRUCTURAL DAMAGE ASSESSMENT BASED ON SEMANTIC SEGMENTATION USING REMOTE SENSING IMAGES

ALPERGİN, Serhat

Master of Science in Department of Electrical and Electronics Engineering

Supervisor: Prof. Dr. Mehmet Sıraç ÖZERDEM

Co-Supervisor: Assoc. Prof. Dr. Hasan POLAT

June 2025, 113 pages

In the aftermath of natural disasters, integrating aerial imagery with interior building images is considered one of the most effective and reliable methods for remote sensing-based damage assessment, as it enables the extraction of structural damage information from roof, façade and interior views. While interior damage analysis focuses on inspecting structural elements, exterior assessments are typically limited to roofs and façades. The first part of this dissertation addresses deep learning-based semantic segmentation approaches developed to overcome the limitations of conventional machine learning techniques in post-earthquake damage detection and crack segmentation in reinforced concrete structures. Specifically, a DeepLabV3+ based semantic segmentation architecture was proposed for pixel-level detection of surface cracks in concrete. Within this framework, the performance of various pre-trained backbone architectures was comparatively analyzed in the encoder block. To evaluate the effectiveness of low and high-level feature extraction capabilities of these architectures, publicly available datasets, namely DeepCrack and CrackForest, were employed. experimental results demonstrated that the MobileNetV2 model outperformed the others in terms of both parameter efficiency and segmentation accuracy. The second part of this study presents a comprehensive analysis of deep learning-based semantic segmentation models for post-disaster structural damage assessment in terms of accuracy, generalization ability and computational efficiency. Using the custom-built Kahramanmaraş Earthquake dataset, along with high-resolution drone and satellite imagery from the Joplin Tornado and xBD datasets, the objective was to detect building-level damage grades. The DeepLabV3+ segmentation architecture was evaluated using various backbone networks. For building-level classification, segmentation outputs were merged with polygon boundaries extracted from pre-disaster imagery to determine the structural damage status of individual buildings. experimental findings revealed that ResNet50 and Xception provided the highest segmentation accuracy overall, whereas MobileNetV2 offered advantages in computational efficiency, making it preferable for lightweight and rapid applications. On the other hand, due to class imbalance and the complexity of debris patterns, all models exhibited difficulty in accurately detecting fully collapsed buildings an issue most prominent in architectures with shallower depth. This study proposes a deep learning-based framework for rapid and accurate post-disaster damage assessment.

Keywords: Damage Detection, Structural Health Monitoring, Deep Learning, Satellite and Drone Imagery, DeepLabV3+, Semantic Segmentation

1. GİRİŞ

Günümüz inşaat mühendisliğinde, yapıların taşıyıcı sistem bütünlüğünün korunması ve yapısal güvenliğin sürekliliğinin sağlanması, tasarım ve uygulama süreçlerinin temel amaçları arasında yer almaktadır. Bu amacı gerçekleştirmedeki en büyük zorluklardan biri ise doğal afetlerin, özellikle depremlerin, yapılar üzerinde oluşturduğu dinamik ve yıkıcı etkilerden kaynaklanmaktadır. Doğal afetler dünya çapında canlıların hayatlarını kaybetmeleri ve yapı ile altyapının ciddi hasarlar görmesine neden olmaktadır. Bir afet olayından hemen sonraki saatlerde hasarlı binaların yerinin belirlenmesi, acil durum müdahale aşamasının öncelikli ve hayati görevlerinden biridir. Bu yüzden, afetlerin ardından yapıların ve altyapının hızlı ve otomatik hasar tespiti, acil durum müdahalesini ve kaynaklarını hızlandırmak için kritik öneme sahiptir. Yapı stoğundaki artış ve çeşitlilik, saha ekipleri tarafından manuel olarak yapılan hasar tespitlerinin zaman alıcı ve emek yoğun olmasına neden olabilmektedir. Bu bağlamda, uzaktan algılama, bölgeyi incelemek ve acil durum eylemlerini organize etmek için elde edilen bilgileri kullanmak adına uygun maliyetli ve hızlı bir yoldur. Uzaktan algılamanın gelişmesi sayesinde, görüntüler genellikle afet olayından hemen sonra elde edilebilmektedir. Bu sayede doğru hasar tespit haritaları oluşturularak, acil müdahale ekiplerinin ve ilgili kuruluşların kaynak yönetimi etkinleştirilebilmektedir [1, 2]. Klasik yöntemler ile zorlanılan problemlerin çözümünde yapay zeka algoritmaları devreye girmektedir. Geleneksel saha araştırma yöntemleriyle karşılaştırıldığında, uzaktan görüntüleme modunu benimseyen uzaktan algılama teknolojisi, zamanında bilgi edinme ve saha koşullarıyla sınırlı olmama gibi birçok avantaja sahip olup, bu sayede yapıların afet hasarı bilgilerini çıkarmak için ana teknik araç haline gelmiştir.

1.1 Uydu ve Drone Görüntüleri Üzerinden Hasar Tespiti

Coğrafi Bilgi Sistemleri ile uzaktan algılamanın entegrasyonu, afet yönetimi için son derece önemli araçlar olarak ortaya çıkmaktadır. Yapılan çalışmalar, uydu, uçak, drone, Işık Tespiti ve Uzaklık Ölçümü (LiDAR) ve radar gibi uzaktan algılama görüntülerinden ve derin öğrenmeden yararlanılarak, yüksek kaliteli bina ayak izlerinin oluşturulması ve her bina için hasar seviyesi sınıflandırması ile hasar tespit sürecinin hızlandırılabilceğini göstermiştir [3, 4]. Son yıllarda, uzaktan algılama görüntülerine dayalı olarak deprem hasarına maruz kalan binaların tespiti, esas olarak

yıkılmış binaların tanımlanmasına odaklanmıştır. Bunun nedeni, deprem sonrası çöken binaların acil müdahale ve kurtarma çalışmalarında birincil hedef olan canlıların, bu binalarda mahsur kalmasıdır. Hava görüntüleri kullanılarak yapı hasar tespitinin yapılması ile ilgili mevcut çalışmalar üç kategoriye ayrılabilir: (1) sadece deprem sonrası görüntüleri kullanan teknikler (2) deprem öncesi ve sonrası görüntülere dayanan teknikler (3) yükseklik verileri birleştiren yöntemler [5].

Deprem sonrası görüntüleri kullanan yöntemler, deprem öncesi verilere bağımlılığı ortadan kaldırır ve deprem öncesi-sonrası görüntülere odaklı tekniklere göre daha güçlü evrenselliğe sahiptir [6]. Hasar tespiti görevi esas olarak anlamsal bir segmentasyon problemi olarak kabul edilir [7, 8]. Çökmüş binalar, spektrum, doku ve alan gibi manuel tanımlanan veya otomatik olarak elde edilen özelliklerin çıkarılmasıyla tasvir edilir ve böylece tahmin için uygun bir sınıflandırıcı seçilir. Buna rağmen, yıkılan binaların çeşitliliği ve deprem sonrası senaryoların karmaşıklığı, farklı spektrumlara sahip aynı nesneler ve aynı spektruma sahip farklı nesneler gibi belirgin problemlere yol açmakta, bu da daha ayırt edici sınıflandırma modellerinin oluşturulmasını gerektirmektedir. Ayrıca, binaların çöküp çökmediğini belirlemek için doğrudan kanıt olarak yükseklik bilgisinin eksikliği, bu tür yöntemlerin pratik uygulamasında hala ana zorluktur [9].

Deprem öncesi ve sonrası görüntüleri kullanan yöntemler, tipik özelliklerin değişimlerini çıkararak binaların hasar derecesini değerlendirmek için kullanılabilir [10]. Deprem öncesi verilerin referans olarak kullanılması nedeniyle, depremlerden önce var olan, yıkılmış binalara benzer özelliklere sahip diğer zemin nesneleri, genellikle bu tür yöntemler kullanılarak tespit sonuçlarından etkili bir şekilde elenebilir. Buna rağmen, normal kentsel gelişim, deprem etkisine ek olarak çok sayıda değişiklik de üretebilir. Ayrıca, depremlerden sonra deprem öncesi verilerin eksikliği genellikle bu tür yöntemlerin yaygınlaşmasını ve uygulanmasını kısıtlayan bir darboğazdır [11, 12]. Bunun yanı sıra, etkilenen bölgeden afet öncesi ve sonrası hava görüntülerine sahip olmak, binaların yerini tespit etmeye ve hasarlı kısımlarını değerlendirmeye yardımcı olacaktır.

Yükseklik verilerini birleştiren yöntemler, uzaktan algılama görüntülerine dayalı olarak, LiDAR ve sayısal yükseklik modeli gibi yükseklik verileri tarafından sağlanan yükseklik bilgileri, bu tür yöntemlerde binaların çöküp çökmediğini belirlemek için güçlü bir temel olarak kullanılır [13, 14]. Çökmüş binaların tespitinde, yükseklik verilerindeki ani düşüşler veya deformasyonlar analiz edilir. Uzaktan algılama görüntüleri, yükseklik verileriyle güçlü bir şekilde tamamlayıcı olmasına rağmen, pratik uygulamada sadece çökmüş binaların tespiti için özel olarak yükseklik verilerinin toplanması ve üretilmesi yaygın bir uygulama değildir. LiDAR veya yüksek çözünürlüklü Sayısal Yükseklik Modeli (DEM) üretimi maliyetli ve zaman alıcı olabilir.

Geleneksel makine öğrenimi teknikleri ile karşılaştırıldığında, derin öğrenme, hiyerarşik öğrenme yoluyla karmaşık bir fonksiyonun yaklaşımını elde etmek için derin bir doğrusal olmayan ağ yapısını benimser ve böylece gelişmiş özellikler çıkarır [15]. Bina hasarları için en yaygın yaklaşım uydu görüntülerini kullanarak değerlendirme yapmak, sorunu segmentasyon ve sınıflandırma görevlerinin bir kombinasyonu olarak ortaya koymak ve derin öğrenme modellerini afet öncesi ve sonrası uydu görüntüleri üzerinde eğitmektir. Birçok araştırmacı, kabul edilebilir performansa sahip modeller geliştirebilmek için evrimsel sinir ağlarına (ESA'lar) dayanan derin öğrenme modelleri kullanmıştır [16-18]. Örneğin, Weber ve Kané, bina hasar tespitini, hasar seviyelerinin farklı sınıf etiketlerine atandığı semantik bir segmentasyon görevi olarak incelemiştir. Afet öncesi ile sonrası görüntü kanalları tek bir girdide birleştirilerek, modelin afet öncesi ve sonrası koşulların kanalları arasında ayırım yapmasına dayanmakta ve bu da öğrenme sürecini zorlaştırmaktadır [19]. Abdi vd. kasırga sonrası İnsansız Hava Aracı (İHA) görüntüleri üzerinde ESA'lar kullanarak bina yamalarını dört hasar seviyesine göre sınıflandırmıştır [20]. Benzer şekilde, Zhang vd. afet öncesi ile sonrasında elde edilen iki zamanlı görüntüleri kullanarak bina hasar tespiti amacıyla anlamsal segmentasyon problemini çözmek için uçtan uca bir prosedür geliştirmiştir [21]. Bu modeller, ham görüntülerden düşük ila yüksek seviyeli özelliklerin hiyerarşik temsillerini otomatik olarak öğrenme yetenekleri sayesinde, hasar tespiti uygulamaları için çok uygundur.

1.2 Çatlak Segmentasyonu

Yapısal sağlık izleme kapsamında çatlak tespiti amacıyla, bilgisayarlı görü destekli pek çok otonom sistem geliştirilmiştir. Sınıflandırma ve segmentasyon, bu sistemlerin dayandığı başlıca iki yaklaşımı oluşturmaktadır. Sınıflandırma temelli yöntemlerde, görüntüler yalnızca çatlak içerip içermediklerine göre etiketlenirken; segmentasyon tabanlı yöntemler, çatlakların uzamsal konumlarını ve biçimsel özelliklerini pikseller düzeyinde belirleyerek daha ayrıntılı bilgi sunmaktadır. Segmentasyon yaklaşımlarının sunduğu detaylı çıktılar, özellikle hasarın konumunun ve morfolojisinin belirlenmesi açısından sağladığı avantajlar, bu yönetime yönelik ilgiyi artırmıştır. Literatürde, segmentasyon temelli çatlak tespit yöntemleri temel olarak iki ana kategoride incelenmektedir; geleneksel (konvansiyonel) görüntü işleme tekniklerine dayalı yaklaşımlar ve derin öğrenme temelli yöntemler [22].

Geleneksel yöntemlerde, çatlaklara ait karakteristik özelliklerin görüntüden manuel olarak çıkarılması ve bu özniteliklerin makine öğrenmesi algoritmalarına uygun nitelik vektörlerine dönüştürülmesi esastır. Bu bağlamda, geometrik (örneğin uzunluk, genişlik, eğrilik) ve fotometrik (örneğin parlaklık, kontrast) öznitelikler çatlak segmentasyonu sürecinde yaygın olarak kullanılmaktadır [23]. Kenar tespiti, gri seviye histogram analizleri ve dalgacık dönüşümleri gibi klasik teknikler ise geleneksel çatlak segmentasyonu uygulamalarında sıklıkla başvurulan yöntemler arasındadır [24]. Örneğin, Talab vd. beton yüzeylerdeki çatlakları tespit etmek amacıyla Sobel kenar belirleme filtresine dayalı bir algoritma önermiştir [25]. Chun vd. çatlak tespiti için geometrik özniteliklerin yanı sıra ışık gradyanlarını artırmaya yönelik bir yöntem geliştirmiştir [26]. Benzer şekilde, Zou vd. üç aşamadan oluşan bir segmentasyon yöntemi önermiştir: Jeodezik giderme, tensör tabanlı oylama ve kenar belirleme [27]. Bununla birlikte, bu geleneksel yaklaşımlar çoğunlukla sınırlı büyüklükteki veri kümeleri üzerinde eğitilmiş ve spesifik sahnelerle göre optimize edilmiştir. Bu durum, söz konusu yöntemlerin farklı koşullara genellenebilirliğini ve sahada doğrudan uygulanabilirliğini sınırlamaktadır [28]. Ayrıca, düşük kontrast, aydınlatma değişkenliği, yüzey kirliliği, doku bozulmaları ve çatlak morfolojisindeki çeşitlilik gibi çevresel faktörler; özellikle veri kümesinin büyük boyutlara ulaştığı durumlarda, geleneksel yöntemlerin doğruluğunu ciddi şekilde düşürebilmektedir

[29, 30]. Bu sınırlamalar, ön işleme adımlarını veya manuel özellik mühendisliğini zorunlu kılmakta ve bu nedenle daha otomatik, esnek ve yüksek genelleme kapasitesine sahip yaklaşımlara olan ihtiyacı artırmaktadır.

Günümüzde derin öğrenme temelli yaklaşımlar, görüntü işleme alanında dikkate değer başarılar elde ederek, karmaşık görsel verilerin işlenmesinde geleneksel tekniklere kıyasla üstün performans sergilemiştir [31]. Özellikle, ham görüntülerden anlamlı özelliklerin otomatik biçimde çıkarılabilmesi ve geniş veri kümeleri üzerinde yüksek doğruluk oranlarıyla çalışabilmesi, bu yöntemleri daha esnek ve güçlü hâle getirmiştir. Bu bağlamda, bilgisayarlı görü temelli çatlak tespiti uygulamalarında da derin öğrenme tekniklerinin kullanımı hızla yaygınlaşmış; bu gelişme, klasik yöntemlerin sınırlamalarını aşma çabalarının bir sonucu olarak ortaya çıkmıştır [29, 32, 33]. Literatürde, derin öğrenme mimarileriyle yapı yüzeylerindeki çatlakların sınıflandırılması [34], hasarlı bölgelerin nesne tespiti yoluyla belirlenmesi [35] ve piksel düzeyinde semantik segmentasyonunun gerçekleştirilmesi [36, 37] gibi uygulamaların başarıyla yürütüldüğü görülmektedir. Ancak, çatlakların çoğunlukla düşük kontrastlı, ince yapılı ve yönü sürekli değişen lineer yapılar biçiminde ortaya çıkması, geleneksel kutu tabanlı tespit yaklaşımlarının performansını sınırlamakta ve bu durum, detaylı analiz imkânı sunan semantik segmentasyon temelli çözümlere olan ilgiyi artırmaktadır [38].

Ağır hasarlı ve çökmüş binalar, ciddi yapısal hasarın güçlü göstergeleri olan dökülme, enkaz, moloz yığınları ve kırık elemanlar gibi dışarıdan görülebilen hasar kanıtlarının tanınmasıyla tespit edilmektedir. Bu hasar kanıtları, nadiren doğrudan görüntülerden çıkarılabilen iç yapı elemanlarındaki, örneğin kolonlar ve kirişler, hasarlar gibi ek bilgiler gerektirdiğinden, binanın gerçek hasar durumunu tespit etmek için tek başına yeterli olmayacaktır. Görüntülerden elde edilebilecek bilgiler sınırlı olsa da, arama ve kurtarma süreçlerine dahil olan paydaşların gereksinimlerini karşılamak için genellikle yeterlidir. Ayrıca, bu bilgiler daha sonraki ayrıntılı değerlendirmelerin planlanmasında, örneğin acil müdahale gerektiren sıcak noktaların belirlenmesinde ve saha incelemesi için konumların önceliklendirilmesinde kullanılabilir [39]. Ayrıca bina hasarının karmaşık görünümü mevcut yöntemler için zorluk teşkil etmektedir [40].

1.3 Hava ve Yersel Görüntüler Üzerinden Hasar Tespiti

Yapıların hasar bilgisini çıkarmak için hava görüntüleri ve bina içi görüntülerin entegrasyonundan faydalanmak etkili yöntemlerden biridir. Bina içi görüntülerden tespit edilemeyen çatı hasarları ile hava görüntülerinden tespit edilemeyen bina içi hasar görüntülerinin entegrasyonu sayesinde, belirlenen alandaki yapıların yapısal hasarlarının tespitinin daha sağlıklı yapılması olanağı sağlayabilir. Yapıların taşıyıcı sistemlerinde oluşan çatlaklar, yapısal hasarların ya da bozulmaların en yaygın göstergeleri arasında yer almaktadır [29, 41]. Bu tür çatlaklar, özellikle doğal afetler sonrasında yapının çökme riski açısından ilk uyarı sinyalleri olarak değerlendirilmekte ve kritik bir öneme sahiptir [42]. Çatlakların varlığı, yapıların güvenliği, uzun ömürlülüğü ve işlevselliği üzerinde doğrudan olumsuz etkiler yaratabilir. Bu nedenle, yapı yüzeylerinde meydana gelen çatlakların kısa sürede ve yüksek doğrulukla tespit edilmesi, yapı denetimi açısından elzemdir. Günümüzde yapı denetim süreçlerinde sıklıkla başvurulana geleneksel yöntem, uzman kişiler tarafından gerçekleştirilen görsel incelemelerdir [43]. Bu yöntem kapsamında çatlaklar genellikle çıplak gözle, el tipi dedektörler yardımıyla veya iskele benzeri platformlar üzerinden yapılan çeşitli testlerle analiz edilmektedir. Ancak söz konusu yöntemlerin zaman açısından verimsiz, yüksek maliyetli ve kullanıcıya bağlı hatalara açık olması, yapı hasarlarının değerlendirilmesinde bilgisayar destekli otomatik sistemlerin geliştirilmesini ve yaygınlaştırılmasını her geçen gün daha önemli bir ihtiyaç haline getirmektedir.

Çalışmanın odak noktası, hem yapı yüzeylerindeki çatlak tespiti hem de afet sonrası bina hasar analizine yönelik kapsamlı, karşılaştırmalı derin öğrenme tabanlı yaklaşımlar geliştirmek ve değerlendirmektir. Bu bağlamda, amaçlar aşağıdaki gibi özetlenebilir:

- Derin öğrenme tabanlı DeepLabV3+ mimarisi kullanılarak, farklı kodlayıcı (encoder) omurga mimarilerinin beton çatlaklarının semantik segmentasyonu üzerindeki etkinliklerini analiz etmek,
- DeepCrack ve CrackForest gibi çeşitli morfolojik yapıya sahip veri setlerinde model başarımını nesnel metriklerle karşılaştırmak,
- Yüksek çözünürlüklü drone ve uydu görüntülerinden, özellikle 2023 yılı Kahramanmaraş Depremi sonrası oluşturulan gerçek veri setlerinde bina

hasar tespiti gerçekleřtirmek ve çoklu veri kaynaklarının (uydu, drone, bina ii grntler) entegrasyonu ile kapsamlı hasar analizi yapmak,

- Bina dzeyinde sınıflandırma iin afet ncesi poligon verilerini kullanarak, modelin afet sonrası kaynak ynetimi ve mdahale planlamasında kullanım potansiyelini deęerlendirmek,
- Farklı omurga mimarilerinin, doęruluk, hesaplama yk, hesaplama verimlilięi, eęitim sresi ve tahmin zamanı gibi pratik uygulama kriterleri zerindeki etkilerini karřılařtırmalı olarak incelemek,
- Doęal afetlerden sonra arama-kurtarma ve mdahale planlamaları ile gerek zamanlı uygulamalar iin donanımsal olarak uygulanabilir, hafif derin mimarilerin tespit edilmesi ve etkin bir karar destek sisteminin tasarımı amalanmaktadır.

Bu tez alıřmasında, iki temel problemin zmne odaklanılmıřtır. İlk olarak, yapı taşıyıcı sistemlerindeki atlakların derin ęrenme temelli segmentasyonu; ikinci olarak, uydu ve drone grntleri zerinden hasar tespiti yapılması ile uzaktan algılama verilerinin bu srece katkısı detaylı olarak analiz edilmiřtir. Elde edilen bulguların, literatre katkıda bulunması ve afet ynetimi alanında hızlı ve gvenilir karar destek sistemlerinin geliřtirilmesine temel oluřturması hedeflenmiřtir.

2. ÖNCEKİ ÇALIŞMALAR

Derin öğrenmenin gelişimi ile deprem hasarı değerlendirmesindeki ilerlemeler umut verici olsa da, belirli sınırlamalar devam etmekte ve araştırmacıları yenilikçi çözümler önermeye teşvik etmektedir. Uydu görüntülerinin zamansal çözünürlüğü, genellikle tekrar ziyaret aralıklarıyla sınırlıdır. Bu durum, özellikle sismik olaylar sırasında ve sonrasında gerçek zamanlı veri elde edilmesini güçleştirmektedir. Bu sınırlamayı aşmak amacıyla, uydu verilerinin İHA görüntüleriyle entegrasyonu, önerilen çözümlerden biri olarak öne çıkmaktadır. Mekânsal çözünürlük, büyük kentsel alanlarda zorluk olup, hasar tespitinde mekânsal netliği artırmak için daha yüksek çözünürlüklü sensörlerin kullanılması veya çok çözünürlüklü veri setlerinin birleştirilmesi önerilmektedir. Afet sonrası aşırı bilgi yüklemesi sorunu, daha erişilebilir bir formatta karar vericileri eyleme geçirilebilir bilgiler sağlamak için otomatik hasar değerlendirme araçlarının Coğrafi Bilgi Sistemleri (CBS) ile entegre edilmesini içermektedir. ESA gibi Makine Öğrenmesi (ML) modellerinin yoğun öğrenme algoritmalarının yorumlanabilirliği diğer bir zorluktur. Daha açıklanabilir modellere yönelik öneriler veya yorumlanabilirlik tekniklerinin entegrasyonu, hasar tespit uygulamalarında bu algoritmaların şeffaflığını ve güvenilirliğini artırmayı amaçlamaktadır. Büyük veri kümelerini etiketlemek, makine öğrenimi modellerini eğitmek için bunlara açıklama eklemek, zaman ve kaynak gerektiren bir işlemdir. Çalışmalar, önceden eğitilmiş modellerin sınırlı etiketli örneklerle sahip yeni veri kümelerine uyarlandığı modellere yönelmektedir. Derin öğrenme metodolojileri, özellikle de ESA'lar, yapısal hasar modellerini doğru bir şekilde ayırt etmede üstün performans göstermektedir. Destek Vektör Makineleri (DVM) ve Karar Ağaçları (DT) gibi geleneksel sınıflandırma yaklaşımları ise daha az incelikli algoritmik çerçevelere bağımlılıkları ve manuel olarak tasarlanmış özellikler nedeniyle, daha düşük doğruluklar sergileme eğilimindedir. Deprem sonrası hasar değerlendirmelerinin etkinliğini artırmak için makine öğrenimi metodolojileri, sensör teknolojisi ve veri yönetimi stratejilerindeki gelişmeleri birleştirerek bu alanın disiplinler arası doğasının altını çizmek çözüme katkı sağlayabilir [44].

2.1 Hava Görüntüleri Kullanılan Çalışmalar

2.1.1 Geleneksel Yöntemler Kullanılan Çalışmalar

Geleneksel makine öğrenimi algoritmaları, deprem hasar tespitine katkılar sağlamıştır.

Wang vd. deprem sonrası uzaktan algılama görüntülerine dayalı olarak yıkılan binaların tespiti için çok kaynaklı verilerden geleneksel görsel özellikler ve çift sıçrama özellikleri arasındaki tamamlayıcı bilgileri çıkarmıştır. Deprem sonrası yüksek çözünürlüklü Sentetik Açıklıklı Radar (SAR) görüntülerinden ortak nesne kümeleri türetilerek, görsel özellikler ile SAR görüntülerine özgü çift yansıma özellikleri birleştiren, yıkılmış binalar için bir tespit yöntemi önermiş olup, tespit sonuçları geliştirilmiş aktif öğrenme DVM'lere dayalı olarak elde edilmiştir [5].

Tu vd. afet sonrası acil müdahale ve kurtarma operasyonlarına destek amacıyla, görsel Bag-of-Words (BoW) modeli ve sınıflandırma temelli yeni bir hasarlı bina bölgesi tespit yöntemi önermektedir. Yöntem kapsamında, afet öncesi görüntülerdeki bina bölgeleri BoW tabanlı sahne sınıflandırmasıyla belirlenmekte; ardından, afet öncesi ve sonrası görüntüler arasındaki değişim, görsel öznitelik frekanslarına dayalı olarak kodlanmakta ve DVM sınıflandırıcı ile analiz edilmektedir. Tespit edilen bina bölgeleri afet sonrası görüntülere aktarılıp karşılaştırılarak, hasarlı ve hasarsız alanlar ayrıştırılmaktadır. Deneysel sonuçlar, yöntemin bina hasarlarının tespitinde etkili ve uygulanabilir olduğunu göstermekte olup, sahne temelli değişim analizine dayalı yaklaşımlar için önemli katkılar sunmaktadır [10].

Bai vd. 2015 Nepal depremini bir vaka çalışması olarak ele alarak, olay sonrası çift polarimetrik SAR görüntülerinin deprem hasar tespiti için kullanımını, deprem sonrası hasarı sınıflandırmada uydu görüntülerinden çıkarılan özellikleri kullanarak, K-En Yakın Komşu (KNN) ve DVM'nin etkinliğini göstermiştir. Hasarlı ve hasarsız kentsel alanların radar saçılma özellikleri, bir dizi polarimetrik SAR özelliği kullanılarak karşılaştırılmış ve sonuçlar, tek bir polarimetrik özellik ile hasarlı ve hasarsız kentsel alanları ayırt etmenin zor olduğunu göstermiştir. Pearson korelasyon analizi, çapraz polarizasyonun geri saçılma katsayısından türetilen doku özelliklerinin, karo tabanlı bina hasarını belirlemede diğer özelliklere kıyasla yüksek

performans sergilediğini ortaya koymuştur. Denetimli öğrenme sonucu, özellik azaltmanın sınıflandırma doğruluğunu artırabileceğini ve DVM sınıflandırıcısının karo birimindeki iki sınıf hasarı sınıflandırmada %80,5 oranında genel bir doğruluk elde ettiğini göstermiştir. Bu sonuçlar, deprem hasarı değerlendirmeleri için polarimetrik SAR bilgilerinin önemini ve verimliliğini göstermektedir. Ayrıca, şu anda uydu görüntülerinden yalnızca kısmi çatı çökmesi veya tam çökme gibi önemli hasarlar güvenilir bir şekilde görülebildiği, bu sınırlamaların, yöntemin diğer deprem senaryolarına iyi bir şekilde genelleştirilememesine neden olabileceği değerlendirilmiştir [45].

Khodaverdi vd. olay sonrası yüksek çözünürlüklü uydu görüntüleri ve LiDAR raster verileri üzerinde çok çözünürlüklü segmentasyon algoritması ile oluşturulmuş görüntülerinin birleştirilmesine dayanan nesne tabanlı bir algoritma verileri üzerinden dokusal, geometrik ve istatistiksel özellikleri, KNN sınıflandırma algoritması aracılığıyla her iki veriyi sınıflandırmak için uygulamıştır. Son olarak, her iki sınıflandırma sonucu entegre edilerek kesinlikle hasarlı, muhtemelen hasarlı ve hasarsız olmak üzere üç sınıftan oluşan nihai bir hasar haritası oluşturulmuştur. Önerilen entegre yöntemin Haiti veri seti üzerinde uygulanan diğer hasar tespit teknikleriyle karşılaştırılması, genel doğruluk durumunda önerilen yöntemin üstünlüğünü göstermiştir [46].

Rao vd. deprem sonrası hasarlı binaları belirlemede topluluk öğrenme yöntemlerinin faydasını göstermek için Rastgele Orman (RF) sınıflandırıcıları kullanmıştır [47].

Hajeb vd. Kumamoto depreminin binalarda yol açtığı hasarı değerlendirmek için deprem öncesi ve sonrasında SAR ve LiDAR verileri bir arada kullanmış, hasar oranını sınıflandırmak ve tahmin etmek için DVM ve RF dahil olmak üzere, hasar tespiti için makine öğrenimi algoritmaları kullanılarak, olay öncesi ve sonrası LiDAR görüntülerindeki yükseklik farkı (ELD) ve doku farkı (TD) ile olay öncesi ve sonrası SAR görüntülerindeki tutarlılık farkı (CD) olmak üzere üç değişken dikkate alınmış ve bunların sonuçları çıkarılmış olup, ELD parametresinin hasarlı binaların belirlemede önemli derecede rol oynadığını göstermiştir [48].

Takhtkeshha vd. deprem sonrası hızlı bina hasarı tespitinde, derin olmayan özelliklerden derin özellikleri çıkarmak için ‘non-deep’ (geleneksel), ‘deep’ (derin) ve bu ikisinin füzyonu olmak üzere üç farklı özellik kümesi değerlendirilmiş, derin özellikler, ‘tek epok konvolüsyonel otomatik kodlayıcı’ (One-Epoch Convolutional Autoencoder – OECAE) aracılığıyla geleneksel özelliklerden elde edilmiştir. DVM, RF, Gradyan Artırımı (GB), Aşırı Gradyan Artırımı (XGB), DT, KNN ve adaBoost dahil olmak üzere yedi makine öğrenimi algoritması ve temel bir derin öğrenme algoritması (yani, Çok Katmanlı Algılayıcı (MLP)) bina hasar haritalarını elde etmek için uygulanmış, kendi kendini denetleyen, hızlı bir derin öğrenme yöntemini İHA verilerini kullanarak sunmuştur. Sonuçlar, otomatik seçilen eğitim örneklerinin manuel seçimlere kıyasla, doğruluk (%22) ve kappa katsayısı (%33) açısından önemli üstünlük sağladığını göstermektedir. OECAE ile elde edilen derin ve geleneksel özelliklerin birleşimi, yalnızca tek başına kullanılan özelliklere göre hasar tespit performansını anlamlı şekilde artırmıştır [49].

Mittal vd. xBD veri seti üzerinden bölge tabanlı hasar değerlendirmesi amacıyla denetimsiz bir öğrenme çerçevesi tanıtmış, bu çerçeve, etiketli eğitim verilerine ihtiyaç duymadan büyük ölçekli uydu görüntüsü veri kümelerindeki hasarı değerlendirmede kullanılmış; algoritma, K-Means algoritması ile karşılaştırılarak küme grafikleri aracılığıyla K-Means’e kıyasla çok daha etkili performans gösterdiği ortaya konulmuştur [50].

Karimzadeh vd. deprem sonrası hasarlı ve sağlam yolların ayrımını yapmak ve bakım-onarım gerektiren kaldırım bölgelerini tespit ederek önceliklendirmek amacıyla, SAR görüntülerinden elde edilen veriler üzerinde multilayer perceptron sınıflandırma yöntemi uygulamışlardır [51].

Literatürde hava görüntüleri üzerinden hasar tespiti alanında geleneksel yöntemler kullanılan modellerin performans değerlendirmesi Tablo 2.1’de verilmiştir.

Tablo 2.1 Hava Görüntüleri Üzerinden Hasar Tespiti Alanında Geleneksel Yöntemler Kullanılan Modellerin Performans Değerlendirmesi

Referans	Veri Seti	Model	DSC	IoU	Doğruluk	Keskinlik	Duyarlılık
[5] Wang, C. at al. (2022)	Sendai-1	Active Learning	-	-	0.824	-	-
	Sendai-2	DVM	-	-	0.806	-	-
	Sendai-3		-	-	0.786	-	-
[10] Tu, J. at al. (2017)	Ludian	BoW + DVM	-	-	0.917	-	-
[11] Jun,L& Pei,L.(2019)	Earthquake	OHI+	-	-	-	-	-
	Bam	Histogram	0.796	0.661	0.882	-	-
[44] Ö. Kaya (2024)	Ref_Direct_	DVM	-	-	0.648	-	-
	PCA_minCor						
[45] Bai, Y. at al. (2017)	Gorkha, Nepal	DVM	-	-	0.805	-	-
[46] Khodaverdi,N. at al.(2019)	Earthquake Haiti	KNN	0.820	0.695	0.920	0.990	0.700
[48] Hajeb, M. at al. (2020)	Kumamoto	DVM	-	-	0.871	-	-
[49] Takhtkeshha, N.at al. (2023)	Kermanshah, Iran	DVM	-	-	0.820	-	-
		MLP	-	-	0.820	-	-
[51] Karimzadeh,S. at al.(2022)	Kumamoto Earthquake	Multilayer Perceptron	0.831	0.711	0.871	0.975	0.975

2.1.2 ESA Kullanılan Çalışmalar

Günümüzde derin öğrenme, görüntü sınıflandırma, nesne algılama ve görüntü segmentasyonu gibi bilgisayarla görmenin çeşitli yönlerinde başarılı sonuçlar elde etmiştir. Çalışmalar, derin öğrenme teknolojilerinin, özellikle de ESA'ların yapısal hasar modellerini yüksek doğruluklarla ayırt etmedeki üstün performansının altını çizmektedir. Araştırmacılar, otomatik yapısal hasar tespiti için çok yöntem geliştirmiştir.

Shen vd. uydu görüntülerinden bina hasar değerlendirmesi için BDANet olarak adlandırılan yeni, iki aşamalı evrimsel sinir ağı önermiş, ilk aşamada, binaların konumlarını çıkarmak için bir U-Net kullanılmış, daha sonra, ilk aşamadaki ağ ağırlıkları bina hasar tespiti için ikinci aşamada paylaşılmıştır. İkinci aşamada, afet öncesi ve sonrası görüntülerin ağa ayrı ayrı beslendiği iki dallı çok ölçekli bir U-Net omurga olarak kullanılmaktadır. Afet öncesi ve sonrası görüntüler arasındaki korelasyonları keşfetmek için çapraz yönlü bir dikkat modülü önerilmiştir. Ayrıca, zor sınıfların üstesinden gelmek için CutMix veri artırımından yararlanılmıştır [3].

Yang vd. VGG16, Inception V3, Resnet50 ve DenseNet121 olmak üzere dört düzeltilmiş ESA modelini eğitmek üzere bina görüntülerinden yeterli eğitim örnekleri hazırlamak için xBD veri seti kullanmış, ESA ağının uydu ve hava fotoğraflarından depremden zarar görmüş bina bilgilerinin belirlenmesindeki performansı değerlendirilmiştir. xBD örnekleriyle önceden eğitilen ESA modellerinin coğrafi ve veri aktarılabilirliği, Wenchuan bölgesinin Çok Yüksek Çözünürlüklü (VHR) uydu görüntü örnekleri ve 2008 Wenchuan depreminden hemen sonra elde edilen Beichuan bölgesinin hava fotoğrafı örnekleri ile doğrulanmıştır. xBD örnekleriyle önceden eğitilmiş ve düzeltilmiş DenseNet121, seçilen dört ESA modeli arasında en iyi performansı sergilemiştir. Transfer öğrenme, ağ modelinin farklı platformlar tarafından elde edilen uzaktan algılama görüntülerine zayıf uyarlanabilirlik sorununu çözmüş ve afetten zarar görmüş binaları doğru bir şekilde tanımlayabilmiştir [52].

Maraş ve Sarıyıldız, Haiti depremi verilerini kullanarak, hasarlı yapıların hızlı ve güvenilir biçimde tespit edilebilmesini amaçlayan çalışmada, Maskeli Bölgesel Evrişimsel Sinir Ağı (Mask R-ESA) modelini kullanarak hasar tespiti gerçekleştirmiştir. Çalışmada, İHA kullanılarak temin edilen görsellerin konumsal çözünürlüğündeki artışın, afet sonrası yapı hasarlarının belirlenmesinde derin öğrenme yaklaşımlarının etkinliğini artırabileceği vurgulanmıştır [53].

Bhangale vd. yüksek performanslı ikili sınıflandırma ile afet verileri için derin ESA modeli oluşturmuş ve hasar tespiti için Haiti deprem sonrası afet veri seti üzerinde uygulamıştır [54].

Nex vd. ticari bir İHA ile bina hasarlarını neredeyse gerçek zamanlı olarak otonom bir şekilde haritalamak için yeni bir çözüm önermiş, görüntülerin bir dizüstü bilgisayarda canlı olarak yayınlanmasına ve anında işlenmesine olanak tanıyan farklı bileşenleri entegre etmiştir. Derin öğrenme algoritmaları ile gelişmiş fotogrametrik teknikler bir araya getirilerek bina hasarlarının konumunu gösteren gerçek bir ortofoto elde edilmiş ve bu görüntüler İHA üsse döndüğünde zaten işlenmiş olmaktadır. Bu algoritmalar, gerçek zamanlı gereksinimleri karşılayacak ve hızlı sonuçlar verecek şekilde özelleştirilmiştir. Önerilen metodoloji, neredeyse tamamen

otonom bir çözüm sunmak için farklı alanlardan gelen farklı çözümlerden faydalanmaktadır. Yazılım geliştirme kitleri ile yapılan özelleştirmeler, görüntülerin özel bir dizüstü bilgisayarda yayınlanmasına izin verirken, fotogrametri ve derin öğrenme algoritmalarının entegrasyonu, bina hasar haritalarının verimli bir şekilde oluşturulmasını sağlamıştır [55].

Ma vd. depremlerden sonra uzaktan algılama görüntülerindeki bina gruplarının hasar bilgilerini çıkarmak için geliştirilmiş bir ESA yaklaşımını, CBS verileriyle birleştirerek yeni bir strateji önermişlerdir [56].

Deng vd. afet sonrasında, binaların hasar seviyesini sınıflandırırken, binaları segmentlere ayırabilen bina hasar tespiti için bir ağ tasarlamış, U-Net'i temel alarak iki aşamalı bir bina hasar tespit ağı modellemiştir. İlk aşama, bina segmentasyonuna odaklanan bağımsız bir U-Net ve ardından bina hasar sınıflandırmasına odaklanan bir Siam U-Net'tir. Ekstra atlama bağlantısı ve asimetrik evrişim bloğu, ağın farklı binaları segmentlere ayırma yeteneğini geliştirmek için kullanılmıştır [57].

Ahmadi vd. doğal afetlerden sonra, bina lokalizasyonu ve hasar tespiti görevleri için bina ayak izi lokalizasyonu ve bina başına hasar seviyesi sınıflandırmasındaki yanlışlıkları gidermek amacıyla iki dal arasında paylaşılan ağırlıklara sahip iki aşamalı, çift dallı bir U-Net mimarisi önermiştir. Önceden eğitilmiş özellik çıkarma omurgaları, Seçmeli Çekirdek Modülü (SKM) ile birlikte, yerleştirme ve hasar değerlendirme performanslarını iyileştirmek için kullanılmıştır [58].

Xie vd. uzaktan algılama görüntülerindeki hasarlı binaların özelliklerine dayanarak, heterojenlik özelliklerini dikkate alan hasarlı bina tespitine yönelik çerçeve önermiştir. Öncelikle, ağın özellik algılama yeteneğini geliştirmek için hasarlı binaların özelliklerini farklı yönlerden çıkarabilen ve küresel ile yerel bilgileri etkili bir şekilde harmanlayan yerel-küresel bağlam dikkat modülü önerilmiştir. Ayrıca modül, bilgi çıkarırken farklı ölçeklerdeki özellik haritaları arasındaki korelasyonu da dikkate almaktadır. İkinci olarak, kodlama ve kod çözme süreçleri arasındaki basit bağlantıyı değiştirmek için kendi kendine dikkat eden bir özellik füzyon modülü kurulmuş olup, bu da yukarı örnekleme işlemi sırasında ağın ayrıntılı özellik

kurtarma yeteneğini geliştirmektedir. Son olarak, farklı ölçeklerdeki anlamsal ve ayrıntılı özellikleri tam olarak toplamak için, tahmin aşamasına iki ayrı dal eklenerek çok dallı bir yardımcı sınıflandırıcı oluşturulmuştur. Önerilen yaklaşımın etkinliği 2010 Haiti depreminden elde edilen verilere dayanarak doğrulanmış ve üç nesne yönelimli yöntem ve mevcut 16 derin öğrenme modeli ile karşılaştırmalar yapılmıştır. Derin öğrenme modelleri ile karşılaştırıldığında önerilen yaklaşım kullanılarak %0,03-%7,39 oranında IoU artışı elde edilmiştir [59].

Qing vd. süper piksel seviyesinde ESA tabanlı doğrudan uzaktan algılama değişim tespiti kullanılarak, operasyonel bir deprem kaynaklı bina hasarı değerlendirmesi önermiş, ilk olarak, görüntü işleme kapsamını daraltmak için ekstra özellik geliştirme bantları (EFEB'ler) kullanılarak merkez üssüne yakın hassas bina alanları çıkarılmıştır. Ardından, hassasiyeti ve verimliliği artırmak için, olay öncesi süper piksel kısıtlaması stratejisine sahip, doğrudan bir değişiklik algılama yöntemine dayalı olarak çıkarılan bina alanlarında ince ölçekli bina hasarı tespit edilmiştir. Son olarak, hasarı nicel olarak değerlendirmek için hızlı bir uzaktan algılama deprem hasar endeksi kullanılmıştır. Vaka çalışmasının deneysel sonuçları, hasarlı binaların önerilen iş akışına göre doğru ve etkili bir şekilde konumlandırılabilmesini ve sınıflandırılabilmesini göstermektedir. Tek zamanlı görüntü ve olay sonrası segmentasyon ile yapılan karşılaştırmalı deneyler, doğrudan değişiklik tespitinin üstünlüğünü daha da somutlaştırmaktadır. Hasar değerlendirme sonucu, Ludian depreminden sonraki resmi raporla eşleşerek önerilen iş akışının güvenilirliğini kanıtlamıştır [60].

Mei vd. çift zamanlı uydu görüntülerinden eşzamanlı bina lokalizasyonu ve çok seviyeli değişiklik tespiti için farka duyarlı bir dikkat ağı (D2ANet) önermiş, afet öncesi ve sonrası görüntülerin özelliklerindeki ayrı kanallardaki farklılıkları göz önünde bulundurarak, özelliklerin değişime duyarlı kanallarını uyarmak ve küresel değişim modelini öğrenmek için eşleştirilmiş özellikleri kullanan çift zamansal bir toplama modülü geliştirmiştir. Afetlerin neden olduğu bina hasarının doğası karmaşık ortamlarda çeşitlilik gösterdiğinden, çok seviyeli değişiklikler arasındaki yerel korelasyonlardan yararlanmak için bir fark-dikkat modülü tasarlanmış, bu da farklı ölçeklerdeki hasarı belirleme yeteneğini geliştirmiştir. Büyük ölçekli bina

hasarı deęerlendirmesinde, xBD veri seti üzerinde yapılan detaylı analizler, yaklaşımın son teknoloji ürünü yeni sonuçlar sağladığını göstermektedir [61].

Wu vd. hasarlı binaları tek seferde konumlandırabilen ve sınıflandırabilen bir Siyam sinir ağı önermiş olup, bu ağıın ana parçaları, farklı omurgalar kullanan çeşitli dikkat U-Net'tir. Dikkat mekanizması, işe yaramayan özelliklerin etkisini azaltmak için ağıın etkili özelliklere ve kanallara daha fazla dikkat etmesini sağlar. Bina hasar deęerlendirmesinin ilerlemesi için büyük ölçekli xBD veri seti kullanılmış, sonuç dengeli F1 puanları karşılaştırılmıştır. Skor, dikkat mekanizmasına sahip SEresNeXt'in performansının, 0,787'ye ulaşan F1 skoru ile tekli modeller dikkate alındığında üstün performans sağladığını göstermektedir. Modelin aktarılabilirliğini ve sağlamlığını doğrulamak için, performansı araştırmak üzere iki yeni afetin Maxar Açık Veri Programındaki veri seti seçilmiştir. Görsel karşılaştırma ile sonuçlar, modelin sağlam ve genellenebilir olduğunu göstermiştir [62].

Gupta vd. afet sonrası senaryolarda etkilenen alanları ve erişilebilir yolları belirlemek için, segmentasyon sinir ağlarını kullanan bir çerçeve önermiş, hava görüntüsü segmentasyonu görevinde ImageNet ile ön eğitimin etkinliği analiz edilmiş ve popüler segmentasyon modellerinin performansları karşılaştırılmıştır. Deneysel sonuçlar, ImageNet üzerinde ön eğitimin genellikle bir dizi model için segmentasyon performansını artırdığını göstermektedir. Eğitim için OpenStreetMap'ten (OSM) elde edilebilen herkese açık veriler kullanılmış ve zaman alan manuel açıklama ihtiyacı ortadan kaldırılmıştır. Yöntem ayrıca OSM'den elde edilebilen yol ağı verilerini güncellemek ve doğal bir afetin yol açtığı değişiklikleri tespit etmek için çizge teorisinden yararlanmıştır. Anlamsal segmentasyon görevi için farklı kodlayıcılar kullanmada, VGG16'nın diğer tüm özellik çıkarma modüllerinden daha iyi performans gösterdiğini aktarmıştır [63].

Moradi ve Hosseini, piksel tabanlı, yüksek çözünürlüklü, uzaktan algılama görüntüleri üzerinden Haiti'nin VHR uydu görüntüleri ve bir konvolüsyon ağı olan U-Net üzerinde çalışmış, öğrenme algoritmasının sonuçları iyileştirmek için yaptığı derin değişiklikler, depremin neden olduğu binaların hasarını belirlemeye yönelik

olup, piksel piksel bozulmayı inceleyen önceki çalışmaların yanı sıra, nihai kesinliği artırmak için bu yaklaşımın başarısını göstermiştir [64].

Miura vd. ortofoto görüntüler üzerinden, ESA modelleri kullanarak, deprem sonrası bina hasarlarının sınıflandırılmasına yönelik çalışma gerçekleştirmiştir. Çalışma kapsamında binalar; çökmüş, çökmemiş ve mavi muşamba ile kaplanmış olmak üzere üç ana kategoriye ayrılmıştır. Bu sınıflandırma, yapısal hasar seviyelerine göre ağır hasar, ihmal edilebilir hasar ve genellikle orta düzey hasar aralığı ile ilişkilendirilmiştir. Bununla birlikte, güneş panelleri ile molozların ayırt edilmesi, yumuşak kat çökmelerinin belirlenmesi, duvarlardaki kılcal çatlaklar ve önemsiz deformasyonların tespitinde modelin sınırlı başarı gösterdiği ifade edilmiştir. Bu tür örneklerin veri setine daha fazla dahil edilmesinin, modelin genel sınıflandırma performansını artırabileceği öngörülmektedir [65].

Çarkıt, bina hasar tespiti için çift görevli bir U-Net modeli geliştirmiştir. Model, xBD veri kümesi kullanılarak eğitilmiş ve Kahramanmaraş depremlerine ait afet öncesi ve sonrası VHR uydu görüntülerine uygulanmıştır. Modelin başarımı, üretilen hasar haritalarının yer gerçekliği verileriyle karşılaştırılması sonucu F1 skoru esas alınarak değerlendirilmiştir. Sonuçlar, modelin özellikle hasarsız binaları yüksek doğrulukla tespit ettiğini göstermiştir [66].

Literatürde hava görüntüleri üzerinden hasar tespiti alanında ESA kullanılan modellerin performans değerlendirmesi Tablo 2.2’de verilmiştir.

Tablo 2.2 Hava Görüntüleri Üzerinden Hasar Tespiti Alanında ESA Kullanılan Modellerin Performans Değerlendirmesi

Referans	Veri Seti	Model	DSC	IoU	Doğruluk	Kesinlik	Duyarlılık
[3] Shen, Y. at al. (2021)	xBD	Wnet	0,737	0,584	-	-	-
		UNet++	0,740	0,587	-	-	-
		BDANet	0,806	0,675	-	-	-
	Levir	Wnet	0,934	0,876	-	0,879	0,995
	-CD	UNet++	0,940	0,887	-	0,890	0,996
[7] Cao, Q.D., &Choe, Y..(2018)	Hurricane Harvey& Michael	Texas BDANet	0,942	0,890	-	0,895	0,995
		Leaky+ Transfer	0,964	0,931	0,961	-	-
		ESA+DA	0,972	0,946	0,972	-	-
[16] Gupta, R& Shah, M.(2020)	xBD	RescueNet	0,770	0,626	-	-	-
[21] Zhang, Y.at al(2023)	xBD	LRBNet	0,749	0,599	-	-	-
[40] Qiao, W. at al.(2024)	Haiti Earthquake	sw_SqueezeNet	0,419	0,265	0,835	0,296	0,717
		sw_VGG16	0,460	0,299	0,874	0,357	0,646
		sw_ResNet101	0,434	0,277	0,087	0,334	0,621
		U-Net	0,765	0,619	0,961	0,785	0,746
		Weakly supervised semantic segmentasyon	0,720	0,563	0,950	0,710	0,720
[52] Yang, W. at al.(2021)	xBD, Wenchuan, Beichuan Earthquake	VGG16	0,825	0,702	0,836	0,867	0,883
		InceptionV3	0,789	0,652	0,803	0,831	0,852
		ResNet50	0,523	0,354	0,635	0,870	0,950
		DenseNet121	0,805	0,674	0,821	0,889	0,800
[53] Maraş, E.E.& Saryıldız, H.İ.(2023)	Haiti Earthquake	Mask R-ESA Binary	0,908	0,832	0,951	0,867	0,971
		Mask R-ESATernary	0,659	0,491	0,829	0,664	0,663
[54] Bhangale, U.M. at al (2019)	Haiti Earthquake	Derin ESA	-	-	0,850	-	-
[55] Nex, F. at al.(2019)	Lyon, Roquebilliere	MF	0,659	0,491	-	0,573	0,821
		MF+ESA	0,835	0,717	-	0,839	0,831
[56] Ma, H. at al.(2020)	Yushu Earthquake	Inception V3	-	-	0,900	-	-
[57] Deng, L.& Wang, Y.(2022)	xBD	U-Net (Baseline + ESC + ACB)	0,874	0,776	-	-	-
		U-Net (Baseline + ESC + ACB + SA)	0,789	0,652	-	-	-
[58] Ahmadi, S.A. at al.(2024)	xBD Bam City Earthquake	U-Net	0,805	0,674	-	0,820	0,790
		ResNet34-Unet	0,800	0,667	-	0,820	0,780
		EfficientNet	0,820	0,695	-	0,840	0,800
		UNet	-	-	-	-	-
		EfficientNet	0,880	0,786	-	0,890	0,870

Tablo 2.2 (Devam)

[59] Xie, Y. at al.(2022)	Haiti Earthquake	DeepLabv3+	0,807	0,669	0,853	0,788	0,828
		DVM	0,637	0,467	0,671	0,535	0,788
		Resnet101	0,810	0,688	0,858	0,797	0,823
[60] Qing, Y. at al.(2022)	Ludian Earthquake, China	Direct change detection + PreSC	0,686	0,522	-	0,582	0,840
		Direct change detection	0,629	0,459	-	0,503	0,840
		AlexNet + PreSC	0,590	0,420	-	0,480	0,770
		CEESA + PreSC	0,680	0,520	-	0,580	0,840
[61] Mei, J. at al.(2023)	xBD	D2ANet (ResNet-101)	0,754	0,605	-	-	-
[62] Wu, C. at al.(2021)	xBD	ResNet+Attention	0,744	0,592	-	-	-
		SEresNeXt+Attention	0,787	0,649	-	-	-
		U-Net					
		DPN+Attention	0,781	0,641	-	-	-
		SENet+Attention	0,779	0,638	-	-	-
[63] Gupta, A.S. at al.(2020)	Palu Earthquake, Endonezya	ENet	0,928	0,866	-	-	-
		ENetSeparable	0,940	0,887	-	-	-
		LinkNet (ResNet18)	0,945	0,896	-	-	-
		LinkNet (ResNet34)	0,947	0,899	-	-	-
		UNet (VGG11)	0,938	0,883	-	-	-
		UNet (VGG16)	0,945	0,896	-	-	-
		UNetUp (VGG16)	0,943	0,892	-	-	-
[64] Moradi, M. & Shah-Hosseini, R. (2021)		UNet	-	-	0,687	-	-

2.1.3 Transfer Öğrenimi Kullanılan Çalışmalar

Transfer öğrenimi deprem hasar tespitine başka bir boyut kazandırmaktadır. Özellikle güçlü hesaplama ve büyük veri gerektiren modellerin avantajlarını, daha küçük ve spesifik görevler için kullanmayı mümkün kılar. Bu şekilde, eğitim süresi ve veri ihtiyacı azaltılır.

Kaur vd. doğal afetlerin ardından uydu görüntülerine dayalı olarak bina hasarlarını sınıflandırmak için hiyerarşik dönüştürücülü U-Net tabanlı mimariye sahip hiyerarşik dönüştürücü mimarisi (DAHiTrA) kullanarak hasar değerlendirmesi sunmaktadır. Çalışmada, bina hasarını değerlendirmek için yeni bir transformatör tabanlı ağ önerilmiş, bu ağ, birden fazla çözünürlükteki hiyerarşik uzamsal özelliklerden yararlanır ve uzamsal özelliklere bir dönüştürücü kodlayıcı uyguladıktan sonra özellik alanındaki zamansal farklılıkları yakalar. Önerilen ağ, bina lokalizasyonu ve

hasar sınıflandırması için xBD ve değişiklik algılama görevleri için LEVIR-CD veri seti üzerinde test edildiğinde gelişmiş performans elde etmiştir. Ayrıca, modeli sınırlı ince ayarlarla uyarlayarak ve böylece modeli kıt veriye sahip yeni hasar görmüş alanlara uygulayarak, bu veri setini kullanmanın bir yaklaşımını göstermektedir [4].

Li vd. single-shot multibox detector (SSD) yönlendirmeli, eğitim ve veri artırımı ile hasarlı bina değerlendirme yöntemi önermiş, VGG16'dan oluşan bir Konvolüsyon Otomatik Kodlayıcı (CAE) oluşturulmuş ve etiketlenmemiş afet sonrası görüntüler kullanılarak eğitilmiştir. Bir transfer öğrenme stratejisi olarak, SSD modelinin ağırlıkları CAE muadilinin ağırlıkları kullanılarak başlatılmış, eğitim veri setini artırmak için görüntü yansıtma, döndürme, Gauss bulanıklaştırma ve Gauss gürültüsü işleme gibi veri artırma stratejileri kullanılmıştır. Deneyler, ön eğitim stratejisinin sıfırdan eğitilen SSD'ye kıyasla genel doğruluk açısından %10'luk bir iyileşme sağlayabileceğini göstermektedir. Bu deneyler ayrıca veri artırma stratejilerinin kullanılmasının mAP ve mF1'i sırasıyla %72 ve %20 oranında iyileştirebileceğini göstermektedir [67].

Shi vd. deprem sonrası hava görüntülerinden yıkılmış binaları tespit etmek amacıyla YOLO mimarisinin klasik bir versiyonu olan ve geliştirilmiş biçimiyle kullanılan you only look once versiyon 4 model (YOLOv4) mimarisini önermiş, özellikle, K-NN algoritmasını görüntüden çapa sayısını ve boyutunu en uygun şekilde seçmek için kullanılmıştır. YOLOv4'teki CSPDarkNet53'teki Resblock'u, omurganın yeteneğini ve sınıflandırma performansını iyileştirmek için ResNext bloğu ile değiştirilmiştir. Ayrıca, YOLOv4'ün kayıp fonksiyonunu Focal-EOIU kayıp fonksiyonu ile değiştirilmiştir. Sonuçlar, orijinal YOLOv4 modeliyle karşılaştırıldığında, önerilen yöntemin çökmüş binaları daha doğru bir şekilde çıkarabildiğini göstermektedir. AP (ortalama hassasiyet) %88,23'ten %93,76'ya yükselmiştir. Tespit hızı 32,7 f/s'ye ulaşmıştır. Yöntem doğruluğu artırmakla birlikte, yıkılmış binaların tespit hızını da artırmıştır [68].

Shi vd. afet sahnelerinin karmaşıklığı ve veri kümelerinin azlığı, bina hasarının belirlenmesinde büyük zorluklar olduğundan, bu zorlukların üstesinden gelmek için, depremden sonra alınan hava görüntülerini kullanarak binaların hasar derecesini

sınıflandırmak ve değerlendirmek için Cross Conv Transformer modeli önermiştir. Görüntülerden özellik çıkarmak için Conv-Embedding ve Conv-Projection kullanılmış, Konvolüsyon ve Transformatörün entegrasyonu, modelin hesaplama yükünü azaltırken, özellik çıkarma yeteneklerini geliştirmiştir. Ayrıca, her bir dalın sırasıyla küresel ve yerel özelliklere odaklanmasına olanak tanıyan, küresel ve yerel dikkati olan iki dallı Conv-Transformer mimarisi tasarlanmıştır. Çapraz dikkat füzyon modülü, sınıflandırma özelliklerini zenginleştirmek için iki daldan gelen özellik bilgilerini birleştirir. Son olarak, modeli değerlendirmek için Beichuan ve Yushu depremleri sırasında çekilen hava görüntüleri, eğitim ve test veri seti olarak alınmıştır. Önerilen Cross Conv-Transformer modeli, Vision Transformer (ViT) ve EfficientNet'e kıyasla sınıflandırma doğruluğunu sırasıyla %4,7 ve %2,1 oranında artırmıştır. Sonuçlar, Cross Conv-Transformer modelinin ağır ve orta derecede hasar kategorileri arasındaki yanlış sınıflandırmayı önemli ölçüde azaltabileceğini göstermektedir [69].

Hu ve Tang, ilk olarak afet sonrası uydu görüntülerini kullanarak, hava görüntüleri üzerinde eğitilen U-NASNetMobile modelin genelleme yeteneği değerlendirmiş, ardından, afet sonrası uydu görüntüleri için genelleme yeteneğini geliştirmek amacıyla üç tür yöntemi sistematik olarak analiz etmiştir. Her afetten rastgele seçilen çok az sayıda eğitim örneği kullanarak modele ince ayar yapılmış, CycleGAN kullanarak afet sonrası uydu görüntülerinin stili aktarılmış ve etki alanı karşıt eğitimi kullanarak, özellik dönüşümü gerçekleştirilmiştir. Deneyde kullanılan xBD uydu görüntüleri, kasırga, hortum, deprem, tsunami, sel ve orman yangını gibi dünya çapında sıkça meydana gelen altı afet türünden 14 farklı olaydan oluşmaktadır. Deneysel sonuçlar, üç yöntemin bina haritalama açısından küresel modelin doğruluğunu önemli ölçüde artırabileceğini ve binaların hasar bilgilerini daha hızlı çıkarmak için gelişmiş bir transfer-öğrenme yöntemiyle birleştirilmiş, mevcut bir küresel modeli kullanarak sınıflandırma sonrası karşılaştırma yapmanın umut verici olduğunu göstermiştir [70].

Literatürde hava görüntüleri üzerinden hasar tespiti alanında transfer öğrenimi kullanılan modellerin performans değerlendirmesi Tablo 2.3'te verilmiştir.

Tablo 2.3 Hava Görüntüleri Üzerinden Hasar Tespiti Alanında Transfer Öğrenimi Kullanılan Modellerin Performans Değerlendirmesi

Referans	Veri Seti	Model	DSC	IoU	Doğruluk	Kesinlik	Duyarlılık
[4] Kaur,N. at al. (2022)	xBD	DAHITrA	0.819	0.872	-	-	-
	xBD	Siam-Unet	0.743	0.824	-	-	-
	xBD	BDANet	0.806	0.864	-	-	-
	Levir-CD	DAHITrA	0.908	0.842	-	-	-
	Levir-CD	Siam-Unet	0.859	0.813	-	-	-
	Ida-BD	DAHITrA	0.585	0.805	-	-	-
[20] Abdi,G. at al.(2022)	Irma, Dorian,Fire	ResNet-34	0.981	0.963	0.981	-	-
[67] Li,Y. at al.(2019)	Hurricane	SSD + CAE	0,678	0,513	-	0,772	-
	Sandy&Irma	SSD + CAE	0,569	0,398	-	0,515	-
[68] Shi,L. at al.(2021)	Yushu	YOLOv4	0,654	0,486	-	0,820	0,882
	Earthquake	YOLOv4+ResNext	0,721	0,564	-	0,860	0,895
	Wenchuan	YOLOv4 + ResNext	0,872	0,773	-	0,890	0,937
	Earthquake	+ Focal-EIOU Loss					
[69] Shi, L. at al. (2023)	xBD	ResNet	-	-	0.913	-	-
		Vision Transformer	-	-	0.936	-	-
		EfficientNet	-	-	0.948	-	-
		Cross Conv-Transformer	-	-	0.976	-	-
[70] Y. Hu and H. Tang. (2021)	(xBD)	U-NASNetMobile +	-	0.702	-	0.789	0.863
	Moore-TD	Transfer					
	Harvey-HC		-	0.331	-	0.546	0.452
	Nepal-FD		-	0.368	-	0.424	0.753
	Joplin-TD		-	0.469	-	0.509	0.828
[71] Da at al.(2022)	xBD	Resnet50	0,785	0,646	-	-	-
		SDAFormer (without SF)	0,795	0,660	-	-	-
		SDAFormer (with SF)	0,802	0,669	-	-	-
[72] Ma, H. at al.(2020)	Haiti	YOLOv3	0,827	0,705	-	0,880	0,780
	Earthquake	Yolov3-ShuffleNet	0,838	0,721	-	0,870	0,810
		YOLOv3 -S-GIoU	0,904	0,825	-	0,930	0,880
		DenseNet121	0,790	0,653	0,790	0,820	0,730
		Multi-temporal					

Da vd. simetrik bir hiyerarşik dönüştürücüyü, Siam U-Net benzeri bir ağa yerleştiren SDAFormer adlı yeni iki aşamalı hasar değerlendirme çerçevesi önermiş; ilk aşamada, afet öncesi görüntü, bina lokalizasyonu için bir segmentasyon ağına beslenmiştir. İkinci aşamada, ilk aşamadan paylaşılan ağırlıklara dayalı olarak iki dallı bir hasar sınıflandırma ağı kurulmuştur. Ardından, afet öncesi ve sonrası

görüntüler hasar tespiti için ağı ayrı ayrı gönderilmiş, ayrıca, Swin Transformer bloklarında uzamsal bilgi oluşturan piksel düzeyinde korelasyon oluşturarak özellik temsil yeteneğini geliştirmek için bir uzamsal füzyon modülü tasarlanmıştır. Önerilen çerçeve, büyük ölçekli bina hasarı değerlendirme veri seti-xBD üzerinde önemli bir gelişme sağlamaktadır [71].

Ma vd. deprem sonrası uzaktan algılama görüntülerinden yıkılmış binaları bulmak için ESA'ya dayalı nesne algılama yöntemini YOLOv3 uygulamayı amaçlamış, ayrıca, YOLOv3 daha etkili tespit sonuçları elde etmeye yönelik geliştirilmiştir. İlk olarak, YOLOv3'teki Darknet53 ESA, hafif ESA ShuffleNet v2 ile değiştirilmiş, ikinci olarak, kayıp fonksiyonundaki tahmin kutusu merkez noktası, XY kaybı ve tahmin kutusu genişliği ve yüksekliği, WH kaybı, Generalized Intersection over Union (GIoU) loss ile değiştirilmiştir. Geliştirilmiş YOLOv3 modeli kullanılarak Yushu ve Wenchuan depremlerinden sonra 0,5 m çözünürlükte yüksek uzamsal çözünürlüklü, havadan uzaktan algılama görüntüleri ile yapılan deneyler, parametre sayısında önemli bir azalma göstermiş olup, genel YOLOv3 ile karşılaştırıldığında, tespit hızı 5,21 f/s ve hassasiyeti %5,24 oranında iyileşmiştir [72].

2.2 Bina Cepheleri Alanında Kullanılan Çalışmalar

Literatürdeki bazı çalışmalar çatı haricinde, bina cephelerinin de analizini gerektirmesi nedeniyle, eğik açılı (oblique) görüntülere odaklanmıştır.

Duarte vd. araştırmalarında çoklu zamansal cephe hasar tespiti üzerine odaklanmışlardır. Bu çalışmanın ilk amacı, konvolüsyonel sinir ağlarına dayalı denetimli bir sınıflandırma yöntemi çerçevesinde, afet öncesi ve sonrası eğik hava görüntülerini en uygun şekilde birleştirerek cephe hasarlarını tespit etmektir. İkinci hedef ise, cephe görüntülerinin genellikle insanlı hava fotogrametrisiyle yapılan çalışmalarda farklı açılardan elde edilen çoklu görünümle temsil edildiği gerçeğinden yola çıkarak, bu çoklu görünüm verilerini birleştiren çeşitli yöntemlerin geliştirilmesidir. Bu doğrultuda, önerilen yöntemler görüntü sınıflandırma sürecine entegre edilmiştir. Çalışmada altı farklı çoklu zamansal yaklaşım, üç tekli zamansal yöntem ile karşılaştırılmış; elde edilen bulgular, çoklu zamansal tekniklerin f1-skoru

açısından tekli zamansal yaklaşımlara göre yaklaşık %25 oranında daha başarılı olduğunu ortaya koymuştur [73].

Kakooei ve Baleghi, afet sonrası bina hasar tespiti amacıyla yalnızca çatı örtüsünü değil, aynı zamanda bina cephelerinin de analizini gerektirmesi nedeniyle, oblique görüntüler, afet öncesi mahalle düzeyindeki binaların yapısal özellikleri analiz edilerek bilgi kümeleri, bina kümeleri düzeyinde toplanmıştır. Böylece, her bir binaya ait afet sonrası hasar durumu, küme düzeyinde elde edilen bilgilerle desteklenmiş, geliştirilen Intra-Cluster Classification (ICC) yöntemi, denetimsiz ve denetimli öğrenme tekniklerinin hiyerarşik bir yapıda entegrasyonunu içermiştir. Bu yöntem ile bina kümeleri içinde hasarlı ve hasarsız bölgeler tespit edilmiştir [74].

Tu vd. tarafından geliştirilen yerel simetri özellikleri ve Gini indeksi tabanlı cephe hasar tespit yöntemi referans alınmıştır. Bu yöntem, oblique hava görüntülerinden elde edilen bina cephelerinde yerel simetri bozulmalarını analiz ederek hasar tespiti yapmaktadır [75].

Vetrivel vd. uzaktan algılama görüntülerinde yapı hasarlarını, görüntüleme ölçeği ve karmaşıklığından bağımsız olarak, ızgara temelli bir sınıflandırma yöntemiyle tespit etmeyi amaçlamışlardır. Bu amaçla, BoW yaklaşımı ile Histogram of Oriented Gradients (HoG) ve Gabor dalgacıkları gibi radyometrik öznitelikler kullanılarak, DVM, RF ve Adaboost sınıflayıcılarıyla denetimli öğrenme modelleri geliştirilmiştir. Çalışmada kullanılan dört farklı veri seti, görüntüleme platformu, ölçek ve sahne karmaşıklığı açısından çeşitlilik göstermektedir [76].

Literatürde hava görüntüleri üzerinden hasar tespiti alanında bina cepheleri kullanılan modellerin performans değerlendirmesi Tablo 2.4'te verilmiştir.

Tablo 2.4 Hava Görüntüleri Üzerinden Hasar Tespiti Alanında Bina Cepheleri Kullanılan Modellerin Performans Değerlendirmesi

Referans	Veri Seti	Model	DSC	IoU	Doğruluk	Kesinlik	Duyarlılık
[73] Duarte,D. at al.(2020)	L'Aquila& Tempera Earthquake,	DenseNet121	0.820	0,695	0,840	0,870	0,800
		Mono-temporal					
		DenseNet121	0,790	0,653	0,790	0,820	0,730
[74] M. Kakooei and Y. Baleghi (2023)	Hurricane Michael 4-class RS-scale	Intra- Cluster-Classification (ICC)	-	-	0.832	-	-
			-	-	0.910	-	-
			-	-			
[75] Tu,J. At al (2017)	Beichuan Earthquake	Simetri-Gini	0.822	-	-	0.837	0.807
[76] Vetrivel,A. (2016)	Dataset 1	BoW-HoG + DVM	-	-	0.98	0.98	0.97
	Dataset 2	BoW-HoG + DVM	-	-	0.91	0.93	0.89
	Dataset 3	BoW-HoG + DVM	-	-	0.96	1.00	.093
	Dataset 4	BoW-Gabor + DVM	-	-	0.91	0.95	0.88

2.3 Çatlak Segmentasyonu Alanında Yapılan Çalışmalar

Derin öğrenmenin görüntü işleme konusundaki başarısından yararlanmak amacıyla, çok sayıda semantik segmentasyon mimarisi geliştirilmiştir. Bu çerçeveler genellikle U-Net [77], SegNet [78], Tam Evrişimli Ağ (FCN) [79] veya DeepLabV3+ [80] gibi temel mimariler kullanılarak ya doğrudan uygulanmış ya da çeşitli mimari değişikliklerle yeniden yapılandırılmıştır. Örneğin Zhang vd. U-Net mimarisinin kenar bilgisi çıkarımındaki eksikliklerini gidermek amacıyla her bir kodlayıcı katmana dikkat (attention) modülleri entegre ederek ALP-UNet adını verdikleri geliştirilmiş bir model sunmuşlardır [81]. Aynı zamanda kod çözücü yapıyı da optimize ederek segmentasyon başarımını önemli ölçüde artırmışlardır. König vd. kodlayıcı-kod çözücü mimariler ile transfer öğrenme yaklaşımlarının performansa etkilerini değerlendirmiş ve farklı omurga mimarileriyle yaklaşık %4'e varan performans değişimleri gözlemlemişlerdir [23]. Lee vd. DANet, U-Net, FCN ve DeepLabV3+ gibi farklı mimarileri kullanarak, yığın öğrenme entegrasyonu sayesinde Jaccard benzerlik indeksinde önemli artışlar elde etmişlerdir [82]. Al-Huda vd. segmentasyon sürecinde karşılaşılan gürültü temelli zorlukları azaltmak için sınıflandırıcı ve segmentasyon ağı arasında bilgi paylaşımı sağlayan hibrit bir model önermiştir [83]. Yang vd. yerel özelliklerin yetersiz işlenmesi ve havuzlama katmanlarının neden olduğu bilgi kayıplarını azaltmak amacıyla, U-Net üzerine

hiyerarşik ve ilerlemeli bağlamsal füzyon modülleri ekleyerek daha yüksek doğrulukta segmentasyon hedeflemiş ve modelin etkinliğini nicel analizlerle ortaya koymuşlardır [22]. Soni vd. FCN tabanlı bir mimaride farklı evrimsel omurga yapılarının performansa etkilerini karşılaştırmış; VGG16'nın semantik öznitelik çıkarımında üstün performans gösterdiğini belirtmişlerdir [84]. Liu vd. iki boyutlu uzamsal ile üç boyutlu geometrik bilgilerin birleşimine dayanan bir segmentasyon modeli sunmuş ve çok boyutlu füzyon yaklaşımı ile mevcut yöntemlerin üzerine çıkan bir başarı elde etmiştir [85]. Lang vd. dikkat mekanizması destekli bir derin segmentasyon mimarisi önererek, arka plan parazitlerinin azaltılması yoluyla segmentasyon doğruluğunu artırmayı başarmışlardır [86].

Özgenel'in çalışması, kapsam ve içerik açısından önceki araştırmalarla benzerlik göstermekte olup, temel olarak sınıflandırma ve çatlak bölgesi tespiti odaklıdır. Çalışmanın ilk bölümünde, farklı yapı elemanlarına ait görüntüler kullanılarak GoogleNet, AlexNet, VGG19, VGG16, ResNet101, ResNet152 ve ResNet50 mimarileri ile çeşitli sınıflandırma modelleri geliştirilmiş ve bu modeller ayrı test verileriyle değerlendirilmiştir. İkinci bölümde ise, yazar tarafından özgün olarak tasarlanıp geliştirilen QuadP isimli bir segmentasyon mimarisi sunulmuştur. Literatürdeki FCN [79] ve SegNet [78] mimarileriyle karşılaştırılan QuadP, dört farklı test ortamında ve çeşitli değerlendirme kriterleri açısından üstün performans göstermiş olup, bu yönüyle, özgün bir model tasarımı ortaya koymaktadır [87-89].

Yılmaz vd. betonarme elemanların sismik hasarlarını sınıflandırmak için derin öğrenme tabanlı akıllı yazılım olan DamageNet ve mobil uygulamalarını geliştirmiştir. Farklı yıkıcı depremlere maruz kalmış 2455 hasarlı elemanın görüntüleri 'datacenterhub' veritabanından toplanmış, DamageNet algoritması, performans ölçütlerine göre önceden eğitilmiş ESA algoritmalarıyla (VGG16, ResNet-50, MobileNetV2 ve EfficientNet) karşılaştırılmıştır. Diğer modellerle maksimum %89 test başarıları elde edilirken, DamageNet ile hasar sınıflandırmada %92 test başarıları elde edilmiştir. DamageNet modeline dayalı olarak geliştirilen mobil uygulama, Kahramanmaraş/Türkiye'de meydana gelen depremler sonrasında sahada test edilmiş ve %88 sınıflandırma başarıları elde edilmiştir [90].

Cangür, çalışmasında Kahramanmaraş merkezli depremler sonrası çekilen görseller kullanılarak betonarme yapılarda oluşan hasarların sınıflandırılması hedeflenmiştir. Çalışmada AlexNet ve VGG19 gibi ESA modelleri kullanılmış, bu modellerin yapısal ve yapısal olmayan hasarları sınıflandırmadaki performansları karşılaştırılmıştır. Veri seti, yöntem olarak k-fold çapraz doğrulama (5 katlı) ile eğitilmiştir. AlexNet modelinin %97,41 doğruluk oranı ve %8,19 kayıp sonuçlarıyla, VGG19 modeli esas alındığında, daha başarılı sonuçlar elde ettiğini göstermektedir. Ayrıca, sınıf aktivasyon haritaları yardımıyla modellerin hasarın yerini doğru şekilde tespit edip etmediği analiz edilmiştir. AlexNet'in, görsellerdeki hasar bölgelerine daha iyi odaklandığı görülmüştür. Çalışma, deprem sonrası hızlı ve nesnel karar destek sistemlerinin geliştirilmesine yönelik değerli katkı sunmaktadır [91].

Ye vd. mevcut çatlak tespit yöntemlerinin sınırlamalarını aşmak ve çoklu nesne içeren ortamlarda beton çatlaklarını daha etkili bir şekilde belirlemek amacıyla YOLOv7 mimarisine dayalı, üç özgün modül içeren bir ağ geliştirmiştir. Bu ağ, algısal alanın yetersizliği, doğruluk sınırlamaları ve gradyan dağılım sorunları gibi temel problemleri çözmeye yönelik olarak Swin Transformer bloklarının entegrasyonu, artık bağlantıların eklenmesi gibi çeşitli tekniklerle optimize edilmiştir. Ayrıca model, değişken çevresel koşullara uyum sağlayabilmek amacıyla farklı çözünürlük, pozlama ve gürültü seviyelerine sahip veri kümeleri üzerinde eğitilmiştir. Deneysel sonuçlar, bu mimarinin yalnızca çatlak tespitinde yüksek doğruluk sunduğunu değil, aynı zamanda çeşitli düzeylerdeki gürültü bozulmalarına karşı da sağlamlık gösterdiğini ortaya koymuştur [92].

Jenkins vd. yol ve kaldırım yüzeylerinde meydana gelen çatlakların piksel bazında sınıflandırılmasını sağlamak amacıyla U-Net mimarisine dayalı tam evrişimli sinir ağı önermiştir. Model, kodlayıcı aşamasında giriş görüntüsünü düşük seviyeli özellik haritalarına dönüştürmekte, ardından kod çözücü katman, bu kodlanmış özellikleri orijinal çözünürlükte yeniden yapılandırmaktadır. Bu süreçte kodlayıcı katmanlarının havuzlama indeksleri verimli bir şekilde yukarı örnekleme amacıyla kullanılmaktadır. Sınıflandırma katmanı, her bir pikselin etiketlenmesini sağlarken, model mevcut uygulanabilir verilerin eksikliğine rağmen, herkese açık bir dizi yol çatlağı veri kümesi üzerinde görüntü segmentasyonu gerçekleştirilmiştir [93].

Fan vd. otomatik olarak kaldırım yüzeylerindeki çatlakları tespit etmek ve ölçmek amacıyla, havuzlama katmanı içermeyen, olasılık füzyonuna dayalı bir konvolüsyonel sinir ağı topluluğu geliştirmiştir. İlk olarak, ham görüntülerden küçük çatlakların yapısal özelliklerini yakalamak için birden fazla ESA modeli kullanılmış; ardından, bu modellerin çıktılarının ortalaması alınarak nihai çatlak olasılığı elde edilmiş, böylece öngörülen bir olasılık haritası oluşturulmuştur. Son aşamada ise öngörülen morfolojik özellikler, iskelet çıkarma algoritması ile ölçülmüştür. CFD ve AigleRN veri tabanlarında gerçekleştirilen deneyler, önerilen yaklaşımın performansını mevcut yöntemlerle karşılaştırmalı olarak ortaya koymuştur [94].

König vd. küçük boyutlu veri kümelerinden verimli şekilde faydalanmak için yama tabanlı bir eğitim süreci benimseyerek, yüzey çatlaklarının anlamsal segmentasyonu için U-Net temelli tamamen konvolüsyonel bir mimari geliştirmiştir. Mimari, kodlayıcı ile kod çözücü katmanları arasında dikkat temelli bir geçitleme mekanizması içermekte ve konvolüsyonel bloklarda artık bağlantılar kullanmaktadır. Bu sayede, yalnızca ilgili aktivasyonların daha ileri katmanlara aktarılması sağlanarak, daha doğru ve anlamlı segmentasyon elde edilmiştir [95].

Altun ve Altun tarafından, beton yüzeylerdeki çatlakların tespiti amacıyla METU veri kümesi kullanılmış ve YOLOv8 mimarisi temel alınarak bir görüntü işleme yaklaşımı geliştirilmiştir. Çalışmada, veri seti çeşitli veri artırma teknikleriyle zenginleştirilmiş ve modelin eğitimi gerçekleştirilmiştir. Elde edilen deneysel bulgular, modelin çatlakları yüksek doğrulukla tespit ettiğini, yanlış pozitif oranının oldukça düşük seviyede kaldığını ve farklı çatlak sınıfları arasında başarılı bir ayırım yapabildiğini göstermiştir [96].

Ali vd. beton yapıların yüzeylerinde meydana gelen çatlakların tespiti amacıyla özel olarak tasarlanmış ESA modeli geliştirmiştir. Bu çalışma kapsamında önerilen model, eğitim veri kümesinin büyüklüğü, veri örneklerinin çeşitliliği (heterojenliği), ağı yapısal karmaşıklığı ve eğitim sürecindeki epok sayısı gibi faktörler dikkate alınarak, dört farklı derin öğrenme mimarisiyle karşılaştırılmıştır. Modelin etkinliği, iki farklı genel veri kümesinden türetilmiş sekiz ayrı veri seti üzerinde test edilmiştir. Karşılaştırmalar, yaygın olarak kullanılan önceden eğitilmiş VGG16, VGG19,

ResNet-50 ve Inception V3 modelleriyle gerçekleştirilmiştir. Elde edilen deneysel bulgular, eğitim verisinin hem miktarının hem de çeşitliliğinin model başarımı üzerinde belirgin etkiler oluşturduğunu göstermiştir. Tüm modeller, sınırlı fakat çeşitli verilerle eğitildiğinde, tatmin edici sonuçlar üretirken, veri miktarının artırılması ve çeşitliliğin azaltılması durumunda genelleme kapasitesinde düşüş gözlemlenmiş ve bu durum aşırı uyum (overfitting) sorununa yol açmıştır. Özelleştirilmiş ESA modeli ile VGG16, sınırlı veri koşullarında sınıflandırma doğruluğu, çatlakların lokalizasyon başarısı ve işlem süresi bakımından diğer yöntemlere kıyasla daha başarılı performans sergilemiştir. Bu sonuçlar, her iki modelin beton yapılarda çatlakların doğru ve verimli bir şekilde tespit edilmesi ve konumlandırılmasında avantaj sağladığını göstermektedir [97].

Fang vd. ham görüntülerdeki çatlakların tespitine yönelik olarak, derin öğrenme algoritmalarını Bayes olasılık analizleri ile birleştiren yenilikçi bir hibrit yöntem geliştirmiştir. Bu yaklaşıma göre, Faster R-ESA gibi gelişmiş bir nesne tanıma ağı yeniden eğitilmiş ve çatlak hatları boyunca yamalar oluşturmak için yarı otomatik bir etiketleme süreci tasarlanmıştır. Elde edilen tespitlerin doğruluğunu artırmak amacıyla, uzamsal yakınlık, yönelme ve hizalama tutarlılığı gibi kriterlere dayalı Bayes entegrasyon algoritması uygulanmış, böylece yanlış pozitif tespitlerin bastırılması sağlanmıştır. Geliştirilen yöntem, yeni bir geniş çaplı çatlak veri seti üzerinde kapsamlı testlerle doğrulanmıştır [98].

Hadinata vd. tarafından gerçekleştirilen karşılaştırmalı çalışmada, beton yüzeylerdeki çatlakları tespit etmede U-Net ve DeepLabV3+ mimarilerinin etkinlikleri değerlendirilmiştir. İç ve dış kaynaklı veri kümeleri kullanılarak yapılan analizler, her iki mimarinin de çatlakların segmentasyonunda yüksek doğruluk sunduğunu ortaya koymuştur. Böylece, encoder-decoder yapısına sahip bu iki modelin, beton yüzey görüntülerinde etkili ve güvenilir segmentasyon sağladığı sonucuna ulaşılmıştır [99].

Arafin vd. beton yapılardaki iki farklı kusur türü olan çatlaklar ve dökülmeleri içeren geniş kapsamlı bir veriseti oluşturmuş ve sınıflandırmak amacıyla önceden eğitilmiş ESA modelleri (ResNet50, InceptionV3, VGG19, Xception ve MobileNetV2)

kullanmıştır. Gerçek koşulları daha iyi temsil edebilmek için veri artırımı uygulanmamış; ayrıca, modellerin hiperparametrelerine ilişkin kapsamlı bir duyarlılık analizi yapılarak en uygun sınıflandırma koşulları belirlenmiştir. Sonuçlar, model performanslarını karşılaştırmalı olarak değerlendirerek en uygun mimari seçiminin yapılmasına olanak tanımıştır [100].

Islam vd. beton yüzeylerdeki çatlakları görüntülerden tespit etmek amacıyla, transfer öğrenmeye dayalı bir derin öğrenme yaklaşımı geliştirmiştir. Bu çalışmada, ImageNet veri seti üzerinden önceden eğitilmiş olan dört farklı ESA mimarisi (VGG16, AlexNet, ResNet18 ve DenseNet161) kullanılarak bir transfer öğrenme stratejisi uygulanmıştır. Model performansı, Kaggle platformunda yer alan BWCI veri kümesi kullanılarak değerlendirilmiş ve transfer öğrenmenin beton çatlak tespiti görevlerinde etkili bir çözüm sunduğu gösterilmiştir [101].

Üncü vd. binalarda oluşan çatlakların ve eğim bozukluklarının tespiti amacıyla görüntü işleme tabanlı ölçüm sistemi geliştirmiş ve bu sistemde ESA tabanlı derin öğrenme algoritmaları kullanılmıştır. Görüntüler ön işleme adımlarından geçirilerek analiz edilmiş ve VGG16 ile InceptionV3 mimarileri kullanılarak en az 2 mm genişliğe ve 4 cm uzunluğa sahip dikey ve yatay çatlakların doğru şekilde tespit edildiği rapor edilmiştir. Bu sistem, özellikle inşaat yapılarında detaylı çatlak analizi için umut vadeden sonuçlar sunmuştur [102].

Yang vd. yapısal çatlakların tespiti ve sınıflandırılması amacıyla özel bir veri seti oluşturmuş ve görüntüler üzerinde üç farklı sinir ağı mimarisi (AlexNet, VGGNet13 ve ResNet18) ile deneyler gerçekleştirmiştir. Test sonuçları, özellikle ResNet18 mimarisinin en başarılı sonuçları verdiğini ortaya koymuştur. Ek olarak, YOLOv3 modeli kullanılarak yapılan nesne tespiti uygulamalarında, çatlak bölgelerinin konumlarının oldukça yüksek doğrulukla belirlendiği gözlemlenmiştir [103].

Zeeshan vd. beton yüzeylerdeki çatlakların sınıflandırılmasına yönelik olarak VGG19 mimarisine dayalı bir transfer öğrenme yaklaşımı önermiştir. Modelin son iki konvolüsyonel bloğu ince ayar yapılarak optimize edilmiş ve son katman Softmax tabanlı iki sınıflı bir sınıflandırıcıyla değiştirilmiştir. Bu model, SDNET2018 veri

setinden seçilen çeşitli beton yüzey türleri (duvar, kaldırım, köprü) üzerinde test edilmiştir. Çalışma, transfer öğrenmenin çatlaklı ve çatlaksız görüntüleri yüksek doğrulukla ayırt etmede etkili olduğunu göstermektedir [104].

Jamshidi vd. çatlakları arka plan piksellerinden ayırt edebilen bir U-Net mimarisi üzerine odaklanarak, transfer öğrenme yaklaşımı geliştirmiştir. Bu amaçla, sentetik bir veri seti oluşturulmuş ve elde edilen veriler, genel veri kümeleriyle birleştirilerek CutMix veri artırımı uygulanmıştır. Ayrıca, beton yüzeylerdeki zamanla yayılan çatlakları takip edebilmek için zamansal veri birleştirme tekniği geliştirilmiş ve çoklu zaman adımlarına ait tahminlerin bütünleştirilmesiyle performans artışı sağlanmıştır. Uygulanan stratejiler, F1 skoru ve mIoU (mean Intersection over Union) değerlerinde sırasıyla %28,4 ve %22,2 oranında iyileşme sağlamıştır [37].

Qayyum vd. çatlak tespiti ve yön sınıflandırması amacıyla yedi farklı önceden eğitilmiş derin öğrenme mimarisini değerlendirmiştir: GoogLeNet, MobileNetV2, InceptionV3, ResNet18, ResNet50, ResNet101 ve ShuffleNet. Görüntüler, dört farklı sınıfa (dikey, yatay, diyagonal çatlak ve çatlaksız) ayrılmış ve her sınıf için dengeli örneklerle eğitim gerçekleştirilmiştir. Modellerin doğruluk oranları ve işlem süreleri karşılaştırılmış, sonuçlara göre InceptionV3 mimarisi en yüksek başarıyı göstermiştir. Bu analiz, çatlak tespiti ve yön tayini için uygun ESA mimarilerinin seçilmesine yönelik kıymetli içgörüler sunmaktadır [34].

Literatürdeki güncel çalışmalar incelendiğinde, derin öğrenme tabanlı mimarilerin çatlak segmentasyonu görevinde geleneksel yöntemlere kıyasla kayda değer performans üstünlüğü sağladığı görülmektedir. Ancak bu yöntemlerin yüksek doğruluk oranlarına rağmen, karmaşık görsel yapılar, düşük kontrastlı çatlak formları ve değişken morfolojik özellikler gibi zorluklarla karşı karşıya kalındığı da bilinmektedir. Literatürde sunulan birçok yaklaşımın, bu sınırlılıkların üstesinden gelmeyi amaçlayan mimari iyileştirmelere odaklandığı anlaşılmaktadır. Özellikle, derin ağ yapılarında özellik çıkarımında kilit rol oynayan kodlayıcı bloklardaki omurga mimarilerin başarımı üzerine yoğunlaşmıştır. Bu çalışmada, bilimsel arka plan doğrultusunda, yapı yüzeylerindeki çatlakların semantik düzeyde ayrıştırılması amacıyla, DeepLabV3+ mimarisi temel alınarak çeşitli kodlayıcı omurgaların

segmentasyon etkinliđi kapsamlı biçimde analiz edilmiştir. Optimum segmentasyon başarımını sağlayacak mimarinin belirlenebilmesi için, farklı morfolojik özelliklere ve çatlak yoğunluklarına sahip veri setleri tercih edilmiş; bu sayede mimarilerin genellenebilirlik ve güvenilirlik düzeyleri değerlendirilmiştir [38].

Ayrıca, kodlayıcı blokta yer alan omurga mimarilerin yalnızca semantik temsil üretme kapasiteleri değil, aynı zamanda segmentasyon sistemine yükledikleri parametre boyutları açısından da eğitilebilirlik verimlilikleri incelenmiştir. Alçak ve yüksek seviyeli özellik çıkarımının segmentasyon çıktıları üzerindeki etkisi, sayısal başarımlar aracılığıyla ortaya konmuş ve kapsamlı biçimde tartışılmıştır.

Modellerin başarımını nesnel ve istatistiksel olarak güvenilir şekilde ölçmek için 10 katlı çapraz doğrulama yöntemi uygulanmış olup, her bir segmentasyon adımında, eğitim, doğrulama ve test veri setleri birbirinden bağımsız olarak yapılandırılmış ve her bir katmandan elde edilen sonuçların ortalaması alınarak nihai değerlendirme gerçekleştirilmiştir.

Literatürde çatlak segmentasyonu alanında kullanılan modellerin performans değerlendirmesi Tablo 2.5’te verilmiştir.

Tablo 2.5 Çatlak Segmentasyonu Alanında Literatürde Önerilen Modellerin Performans Değerlendirmesi

Referans	Model	DSC	IoU	Doğruluk	Kesinlik	Duyarlılık
[34] Qayyum, W. at al. (2023)	GoogLeNet	0,817	0,691	0,912	0,827	0,852
	MobileNetV2	0,725	0,569	0,870	0,735	0,775
	InceptionV3	0,880	0,786	0,945	0,885	0,895
	ResNet18	0,727	0,571	0,870	0,742	0,805
	ResNet50	0,817	0,691	0,907	0,815	0,847
	ResNet101	0,875	0,778	0,940	0,877	0,887
	ShuffleNet	0,795	0,660	0,897	0,792	0,862
[37] Jamshidi, M. at al. (2023)	U-Net (Base model)	0,511	0,343	-	0,512	0,597
	U-Net + CutMix Fine-Tuning	0,585	0,413	-	0,605	0,572
	U-Net + CutMix + Temporal Data Fusion	0,656	0,488	-	0,778	0,612
[92] Ye, G. at al. (2023)	YOLOv7-AMF	-	-	0,941	0,913	0,871

Tablo 2.5 (Devam)

[93] Jenkins, M. D. at al. (2018)	U-Net	0,873	0,775	-	0,924	0,828
[94] Fan, Z. at al. (2020)	ESA	0,953	0,910	-	0,955	0,952
		0,923	0,857	-	0,930	0,916
[95] König, J. at al. (2019)	U-Net	0,949	0,903	-	0,963	0,935
		0,898	0,815	-	0,869	0,930
[96] Altun, M.G.,& Altun, A.H., (2024)	YOLOv8 100 Epoch	0,950	0,900	0,958	-	-
	YOLOv8 200 Epoch	0,950	0,900	0,959	-	-
	YOLOv8 300 Epoch	0,930	0,870	0,964	-	-
[97] Ali, L. at al. (2021)	Customized ESA	0,986	0,972	0,991	1,000	0,973
	VGG16	0,999	0,998	0,999	0,998	1,000
	VGG19	0,960	0,923	0,960	0,972	0,949
	ResNet50	0,996	0,992	0,995	0,993	0,998
	Inception V3	0,994	0,988	0,995	0,994	0,994
[98] Fang, F. at al. (2020)	Baseline	0,307	0,181	-	0,184	0,943
	Faster R-ESA w/VGG16	0,926	0,862	-	0,968	0,888
	Faster R-ESA w/ResNet-101	0,900	0,818	-	0,932	0,877
	YOLO_v3	0,723	0,566	-	0,783	0,672
	SSD (Mobilenet v2)	0,786	0,647	-	0,921	0,686
[99] Hadinata, P. N. at al. (2021)	U-Net	0,875	0,778	0,965	0,881	0,889
	DeepLabV3+	0,852	0,742	0,964	0,920	0,818
[100] Arafın, P. at al. (2022)	InceptionV3	-	-	0,910	0,830	1,00
	Xception	-	-	0,900	0,810	1,00
	MobileNetV2	-	-	0,840	0,700	1,00
	ResNet50	-	-	0,850	0,720	0,970
	VGG19	-	-	0,670	0,620	0,860
[101] İslam, M.M. at al. (2022)	VGG16	0,998	0,996	0,998	0,997	0,999
	ResNet18	0,993	0,986	0,993	0,989	0,997
	DenseNet16	0,996	0,992	0,996	0,995	0,998
	AlexNet	0,998	0,996	0,998	0,999	0,998
[102] Üncü, İ. S. at al. (2023)	VGG16	-	-	0,971	-	-
	InceptionV3	-	-	0,951	-	-
[103] Yang, C. at al. (2021)	AlexNet	0,976	0,953	0,976	0,979	0,973
	VGG13	0,983	0,966	0,983	0,986	0,980
	ResNet18	0,988	0,976	0,988	0,989	0,986
[104] Zeeshan M. at al. (2021)	VGG19	0,917	0,847	0,917	0,919	0,917

3. MALZEME VE YÖNTEM

Bu bölümde, afet sonrası yapı hasarının belirlenmesine yönelik geliştirilen derin öğrenme tabanlı yaklaşımların uygulanmasında kullanılan veri setleri, ön işleme adımları, model mimarileri, eğitim stratejileri ve değerlendirme metrikleri ayrıntılı olarak açıklanacaktır. Tez çalışması kapsamında hem betonarme yüzeylerdeki çatlakların semantik segmentasyonu hem de uydu ve drone görüntülerinden elde edilen bina hasar seviyelerinin segmentasyonu ve sınıflandırılması olmak üzere iki ana problem ele alınmıştır. Bu bağlamda, literatürde yaygın biçimde kullanılan DeepCrack ve CrackForest veri setleri çatlak segmentasyonunda kullanılmak üzere, ek olarak, Kahramanmaraş Depremi, Joplin Kasırgası ve xBD gibi yüksek çözünürlüklü görüntülerden oluşan veri kümeleri yapı hasar tespiti için değerlendirilmesinde kullanılmıştır.


Uygulanan yöntemler, evrişimsel sinir ağlarına dayalı DeepLabV3+ mimarisi üzerine inşa edilerek, farklı kodlayıcı (encoder) omurga yapılarının (MobileNetV2, Xception, ResNet-18, ResNet-50 ve Inception-ResNet) performansları karşılaştırmalı olarak analiz edilmiştir. Ayrıca, bina bazında hasar sınıflandırmasının sağlanabilmesi amacıyla, afet öncesi poligon verileri ile model çıktıları bütünleştirilerek nesne düzeyinde hasar tespiti gerçekleştirilmiştir.

Bu bölümde ayrıca, kullanılan hesaplama altyapısı, hiperparametre ayarları, eğitim ve doğrulama süreci ile performans değerlendirme ölçütleri (Intersection Over Union (IoU), Dice Similarity Coefficient (DSC), doğruluk oranı, kesinlik, duyarlılık vb.) detaylandırılmış, elde edilen çıktılar üzerinden yöntemlerin uygulanabilirliği, verimliliği ve genellenebilirliği teknik bir perspektiften değerlendirilmiştir.

3.1 Beton Yapılarda Çatlak Tespiti

Betonarme yapı yüzeylerindeki çatlakların piksel düzeyinde ayrıştırılmasına yönelik olarak genel semantik segmentasyon çerçevesi, Şekil 3.1’de şematik biçimde sunulmuştur. Bu kapsamda, özellik çıkarıcı olarak görev yapan omurga mimarilerinin segmentasyon başarımına olan etkilerini incelemek amacıyla yapılandırılan DeepLabV3+ tabanlı model mimarisi detaylandırılmıştır. Bölüm içerisinde ayrıca, kullanılan veri setlerinin nitelikleri ile birlikte, karşılaştırmalı analiz

kapsamında değerlendirilen ESA mimarileri (Inception-ResNet, MobileNetV2, ResNet-18, ResNet-50 ve Xception) ayrı ayrı incelenip açıklanmıştır.



Şekil 3.1 Önerilen genel segmentasyon çerçevesi [38]

3.1.1 Veri Seti

Bahsedilen modellerin performanslarını test etmek için erişime açık DeepCrack ve CrackForest veri setlerinden yararlanılmıştır. Bu veri setlerinin bağlantı adresleri sırasıyla [105, 106] numaralı kaynaklarda sunulmuştur. Veri setlerine ait örnek görüntüler ise Şekil 3.2’de görselleştirilmiştir [38].



(a)



(b)

Şekil 3.2 Her iki veri setine ait örnekler (a): DeepCrack, (b):CrackForest [38]

3.1.2 DeepCrack


DeepCrack, 384×544 piksel boyutlarında, toplamda 537 adet RGB formatında görüntüden oluşmaktadır [105]. Bu veri seti, asfalt ve beton gibi yüzeylerde meydana gelebilecek çatlakları içeren farklı ölçeklerdeki görüntülerle karakterize edilmiştir. Nispeten daha geniş hatlara sahip çatlaklar, uzmanlar tarafından işaretlenerek gerçeğe yakın referans segmentasyon haritaları oluşturulmuştur.

3.1.3 CrackForest

CrackForest veri seti ise 480×320 piksel çözünürlüğe sahip, toplam 118 yüzey görüntüsünden oluşmaktadır [106]. Çatlak içeren bu görüntüler için, alan uzmanlarınca hazırlanan gerçek referans segmentasyon haritaları mevcuttur. Tüm görüntüler RGB formatında olup, literatüre bu şekilde kazandırılmıştır.

3.1.4 Ağın Eğitimi

Çatlak sınıflandırma çalışmasında Özgenel'in çalışmasında sunulan etiketlenmiş veriler ile ağımızın eğitimi yapılmıştır [89]. Temel veri setinde 500 görüntüden elde edilen 40000 adet 224x224 piksellik duvar ve zemin resmi bulunmaktadır. Bu resimlerin 20000 adedinde çatlak bulunmakta (hasarlı), 20000 adedinde çatlak bulunmamaktadır (hasarsız). Şekil 3.3'te Özgenel'in sunmuş olduğu veri seti örnekleri gösterilmektedir.



Şekil 3.3 Özgenel Tarafından Sunulmuş Veri Setine Ait Örnekler [89]

3.1.5 DeepLabV3+


DeepLabV3+, semantik segmentasyon alanında yaygın olarak tercih edilen, kodlayıcı (encoder) ve kod çözücü (decoder) olarak adlandırılan iki ana bileşenden

oluşan derin öğrenme tabanlı bir mimaridir [80]. Bu yapı, özellikle görsel veriler üzerinde yüksek doğrulukla sınıflandırma ve nesne ayrımı yapılmasına olanak tanımaktadır. Mimari yapı itibarıyla, kodlayıcı modül; giriş görüntüsünden anlamlı özelliklerin hiyerarşik biçimde çıkarıldığı ve uzamsal boyutların kademeli olarak azaltıldığı bölüm olarak işlev görmektedir. Kod çözücü modül ise, kodlayıcıdan elde edilen düşük çözünürlüklü ancak semantik olarak zengin özellik haritalarının, orijinal görüntü boyutuna yakın bir çözünürlükte yeniden yapılandırılmasını sağlamaktadır [107].

DeepLabV3+ mimarisinde dikkat çeken önemli bir teknik tercih, kodlayıcı bölümünde klasik evrişimsel katmanlar yerine derinlemesine ayrılabilir (depthwise separable) evrişimlerin kullanılmasıdır. Bu yöntem, hem modelin hesaplama yükünü azaltmakta hem de uzamsal çözünürlüğü koruyarak detay kaybını en aza indirmektedir [108]. Bu özellik haritaları, farklı oranlarda atrous (delikli) evrişimler ile çalışan Atrous Spatial Pyramid Pooling (ASPP) modülü aracılığıyla birleştirilmekte ve böylece çok ölçekli bağlamsal bilgilerin entegrasyonu sağlanmaktadır. Elde edilen yüksek seviyeli özellikler, kod çözücü aşamada alçak seviyeli özellik haritaları ile birleştirilerek, yukarı örnekleme (upsampling) teknikleri yardımıyla segmentasyon çıktısı üretilmektedir.

DeepLabV3+ mimarisi, günümüzde yaygın olarak kullanılan diğer semantik segmentasyon modelleriyle karşılaştırıldığında bir dizi teknik ve performans açısından üstünlük sunmaktadır. Bu avantajlar, hem mimari tasarım tercihleri hem de elde edilen deneysel sonuçlar bakımından önemli farklar yaratmaktadır. Derinlemesine ayrılabilir evrişimlerle hesaplama verimliliği ile kodlayıcı bölümünde kullanılan derinlemesine ayrılabilir evrişim (depthwise separable convolution) katmanları, klasik evrişim katmanlarına kıyasla parametre sayısını ve hesaplama yükünü büyük oranda azaltmaktadır. Bu sayede DeepLabV3+, yüksek doğruluk sunarken, mobil ve gömülü sistemlerde kullanım için de daha uygun hale gelmektedir. Gelişmiş kod çözücü yapısı ile daha doğru segmentasyon sınırları, DeepLabV3+'un kod çözücü modülü, yüksek seviyeli semantik özelliklerle birlikte, kodlayıcıdan gelen düşük seviyeli detay bilgilerini de entegre ederek segmentasyon haritalarının daha keskin ve doğru sınırlarla üretilmesini sağlar. Esnek omurga

mimari uyumluluğu ile DeepLabV3+, farklı önceden eğitilmiş derin ağ mimarileri ile kolaylıkla entegre edilebilen esnek bir omurga mimari yapısına sahiptir. Bu durum, uygulamaya özel olarak modelin doğruluk ve hız kriterleri açısından optimize edilmesine olanak tanır. Buna karşılık, SegNet veya FCN gibi mimarilerde bu düzeyde bir omurga esnekliği sınırlıdır. Transfer öğrenmeye yüksek uyum ile DeepLabV3+ mimarisi, büyük ölçekli sınıflandırma görevlerinde eğitilmiş ağlardan transfer öğrenme ile yararlanmayı mümkün kılan bir yapıdadır. Bu, özellikle sınırlı veri içeren uygulamalarda daha hızlı ve başarılı eğitim süreçleri sağlar. Diğer mimarilerde bu entegrasyon her zaman kolay veya etkili olmayabilir. Sınırlı veriyle daha yüksek performansla, derinlemesine ayrılabilir evrişimlerin sağladığı parametre verimliliği ve ASPP ile sağlanan çok ölçekli bağlamsal analiz, DeepLabV3+'ı düşük veri rejimlerinde dahi güçlü bir aday haline getirir. Bu bağlamda, veri toplamının zor ve maliyetli olduğu uzaktan algılama gibi alanlarda, diğer modellere oranla daha iyi performans gösterebilir. Şekil 3.4'te DeepLabV3+ mimarisi gösterilmiştir.



Şekil 3.4 DeepLabV3+ Mimarisi

3.1.6 Kodlayıcı Modülü

DeepLabV3+ mimarisinin kodlayıcı modülü, yüksek düzeyde özellik çıkarımı sağlayan bir ESA mimarisi ile desteklenmektedir [29, 30]. ESA mimarileri, başlangıçta görüntü sınıflandırma amacıyla geliştirilmiş olsalar da, güçlü temsil öğrenimi kabiliyetleri sayesinde semantik segmentasyon gibi farklı görevlerde de başarıyla kullanılabilir. Ancak bu mimarilerin, özel bir probleme ait sınırlı örneklem büyüklüğüne sahip veri kümeleri üzerinde doğrudan eğitilmesi, genelleme

kapasitesini kısıtlayabilmektedir [41]. Bu durum, ağın semantik düzeyde ayırt edici bilgi çıkarım yetisini olumsuz etkileyerek segmentasyon başarımını düşürebilir.

Bu sınırlılıkların üstesinden gelinmesi amacıyla transfer öğrenme yöntemlerinden faydalanmak, literatürde yaygın bir yaklaşımdır. Bu bağlamda, önceden kapsamlı ve çeşitlilik arz eden veri kümeleri üzerinde eğitilmiş olan ESA mimarileri, segmentasyon görevine aktarılacak üzere kodlayıcı yapıya entegre edilmektedir. Özellikle ImageNet gibi büyük ölçekli sınıflandırma görevlerinde başarıyla eğitilmiş olan modellerin yeniden kullanılması, segmentasyon görevinde güçlü ve genelleştirilebilir semantik temsillerin elde edilmesini olanaklı kılmaktadır [109].

Her ne kadar DeepLabV3+ mimarisi, semantik segmentasyon alanında yüksek doğruluk değerleri sunması bakımından öne çıksa da, bu başarımın bir bedeli olarak artan hesaplama maliyeti dezavantaj oluşturmaktadır [29]. Ağın toplam işlem yükü ve bellekteki kaynak tüketimi, doğrudan doğruya kullanılan omurga mimarinin karmaşıklığıyla ilişkilidir. Bu nedenle, uygulamaya özel mimari seçimlerde, segmentasyon doğruluğu ile hesaplama verimliliği arasındaki denge dikkatle gözetilmelidir.

Bu çalışmada, yapılarda oluşan çatlakların segmentasyonuna yönelik olarak, kodlayıcı yapısında kullanılan çeşitli ESA mimarilerinin etkinlikleri analiz edilmiştir. Bu kapsamda, MobileNetv2, Inception-ResNet, ResNet ve Xception gibi derin öğrenme tabanlı mimarilerden yararlanılmıştır.

3.1.7 ResNet

ResNet (Residual Network), yüksek doğruluk oranlarıyla büyük ölçekli görüntü sınıflandırma problemlerinde başarılı sonuçlar sunan bir ESA mimarisidir. İlk olarak He vd. tarafından önerilen bu mimari, 2015 yılında düzenlenen ImageNet Büyük Ölçekli Görsel Tanıma Yarışması'nda (ILSVRC 2015) birincilik elde etmiştir [110]. ResNet, derin evrimsel ağlarda görülen gradyan sönmesi veya patlaması gibi sorunların önüne geçmek amacıyla geliştirilmiş ve bu doğrultuda 'atlamalı bağlantı' (skip connection) ya da 'artık blok' (residual block) yapıları tanıtılmıştır. Bu yapılar

sayesinde daha derin mimarilerin kararlı biçimde eğitilebilmesi mümkün hale gelmiştir.


Mimari, farklı derinliklere sahip varyantlar ile sunulmuş olup, katman sayılarına göre adlandırılan versiyonları (ResNet18, ResNet34, ResNet50, ResNet101 ve ResNet152) bulunmaktadır. Her ne kadar mimarinin farklı versiyonları bulunsada, genel yapısı itibarıyla beş temel evrişim bloğundan oluşmaktadır. Bu blokların her birinde, farklı sayıda evrişimsel katman yer almakta olup, ağırlıklı derinliği bu yapıya göre değişiklik göstermektedir. Bu çalışma kapsamında, model karmaşıklığı ve hesaplama maliyeti dengelenerek ResNet-18 ve ResNet-50 mimarileri tercih edilmiştir.

ResNet-18, toplamda 18 ağırlıklı katmana (convolutional + fully connected) sahip olan görece hafif bir mimaridir. Bu yapı, özellikle sınırlı kaynaklara sahip sistemlerde veya düşük çözünürlüklü veriler üzerinde eğitim yapılacak durumlarda tercih edilmektedir. ResNet-18 mimarisi toplamda 8 adet residual blok içerir. Her blok 2 konvolüsyon katmanından oluşur. Az katmanlı yapısı sayesinde daha hızlı eğitim sağlar. Eğitim süresi kısadır ve overfitting'e daha az eğilimlidir. Daha az derinlik nedeniyle, karmaşık görevlerde yeterli temsil öğrenimi sağlayamayabilir.


ResNet-50, toplamda 50 katmandan (48 evrişim katmanı ve 1 tam bağlı (fully connected)) oluşan ve daha karmaşık görevler için yüksek temsil gücüne sahip bir mimaridir. Derin yapısı sayesinde büyük ve çeşitli veri kümelerinde üstün başarı sağlar. ResNet-50 mimarisi toplamda 16 adet bottleneck residual blok içerir. Her blok 3 konvolüsyon katmanı içerir (1x1, 3x3, 1x1). Identity block, giriş ile çıkış boyutlarının eşit olduğu durumlarda kullanılan bir residual blok türüdür. Bu blokta, giriş doğrudan (skip connection) toplama işlemine katılır. Bu yapı sayesinde, ağırlık öğrenimi sırasında hata geri yayılımı (backpropagation) daha etkili şekilde gerçekleştirilir.

Bottleneck Tasarımı, daha derin mimarilerde hesaplama yükünü dengelemek için kullanılır. 1x1 evrişimlerle boyut küçültülür ve tekrar artırılır. İlk 1x1 evrişim, boyut indirgeme (channel reduction) amacıyla kullanılır. 3x3 evrişim, asıl öğrenme

işleminin yapıldığı çekirdek katmandır. Son 1×1 evrişim, kanal boyutunu tekrar artırarak girişle aynı hâle getirir. Bu üçlü yapı, hesaplama yükünü azaltmakta, ayrıca derin katmanlarda daha etkili özellik çıkarımı sağlamaktadır. Bottleneck blokları sayesinde, model derin ve hafif bir yapıya sahip olmaktadır. Yüksek doğruluk ve güçlü genelleme kabiliyeti sunar. Hesaplama maliyeti yüksektir, ayrıca eğitim süresi uzundur.



Şekil 3.5 ResNet50 Mimarisi



Şekil 3.6 ResNet18 Mimarisi

3.1.8 Xception


Xception modeli, Inception mimarisinden türetilmiş bir evrişimsel sinir ağıdır ve bu yapı, geleneksel evrişim operasyonları ile derinlemesine ayrılabilir evrişimlerin (depthwise separable convolutions) yeniden yapılandırılmasıyla oluşturulmuştur [111]. Şekil 3.7’de klasik bir Inception modülünün genel yapısı gösterilmektedir. Geleneksel Inception modülünde, giriş verisinin boyutunu düşürmek amacıyla 1×1 boyutundaki noktasal evrişim filtreleri (pointwise convolution) kullanılmaktadır. Xception mimarisinde ise bu yapı tersine çevrilmiş bir biçimde uygulanmıştır; yani önce pointwise evrişim gerçekleştirilmekte, ardından kanal başına ayrı ayrı uygulanan uzamsal evrişim adımı kaldırılmaktadır. Bu yapısal değişiklik sonucunda, giriş ve çıkış özellik haritaları arasında küçük ölçekli farklar oluşmakta; ancak bu modifikasyon sınıflandırma performansında belirgin bir artış sağlamaktadır.

Xception mimarisi, artık bağlantılar (residual connections) ile organize edilmiş toplam 36 evrişim katmanından meydana gelir. Bu katmanlar, ağıın temel özellik

çıkarmı işlemlerini gerçekleştiren yapıyı oluşturur. Ayrıca, her bir evrişimsel ve ayrılabilir evrişim katmanından sonra batch normalization işlemi uygulanmaktadır [112]. Gelişmiş özellik çıkarım kapasitesi sayesinde, Xception mimarisi, semantik segmentasyon görevlerinde kodlayıcı blok olarak kullanılması için güçlü bir omurga yapı (backbone) adayı haline gelmiştir.

Görüntü sınıflandırma ve semantik segmentasyon gibi görevlerde derin sinir ağlarının başarısı, yalnızca ağın derinliği değil, aynı zamanda verimli ve çok yönlü özellik çıkarımı yapabilen mimari yapılarla da ilişkilidir. Bu bağlamda geliştirilen Inception ve Xception mimarileri, çok ölçekli filtreleme ve hesaplama verimliliği açısından dikkat çeken iki önemli yaklaşımdır.

Inception, ilk olarak 2014 yılında Google tarafından ‘GoogLeNet (Inception v1)’ adıyla tanıtılmıştır [113]. Temel amacı, ağın derinliğini ve genişliğini artırırken, parametre sayısını denetim altında tutarak hesaplama verimliliğini sürdürmektir. Her Inception bloğunda farklı boyutlardaki evrişim filtreleri (1x1, 3x3, 5x5) aynı anda uygulanır. Böylece her katman, hem lokal hem de daha geniş bağlamsal bilgiyi paralel olarak çıkarır. Yüksek boyutlu girdiler 1x1 konvolüsyonlarla daraltılır. Bu, hesaplama maliyetini düşürür ve ağın daha derin yapılmasına olanak tanır. Ağ, ardışık Inception bloklarının birleştirilmesiyle oluşturulmuştur. Bu modüler yapı, farklı veri setleri ve görevler için kolayca uyarlanabilir. Düşük hesaplama maliyetiyle derin yapı elde edilebilir. Çok ölçekli bilgi çıkarımı ile genelleme kabiliyeti yüksektir. Parametre verimliliği sayesinde overfitting riski azaltılmıştır.



Şekil 3.7 Inception modülünün kanonik gösterimi [38]


Xception (Extreme Inception), 2017 yılında François Chollet tarafından önerilen ve Inception mimarisinin ‘doğrusal bir genişletmesi’ olarak tanımlanan gelişmiş bir modeldir [111]. Bu mimari, Inception felsefesini derinlemesine ayrılabilir evrişimlerle (depthwise separable convolutions) tamamen yeniden yapılandırır. Depthwise Separable Convolution, bu yapı, klasik evrişimlerin yerine kullanılarak her kanalda bağımsız evrişim uygulanır (depthwise), ardından kanallar arası birleşim (pointwise - 1×1 conv) gerçekleştirilir. Bu, klasik evrişime kıyasla daha az parametre ve işlem gerektirir. Xception, baştan sona tamamen derinlemesine ayrılabilir evrişimlerden oluşur ve az sayıda parametre ile daha yüksek doğruluk sağlar. Özellikle büyük ve çeşitli veri setlerinde etkili sonuçlar verir. Hesaplama açısından son derece verimli olup, yüksek çözünürlüklü görüntülerde bile hızlı sonuçlar verir. Derin öğrenme görevlerinde, özellikle transfer öğrenme ile kullanıldığında çok yüksek başarı sağlar. Inception’a göre daha sade ama daha etkili bir mimari sunar.

Inception mimarisi çok ölçekli özellik çıkarmada başarılı bir yapı sunarken, Xception bu prensibi optimize ederek daha yüksek verimlilik ve doğruluk sunan modern bir yaklaşım olarak dikkat çekmektedir. Derin mimarilere dayalı segmentasyon görevlerinde Xception, özellikle DeepLabV3+ gibi çerçevelerde, hesaplama verimliliği ve güçlü temsil öğrenimi nedeniyle sıklıkla tercih edilmektedir.

3.1.9 MobileNet

MobileNet mimarisi, kaynak açısından sınırlı olan mobil ve gömülü sistemlerde kullanılmak üzere görsel uygulamalar için Howard vd. tarafından geliştirilmiştir [114]. Bu mimaride temel amaç, sınıflandırma görevlerinde doğruluk performansı ve işlem süresi arasında dengeli ve verimli bir yapı oluşturmaktır. MobileNet, temel olarak Inception mimarisiyle literatüre giren derinlemesine ayrılabilir evrişim prensibine dayanmaktadır. Bu yaklaşımda, geleneksel evrişim işlemi iki ayrı aşamaya bölünmüştür; 1×1 boyutunda uygulanan noktasal evrişim ve derinlemesine evrişim. Derinlemesine evrişim, her bir kanal için tekil bir filtre uygulanarak gerçekleştirilirken; noktasal evrişim, bu kanallardan elde edilen çıktıları bütünleştirmek amacıyla uygulanmaktadır. Her evrişim katmanı sonrasında batch normalization ve ReLU aktivasyon işlevleri devreye sokularak ağırların kararlılığı artırılmıştır.

Verimli işlem yapısı sayesinde MobileNet, sınıflandırma doğruluğundan büyük ölçüde ödün vermeden, yüksek hızda işlem gerçekleştirebilmektedir. Bu çalışmada, kodlayıcı bloklarda transfer öğrenme yaklaşımının etkinliğini değerlendirmek amacıyla MobileNet mimarisinin güncellenmiş versiyonu olan MobileNetv2 tercih edilmiştir [115]. MobileNetv2’de, evrişimsel yapı üzerinde bazı yapısal iyileştirmeler gerçekleştirilmiştir. Özellikle ilk katmanda, ReLU aktivasyon fonksiyonu ile birlikte 1×1 boyutunda evrişim uygulanmakta; bunu takip eden ikinci katmanda ise derinlemesine evrişim gerçekleştirilmektedir.



Şekil 3.8 MobileNetV2 evrişimsel blokları [115]

Son aşamada, noktasal evrişim herhangi bir aktivasyon işlemi olmadan doğrudan uygulanmaktadır. Ayrıca, ResNet mimarisinden esinlenerek tasarlanan yeni artık bağlantı yapıları sayesinde, daha derin ağların yüksek doğruluk ve düşük hesaplama maliyeti ile eğitilebilmesi mümkün hale gelmiştir. Şekil 3.8’de, genel bir MobileNetV2 evrişimsel bloklarının yapısal görünümü sunulmaktadır.

3.1.10 Inception-ResNet

Inception-ResNet modeli, günümüzde derin öğrenme alanında yaygın biçimde kullanılan artık bağlantılar ile Inception mimarisinin birleştirilmesi fikri temel alınarak geliştirilmiştir [116]. Artık bağlantılar, derin sinir ağlarının daha verimli şekilde eğitilmesini mümkün kılan önemli bir yapı sunmaktadır [117]. Inception mimarisinin gelişmiş bir modeli olan Inception-v3’ün yüksek derinliğe sahip yapısı,


bu mimaride filtre birleştirme süreçlerinin artık bağlantılarla değiştirilmesi fikrini ortaya çıkarmıştır.

Şekil 3.9 Inception-ResNet-v2 modeli/bloğu [38]

Önerilen model kapsamında, Inception mimarisine artık bağlantıların entegre edilmesiyle eğitim süresi ve modelin genel performansında anlamlı iyileşmeler gözlemlenmiştir. ILSVRC 2012 veri seti üzerinde yapılan testlerde, ResNet ve Inception-v3 mimarilerinin sunduğu sınıflandırma başarımı aşılmış ve daha yüksek performanslar sağlanmıştır. Bu çalışmada, bahse konu iki güçlü mimarinin birleşiminden oluşan Inception-ResNet-v2 yapısının, segmentasyon görevlerindeki özellik çıkarım kapasitesi değerlendirilmiştir.

Omurga mimarilerde standart evrişim katmanlarına bir alternatif olarak kullanılan genişletilmiş (atrous) evrişim, modelin parametre sayısını artırmaksızın daha geniş alıcı alanlara (receptive field) ulaşabilmesine olanak tanımaktadır [108]. Bu yöntem

sayesinde, aynı görüntü üzerinden farklı ölçeklerde özelliklerin eş zamanlı olarak çıkarılması sağlanmakta ve çok ölçekli bağlamsal bilgilere erişim mümkün olmaktadır [80]. Şekil 3.10'da, atrous evrişim kullanımıyla uzamsal çözünürlüğün nasıl korunduğu görsel olarak sunulmaktadır.



Şekil 3.10 Genişletilmiş evrişim ile uzamsal çözünürlüğün korunması [38]

Küçük boyutlu özellik haritaları sınıflandırma gibi görevlerde yeterli olurken, semantik segmentasyon gibi uzamsal hassasiyet gerektiren görevlerde daha büyük boyutlu haritaların kullanılması gerekmektedir [107]. Bu nedenle, atrous evrişim operatörlerinin kullanımı, kodlayıcı aşamasında üretilen özellik haritalarının uzamsal ayrıntılarını korumak açısından kritik öneme sahiptir.

3.1.12 Kod Çözücü Modül

Kod çözücü modül, ham görüntülerden çıkarılan ve çıkış oranı (output stride) genellikle 16:1 olacak şekilde elde edilen semantik özellikleri kullanarak, giriş boyutlarına yakın çözünürlükte segmentasyon haritaları üretir. Kodlayıcı tarafından sağlanan bu özellik haritalarının çözünürlüğü, genişletilmiş evrişim gibi yöntemlerle denetlenebilmekle birlikte, çoğu uygulamada çıkış oranı sabit olarak 16 seçilmektedir [80]. Bu yapı sayesinde, detay kaybı minimize edilirken, daha doğru segmentasyon çıktıları elde edilebilmektedir.

Önerilen kod çözücü modül, segmentasyon çıktısının giriş görüntüsüyle benzer çözünürlükte elde edilmesini hedefleyen çok katmanlı bir tasarıma sahiptir. İlk adımda, kodlayıcıdan gelen yüksek seviyeli özellik haritaları, faktör 4 oranında çift doğrusal (bilinear) enterpolasyon yöntemiyle yukarı örneklenmektedir. Ardından, omurga mimari olarak kullanılan ön eğitilmiş ESA modelinden elde edilen düşük

seviyeli özelliklerle birleştirme işlemi gerçekleştirilir. Bu entegrasyonun doğru ve tutarlı bir şekilde gerçekleştirilebilmesi için, her iki özellik haritasının da aynı uzamsal çözünürlüğe sahip olması gereklidir. Düşük seviyeli özelliklerin genellikle yüksek kanal boyutuna sahip olması nedeniyle, bu boyutun azaltılması için 1×1 evrişim uygulanarak kanallar sadeleştirilir. Son aşamada, birleştirilen özellik haritaları birden fazla 3×3 boyutlarında evrişim filtresi ile işlenir ve nihayetinde yukarı örneklenerek segmentasyon haritası üretilir. Bu süreç, segmentasyonun hem uzamsal hem de anlamsal doğruluğunu artırmayı amaçlamaktadır.

3.1.13 Model Başarım Metrikleri

Semantik segmentasyon uygulamalarında, sınıflar arasında genellikle ciddi bir dengesizlik gözlemlenmektedir. Özellikle ilgi alanı olarak tanımlanan nesne ya da bölgeler, çoğu zaman arka planla karşılaştırıldığında oldukça az sayıda piksel tarafından temsil edilmektedir. Bu durum, model başarımını değerlendirirken güvenilir ve genelleştirici sonuçlar elde edilmesini zorlaştırabilir.

Bu nedenle, literatürde yaygın şekilde kabul görmüş olan değerlendirme metriklerinin kullanımı önem arz etmektedir. Bu kapsamda, çalışmada IoU ve DSC metrikleri temel değerlendirme ölçütleri olarak tercih edilmiştir.

IoU, model tarafından tahmin edilen segmentasyon haritası ile gerçek etiketlerin (ground-truth) kesişim ve birleşim kümelerine dayanarak hesaplanmaktadır. Bu metriğin değeri $[0, 1]$ aralığında tanımlanmakta olup, değerin 1'e yaklaşması modelin daha yüksek doğrulukta segmentasyon yaptığına işaret eder. IoU metriği, segmentasyon doğruluğunu özellikle alan kapsamı ve sınır hassasiyeti gibi yönlerden detaylı biçimde değerlendirme yetisine sahiptir. Bununla birlikte, küçük nesnelerin segmentasyonu söz konusu olduğunda, ufak pozisyonel hatalar bile metriğin değerini belirgin biçimde düşürebilmektedir. Bu tür düşüşlerin altında yatan olası nedenler; modelin nesne sınırlarını yeterince doğru tespit edememesi, veri dengesizliği, sınırlı eğitim örnekleri ya da aşırı (over-segmentation) ya da yetersiz (under-segmentation) segmentasyon gibi yapısal problemler olabilir.

DSC ise, tahmin edilen ve gerçek piksellerin kesişiminin iki katının, toplam piksel sayısına oranı olarak tanımlanır [118]. Değer aralığı IoU ile benzer şekilde [0, 1] olup, 1'e yaklaşan değerler tahmin edilen segmentasyonun referans veriye daha fazla benzerlik gösterdiğini ifade eder. DSC, IoU'ya kıyasla daha toleranslı bir yapı sergiler; özellikle küçük nesnelerin segmentasyonu söz konusu olduğunda daha yüksek başarı skorları üretebilir. Bu metrik, ikili sınıflandırma problemlerinde duyarlılık (recall) ile kesinlik (precision) arasında dengeli bir ölçüt sunar. Ayrıca, sınıf dengesizliğinin belirgin olduğu durumlarda IoU'ya kıyasla daha duyarlı sonuçlar sağlaması bakımından avantajlıdır. Küçük yapılar üzerindeki tahmin performansını değerlendirirken daha açıklayıcı bir değerlendirme sunabilir.

Bunlara ek olarak, bu çalışmada segmentasyon ve sınıflandırma problemlerinin kapsamlı analizini yapabilmek amacıyla duyarlılık, doğruluk (accuracy) ve kesinlik gibi tamamlayıcı başarı ölçütlerinden de faydalanılmıştır. Aşağıda, kullanılan tüm model değerlendirme metriklerine ait matematiksel ifadeler sunulmuştur [38].

$$DSC = \frac{2 \times TP}{2 \times TP + FP + FN} \quad (3.1)$$


$$IoU = \frac{TP}{TP + FP + FN} \quad (3.2)$$

$$Duyarlılık = \frac{TP}{TP + FN} \quad (3.3)$$

$$Kesinlik = \frac{TP}{TP + FP} \quad (3.4)$$

$$Doğruluk = \frac{TP + TN}{TP + FP + TN + FN} \quad (3.5)$$

Değerlendirme metrikleri TP (Doğru Pozitif), FP (Yanlış Pozitif), TN (Doğru Negatif) ve FN (Yanlış Negatif) sayılarının dağılımına göre hesaplanmaktadır.



Şekil 3.11 10-katlı çapraz-doğrulama işlemi [38]

Şekil 3.11’de 10 katlı çapraz doğrulama uygulaması gösterilmektedir. Şekil 3.11’de sunulan veri dağılım metodolojisi her iki veri seti için de uygulanmıştır.

3.2 Uydu ve Drone Görüntüleri Kullanılarak Hasar Tespiti

Bu çalışma, Kahramanmaraş depremi sonrasında afet bölgesinde elde edilen uydu ve drone görüntüleri üzerinde gerçekleştirilen semantik segmentasyon işlemlerine yönelik çeşitli derin öğrenme mimarilerinin karşılaştırmalı analizini sunmaktadır. Çalışmada ayrıca, kamuya açık bir hava görüntüsü veri kümesi kullanılarak bina bazlı hasar tespitine yönelik segmentasyon tabanlı bir sınıflandırma yöntemi önerilmektedir. Bu bölümde, kullanılan yeni drone ve uydu görüntüsü veri setlerine ilişkin detaylı bilgiler, deneysel tasarım süreci, segmentasyon ve sınıflandırma performans sonuçları ile yöntemlerin hesaplama karmaşıklığına dair kapsamlı analizler ayrıntılı biçimde sunulmaktadır.

3.2.1 Kahramanmaraş Veri Seti

Kahramanmaraş veri seti, afet sonrası hasar değerlendirmelerine yönelik olarak T.C. Çevre, Şehircilik ve İklim Değişikliği Bakanlığı ve T.C. Milli Savunma Bakanlığı Harita Genel Müdürlüğü tarafından sağlanan güncel uydu ve drone tabanlı hava görüntülerinden oluşturulmuştur [119, 120].



Şekil 3.12 Kahramanmaraş Veri Seti Alanları

Veri seti, depremden etkilenen toplam on bir ilden Şekil 3.12’de belirtilen beşine ait (Kahramanmaraş, Hatay, Gaziantep, Adıyaman ve Malatya) hava fotoğraflarından sayısal arazi modeliyle üretilmiş 08.02.2023 tarihli 30 cm mekânsal çözünürlüğe sahip, Geography-WGS84 referans sistemine bağlı ve ECW formatında ortofoto görüntüler içermektedir.


Bu ortofotolar, 8 bit radyometrik çözünürlüğe ve standart RGB bant dizilimine sahiptir. Farklı çözünürlüklerde elde edilen toplam 305 adet hava görüntüsü, yeni bir veri kümesi oluşturmak amacıyla derlenmiştir.

Görüntü çözünürlükleri, satır (yükseklik) sayısı için ortalama 588 ± 228 piksel ve sütun (genişlik) sayısı için ortalama 759 ± 438 piksel olarak değişmektedir. Farklı boyutlardaki bu görüntüler, belirli bir standart sağlamak ve ön eğitilmiş omurga mimarilerine uyumlu hale getirmek amacıyla 512×512 piksel boyutuna yeniden ölçeklendirilmiştir.


Bina hasar tespitine yönelik görüntüler için zemin gerçeği açıklamaları (ground truth) sağlanmıştır. Tez çalışması kapsamında etiketleme işlemi, her bir pikselin üç ana sınıfa göre sınıflandırılması şeklinde gerçekleştirilmiştir: Arka Plan (bina

içermeyen alanlar), Hasarsız (görünür yapısal hasarı olmayan binalar) ve Yıkılmış (kısmen ya da tamamen çökmüş yapılar).


1/25000 ölçekte hazırlanmış görüntüler kullanılmıştır. ITRF-96-36 dilim 3 derece koordinat sistemindedir. Adıyaman merkez için ITRF-96-39 dilim 3 derece koordinat sistemi kullanılmıştır. Global mapper pro programında gönderilen ecw raster verileri ITRF-96 koordinat sistemine çevrilerek daha kullanılabilir hale getirilmiştir. Netcad 5.2 programında 1/25000 ölçekli karelay ve koordinat işlemleri yapılmış ve şekil 3.13'teki gibi çıktı haline getirilmiştir.




Şekil 3.13 Kahramanmaraş Veri Seti Alanları Ortofoto Görüntüleri (a) Adıyaman Merkez (b) Kahramanmaraş Elbistan (c) Kahramanmaraş Merkez (d) Gaziantep Nurdağı (e) Gaziantep İslahiye (f) Hatay Kırıkhan (g) Hatay Merkez



(e) Gaziantep İslahiye



(f) Hatay Kırıkhan




(g) Hatay Merkez


Şekil 3.13 (Devam)

3.2.2 xBD Veri Seti

xBD veri kümesi, uzaktan algılama alanında bina segmentasyonu ve hasar değerlendirmesi amacıyla yaygın olarak kullanılan, büyük ölçekli ve karşılaştırmalı bir optik uydu görüntü arşividir [121, 122]. Veri seti, depremler, orman yangınları, tsunamiler ve seller gibi çeşitli doğal afetlerin öncesi ve sonrasına ait VHR uydu görüntülerini içermektedir. Toplamda 22.068 adet $1024 \times 1024 \times 3$ boyutlarında RGB görüntüden oluşan bu küme, 11.034 olay öncesi ve sonrası görüntü çifti içermekte olup, farklı uydu platformlarından elde edilen verilerle oluşturulmuştur. xBD, düşük ve yüksek yoğunluklu kentsel bölgelerin yanı sıra kırsal alanları da kapsayan geniş bir mekânsal çeşitlilik sergilemekte ve dünya genelindeki farklı coğrafi bölgelerden toplanmış toplam 850.736 bina poligonunu bünyesinde barındırmaktadır.



(a) Joplin Kasırgası Veri Seti Örnekleri




(b) Kahramanmaraş Merkezli Depremler Veri Seti Örnekleri

Şekil 3.14 Her bir veri setinden örnek görüntüler ve yer-gerçek ek açıklamaları. (a) Joplin Kasırgası (b) Kahramanmaraş Merkezli Depremler Örnekleri. Ground-truth haritalarında siyah renk arka plan sınıfını, yeşil renk hasarsız sınıfı, kırmızı renk ise yıkılmış sınıfı temsil etmektedir.

Bu çalışmada, omurga mimarilerinin afet sonrası senaryolardaki dayanıklılığını analiz etmek ve bina düzeyindeki tahmin modellerinin uygulanabilirliğini değerlendirmek amacıyla, xBD veri kümesinden 22 Mayıs 2011 tarihinde gerçekleşen Joplin kasırgasına ait örnekler kullanılmıştır. Bu alt küme, afet öncesi ve sonrasına ait toplam 149 görüntü çiftinden oluşmaktadır. Olay sonrası görüntüler, modellerin afet koşullarındaki performansını analiz etmek için değerlendirilmiş; olay öncesi ve sonrası görüntülerin birlikte kullanımı ise bina bazlı hasar tahmini

görevlerinde temel veri kaynağı olarak kullanılmıştır. Şekil 3.14'te, her iki veri setinden elde edilen örnek drone ve uydu görüntülerine yer verilmiştir.

Segmentasyon görevlerinde sınıflar arasındaki piksel dağılımındaki dengesizlik, modelin performansını doğrudan belirleyen önemli bir unsurdur. Özellikle, daha fazla piksel ile temsil edilen sınıfların, öğrenme sürecinde daha baskın hale gelmesi nedeniyle daha başarılı segmentasyon sonuçları üretme olasılığı artmaktadır. Bu nedenle, her iki veri kümesinde segmentasyon performanslarının karşılaştırmalı olarak değerlendirilebilmesi için, sınıflar arasındaki piksel oranlarının analiz edilmesi kritik önem taşımaktadır. Şekil 3.15, arka plan, hasarsız ve yıkılmış bina sınıflarının her iki veri kümesinde sahip olduğu piksel sayılarına dayalı yüzde dağılımlarını sunarak bu dengesizliği nicel olarak ortaya koymaktadır.



Şekil 3.15 Arka plan, hasarsız ve tahrip edilmiş sınıfların piksel sayılarına göre yüzde dağılımı

3.2.3 Ağın Eğitimi ve Test Edilmesi

3.2.3.1 Çatlak Segmentasyonu

Önerilen segmentasyon modellerine ilişkin tüm deneysel çalışmalar, MATLAB (MathWorks, Natick, Massachusetts) programlama platformu kullanılarak gerçekleştirilmiştir. Deneyler, Intel i7 2.70 GHz işlemciye, 8 GB NVIDIA GeForce RTX grafik işlem birimine (GPU) ve 16 GB RAM donanım kapasitesine sahip bir bilgisayar ortamında yürütülmüştür. Çalışmada kullanılan farklı omurga mimarilerine sahip segmentasyon yapıları, uçtan uca (end-to-end) ve birbirinden bağımsız olarak eğitilmiştir.

Model eğitimi ve değerlendirme süreçlerinde veri kümesi, genel geçer bir uygulama olarak %80 eğitim, %10 doğrulama ve %10 test olacak şekilde üç alt kümeye ayrılmıştır. Segmentasyon modellerinin genel performansını daha güvenilir ve genelleştirici şekilde değerlendirebilmek amacıyla 10 katlı çapraz doğrulama yöntemi tercih edilmiştir. Her bir doğrulama katında eğitim, doğrulama ve test verileri birbirinden farklı olacak biçimde yapılandırılmış; her katmanda elde edilen değerlendirme sonuçlarının ortalaması alınarak nihai başarı ölçütleri belirlenmiştir.

3.2.3.2 Uydu ve Drone Görüntüleri

Bu çalışmadaki tüm deneysel analizler, NVIDIA RTX serisi GPU ile donatılmış Windows tabanlı bir sistem üzerinde yürütülmüştür. Drone ve uydu görüntülerine yönelik ön işleme adımları ile birlikte, sematik segmentasyon ve bina düzeyinde sınıflandırma işlemleri MATLAB 2022a yazılım ortamında gerçekleştirilmiştir. Model eğitimi sürecinde, farklı omurga mimarilerine ait derin ağların hiperparametreleri deneysel gözlemler doğrultusunda sezgisel olarak yapılandırılmıştır. Optimizasyon işlemleri için başlangıç öğrenme oranı 0,001 olarak belirlenen Adam algoritması kullanılmış; mini yığın (mini-batch) boyutu 4 olarak seçilmiş ve eğitim süreci 10 epok ile sınırlandırılmıştır. Aşırı öğrenme (overfitting) riskini azaltmak amacıyla erken durdurma (early stopping) mekanizması devreye alınmıştır.

Bu tez çalışmasında önerilen semantik segmentasyon mimarilerinin eğitim sürecinde aşırı uyumlamayı önlemek amacıyla öğrenme sabrı (ValidationPatience) parametresi 5 olarak belirlenmiştir. Eğitim sırasında doğrulama kaybı (validation loss), her 2 iterasyonda bir (VerboseFrequency = 2) izlenmiş ve ardışık 5 değerlendirme periyodu süresince iyileşme gözlenmemesi durumunda eğitim süreci erken durdurulmuştur. Bu yöntemle, modelin eğitim verisine aşırı uyum sağlayarak doğrulama verisi üzerindeki genelleme performansının düşmesi engellenmeye çalışılmıştır.

4. BULGULAR VE TARTIŞMA

4.1 Çatlak Segmentasyonu Sonuçları

Bu bölümde, çeşitli ESA modellerinin omurga mimarisi olarak entegre edildiği DeepLabV3+ yapılarının, iki farklı açık erişimli veri kümesi üzerinde gerçekleştirdiği segmentasyon performansları analiz edilmiştir.

Tablo 4.1’de, beş farklı önceden eğitilmiş mimari kullanılarak gerçekleştirilen 10 katlı çapraz doğrulama süreci sonucunda elde edilen ortalama segmentasyon başarımları; DSC, IoU, doğruluk, duyarlılık ve kesinlik ölçütleri açısından karşılaştırmalı olarak verilmiştir.

Tablo 4.1 DeepCrack veri setine ilişkin segmentasyon sonuçları [38]

Yöntem	Sınıf	DSC		IoU		Doğruluk		Duyarlılık		Kesinlik	
		μ	σ	μ	σ	μ	σ	μ	σ	μ	σ
DeepL.& Resnet-18	Çatlak	0.586	0.145	0.428	0.148	0.961	0.023	0.446	0.170	0.949	0.048
	Arkaplan	0.979	0.013	0.960	0.240	0.961	0.023	0.998	0.002	0.962	0.025
DeepL.& Resnet-50	Çatlak	0.625	0.116	0.464	0.122	0.968	0.012	0.475	0.131	0.963	0.023
	Arkaplan	0.983	0.006	0.967	0.012	0.968	0.012	0.998	0.001	0.969	0.013
DeepL.& MobileNetV2	Çatlak	0.631	0.093	0.467	0.098	0.970	0.010	0.487	0.115	0.933	0.047
	Arkaplan	0.985	0.005	0.967	0.011	0.970	0.010	0.996	0.002	0.972	0.009
DeepL.& Xception	Çatlak	0.586	0.147	0.428	0.143	0.962	0.021	0.446	0.160	0.936	0.047
	Arkaplan	0.980	0.011	0.961	0.021	0.962	0.021	0.997	0.002	0.963	0.022
DeepL.& Inception- Resnet	Çatlak	0.482	0.097	0.322	0.080	0.929	0.081	0.330	0.085	0.938	0.050
	Arkaplan	0.959	0.052	0.926	0.086	0.929	0.081	0.998	0.001	0.928	0.086

Burada DeepL=DeeplabV3+, μ ortalama değeri ve σ standart sapmayı temsil etmektedir.

Farklı omurga mimarilerine sahip segmentasyon modellerinin performans değerlendirmeleri, çatlak ve arka plan sınıfları için ayrı ayrı gerçekleştirilmiştir. Genel bulgular, önerilen tüm modellerin ham görüntülerde arka planı yüksek doğrulukla ayırt edebildiğini göstermektedir. Arka plan sınıfı için en başarılı segmentasyon performansı, MobileNetV2 omurga mimarisine sahip DeepLabV3+ çerçevesi tarafından sunulmuştur. DSC, IoU ve doğruluk değerleri bu mimari ile sırasıyla %98.5, %96.7 ve %97 olarak elde edilmiştir. Öte yandan, arka plan segmentasyonunda en düşük başarı ise Inception-ResNet mimarisiyle sağlanan

model tarafından gösterilmiş olup, ilgili metrikler sırasıyla %95.9 (DSC), %92.6 (IoU) ve %92.9 (doğruluk) düzeyinde kalmıştır.

Çatlak sınıfı segmentasyonunda ise arka plan sınıfına kıyasla genel olarak daha düşük başarımlar elde edilmiştir. Bu sınıfta en yüksek segmentasyon performansı yine MobileNetV2 omurga mimarisine sahip model tarafından sağlanmış olup, DSC, IoU ve doğruluk oranları %63.1, %46.7 ve %97 olmak üzere sırasıyla kaydedilmiştir. Bu başarıma en yakın sonuç, ResNet-50 tabanlı model tarafından sunulmuş ve sırasıyla %62.5 (DSC), %46.4 (IoU) ve %96.8 (doğruluk) oranlarında performans düzeyine ulaşılmıştır. En düşük başarı ise Inception-ResNet mimarisi ile çalışan modelde gözlemlenmiş; bu modelin ilgili metrik değerleri %48.2 (DSC), %32.2 (IoU) ve %92.9 (doğruluk) olarak raporlanmıştır. Bu bulgular, Tablo 4.1’de DeepCrack veri seti üzerinde elde edilen segmentasyon performanslarını göstermektedir.

Tablo 4.2 CrackForest veri setine ilişkin segmentasyon başarımları [38]


Yöntem	Sınıf	DSC		IoU		Doğruluk		Duyarlılık		Kesinlik	
		μ	σ	μ	σ	μ	σ	μ	σ	μ	σ
DeepL. & Resnet-18	Çatlak	0.399	0.047	0.250	0.036	0.952	0.018	0.280	0.057	0.773	0.167
	Arkaplan	0.975	0.010	0.952	0.019	0.952	0.018	0.992	0.012	0.959	0.013
DeepL. & Resnet-50	Çatlak	0.410	0.057	0.259	0.046	0.953	0.021	0.284	0.053	0.787	0.159
	Arkaplan	0.975	0.011	0.952	0.021	0.953	0.021	0.992	0.012	0.958	0.014
DeepL. & MobileNetV2	Çatlak	0.419	0.044	0.266	0.036	0.958	0.013	0.312	0.089	0.750	0.173
	Arkaplan	0.978	0.007	0.958	0.014	0.958	0.013	0.991	0.013	0.966	0.011
DeepL. & Xception	Çatlak	0.406	0.073	0.257	0.059	0.953	0.019	0.291	0.081	0.780	0.169
	Arkaplan	0.975	0.010	0.952	0.019	0.953	0.019	0.992	0.014	0.959	0.016
DeepL. & Inception-Resnet	Çatlak	0.361	0.094	0.226	0.067	0.929	0.046	0.237	0.071	0.859	0.106
	Arkaplan	0.961	0.265	0.927	0.047	0.929	0.046	0.995	0.005	0.931	0.046

Tablo 4.2 incelendiğinde, CrackForest veri seti kullanılarak elde edilen segmentasyon başarımları, genel olarak DeepCrack veri setine kıyasla daha düşük düzeyde seyretmiştir. Ancak en yüksek performansı sunan omurga mimariler açısından veri setleri arasında benzerlik gözlemlenmiştir. MobileNetV2 mimarisine sahip model, CrackForest veri seti üzerinde de en başarılı sonuçları üretmiş olup,

arka plan sınıfı için elde edilen metrik değerler sırasıyla DSC, IoU ve doğruluk açısından %97.8, %95.8 ve %95.8 olarak belirlenmiştir. Beton yüzey görüntülerinde arka plan sınıfı, geniş piksel dağılımı nedeniyle yüksek doğrulukla segmentlenebilirken, daha düşük piksel ile gösterilen çatlak sınıfı için segmentasyon performansı sınırlı kalmıştır. Buna rağmen en yüksek çatlak segmentasyon başarımı %41.9 DSC değeri ile MobileNetV2 tarafından elde edilmiş, en düşük performans ise %36.1 DSC değeriyle Inception-ResNet mimarisine sahip model tarafından sunulmuştur.


Farklı segmentasyon mimarilerinin öğrenme süreçlerini değerlendirmek ve karşılaştırmak amacıyla, eğitim sürecinde elde edilen doğruluk ve kayıp eğrilerinin zamansal değişimi incelenmiştir. Bu analiz, açıklamalı (etiketlenmiş) çatlak alanları ile modellerin tahmin ettiği segmentasyon çıktıları arasındaki benzerlik düzeyinin dolaylı bir göstergesi olarak değerlendirilmiştir. Özellikle eğitim kaybı eğrileri, modelin eğitim verisini ne ölçüde öğrenebildiğini ortaya koyması bakımından önemli bir performans göstergesi niteliğindedir [12]. Şekil 4.1’de, DeepCrack veri seti kullanılarak gerçekleştirilen 10 katlı çapraz doğrulama kapsamında, farklı omurga mimarilerine sahip modellerin öğrenme dinamiklerini temsil eden eğitim doğruluğu ve kaybı eğrilerine yer verilmiştir.

Şekil 4.1 incelendiğinde, tüm segmentasyon mimarilerinin öğrenme süreci ilk 50 iterasyon içerisinde büyük ölçüde tamamlanmıştır. Bu süreçte, özellikle kayıp eğrilerinde gözlemlenen dalgalanmaların 50. iterasyon sonrasında belirgin biçimde azalması, modellerin öğrenme aşamasında son uyarlamaları gerçekleştirdiğine işaret etmektedir. MobileNetV2, ResNet-18 ve ResNet-50 omurga mimarilerine sahip DeepLabV3+ yapılarının, diğer mimarilere kıyasla eğitim kaybını daha hızlı bir şekilde minimum seviyeye indirdiği rapor edilmiştir. Buna karşılık, Xception ve Inception-ResNet mimarilerinde, öğrenme sürecinin erken aşamalarında aşırı uyumlama belirtileri gözlemlenmiş ve bu durumun çok katmanlı yapılar nedeniyle öğrenmenin erken sonlanmasına yol açtığı anlaşılmıştır.




Şekil 4.1 DeepCrack veri seri ilişkin eğitim ve kayıp fonksiyonları, (a) ResNet-18, (b) ResNet-50, (c) MobileNetV2, (d) Xception ve (e) Inception-ResNet [38]

Şekil 4.2’de, CrackForest veri seti kullanılarak gerçekleştirilen 10 katlı çapraz doğrulama süreci sonucunda, farklı omurga mimarilerine sahip modellerin öğrenme eğilimlerini temsil eden eğitim doğruluğu ve kaybı eğrilerine yer verilmiştir. Elde edilen sonuçlar, genel olarak tüm modellerin eğitim performansının DeepCrack veri setine kıyasla daha düşük seviyelerde seyrettiğini göstermektedir. Eğitim kaybı eğrisinin yaklaşık 20. iterasyondan itibaren hızlı bir yakınsama eğilimine girdiği ve eğitim doğruluğunun 50. iterasyondan sonra sabit bir değere ulaştığı gözlemlenmiştir. Özellikle Xception ve Inception-ResNet omurga yapılarında, eğitim kaybı ve doğruluk eğrilerinde belirgin dalgalanmalar gözlenmiştir; bu durum, modellerin veri üzerindeki istikrarsız öğrenme davranışlarını işaret etmektedir.




Şekil 4.2 CrackForest veri seri ilişkin eğitim ve kayıp fonksiyonları, (a) ResNet-18, (b) ResNet-50, (c) MobileNetV2, (d) Xception ve (e) Inception-ResNet [38]

Farklı ön eğitilmiş ESA temelli omurga mimarilerinin segmentasyon başarımını güvenilir bir şekilde analiz etmek amacıyla 10 katlı çapraz doğrulama uygulanmıştır. Uygulanan yöntem sayesinde, her bir segmentasyon tekrarında farklı veri dağılımı senaryoları oluşturularak, her bir görüntünün eğitim, doğrulama ve test kümelerinde yer alması sağlanmıştır. Şekil 4.3'te, incelenen omurga mimarilerine ait segmentasyon çıktılarından örnek görsellere yer verilerek, modellerin görsel performanslarına ilişkin nitel bir karşılaştırma yapılmıştır.



Şekil 4.3 Farklı mimarilere ilişkin elde edilen görsel segmentasyon çıktıları (a): Gerçek referans (Ground-Truth), (b) ResNet-18, (c): ResNet-50, (d):MobileNetv2, (e): Xception, (f):Inception-ResNet

Şekil 4.4'te görüldüğü üzere MobileNetV2 tabanlı segmentasyon mimarisinin farklı veri dağılımlarında daha düşük varyansa sahip ve başarılı bir performans sergilemiştir. Farklı omurga mimarileri için genel olarak doğruluk metriğinin en düşük varyansa sahip olduğu gözlemlenmiştir. Her bir segmentasyon katında farklı bir dağılım ile birlikte elde edilen başarımının doğrudan etkilendiği ve değişimin CrackForest veri seti için daha yüksek düzeylerde olduğu tespit edilmiştir. Üstün performans sağlayan omurga mimarilerin kullanıldığı segmentasyon mimarilerinin farklı veri dağılımlarında daha tutarlı olduğu elde edilen bulgularla gözlemlenmiştir. Şekil 4.4'te farklı omurga mimarilere ilişkin segmentasyon çıktılarının örnek görselleri verilmiştir.



Şekil 4.4 Farklı mimarilerine ilişkin segmentasyon performanslarının kutu grafikleri

Ground truth görüntüler ile elde edilen segmentasyon çıktıları karşılaştırıldığında, farklı omurga mimarileriyle yapılandırılmış DeepLabV3+ modellerinin genel olarak tatmin edici düzeyde segmentasyon başarımı sergilediği gözlemlenmiştir. Özellikle ResNet-50 ve MobileNetV2 temelli mimarilerin daha tutarlı ve net segmentasyon sonuçları sunduğu, görsel incelemeler doğrultusunda belirlenmiştir. Buna karşın, Inception-ResNet ve Xception tabanlı segmentasyon mimarilerinde yanlış pozitif (false positive) sınıflandırmaların sayısal olarak fazla olduğu ve bunun modelin ayırt edici gücünü olumsuz etkilediği tespit edilmiştir. Ayrıca, DeepCrack veri setinde yer alan çatlakların görece daha kalın yapılarla ve yüksek piksel yoğunluğu ile temsil edilmesi, önerilen modellerin bu bölgelerde yanlış negatif (false negative) etiketleme yapma riskini azalttığı yönünde bulgular sunmuştur. Görsel segmentasyon çıktıları, bu durumu destekleyen niteliksel kanıtlar sağlamaktadır.

4.2 Kahramanmaraş Veri Seti Segmentasyon Sonuçları


Anlamsal segmentasyon görevinde kullanılan veri kümesi, önerilen ağların eğitimi, doğrulaması ve test işlemleri için sırasıyla %60, %20 ve %20 oranlarında üç alt kümeye ayrılmıştır. Her bir alt küme, ağların etkin şekilde öğrenmesini ve değerlendirilmesini sağlamak amacıyla arka plan, hasarsız ve yıkılmış sınıflarından yeterli sayıda örnek içerecek şekilde dengeli biçimde oluşturulmuştur. Veri kümesinde yer alan farklı bina türleri ve çeşitli görüş açıları, segmentasyon oranlarının değerlendirilmesinde mimarilerin ayırtırma yeteneklerini test etmek için uygun bir çeşitlilik sunmaktadır. Önerilen mimarilerin genelleme kapasitesini ve performans tutarlılığını daha kapsamlı şekilde incelemek amacıyla beş katlı çapraz doğrulama yöntemi uygulanmıştır. Tablo 4.3'te bu çapraz doğrulama sürecinin ardından elde edilen genel segmentasyon performans metrikleri sunulmaktadır.

Table 4.3 Kahramanmaraş depremi için beş kat çapraz doğrulama sonrasında elde edilen segmentasyon sonuçları

Network	Sınıf	DSC		IoU		Hassasiyet		Özgüllük	
		μ	σ	μ	σ	μ	σ	μ	σ
Deep&ResNet18	Arka Plan	0.838	0.029	0.714	0.0417	0.807	0.084	0.876	0.131
	Yıkılmış	0.813	0.172	0.711	0.225	0.801	0.255	0.910	0.071
	Hasarsız	0.705	0.071	0.548	0.082	0.806	0.255	0.910	0.029
Deep&ResNet50	Arka Plan	0.844	0.021	0.732	0.032	0.820	0.058	0.901	0.069
	Yıkılmış	0.849	0.110	0.750	0.161	0.880	0.094	0.901	0.043
	Hasarsız	0.736	0.058	0.585	0.071	0.782	0.062	0.951	0.013
Deep&MobileNetV2	Arka Plan	0.825	0.062	0.699	0.088	0.801	0.047	0.893	0.055
	Yıkılmış	0.853	0.104	0.755	0.151	0.867	0.098	0.897	0.066
	Hasarsız	0.688	0.058	0.527	0.068	0.745	0.096	0.934	0.030
Deep&Xception	Arka Plan	0.802	0.079	0.675	0.102	0.849	0.075	0.810	0.086
	Yıkılmış	0.806	0.105	0.686	0.142	0.768	0.144	0.919	0.069
	Hasarsız	0.646	0.070	0.481	0.074	0.671	0.078	0.941	0.021

Model eğitimi tamamlandıktan sonra gerçekleştirilen çıkarım süreci, özellikle yıkılmış ve hasarsız sınıflarda yüksek segmentasyon başarımı sergilemiştir. Uygulanan mimariler arasında, DeepLabV3+ yapısının ResNet50 ve MobileNetV2 tabanlı omurgaları, DSC ve IoU gibi temel değerlendirme metriklerinde üstün performans göstermiştir. ResNet50 tabanlı mimari, yıkılmış sınıflar için ortalama olarak 0,849 DSC ve 0,750 IoU değerlerine ulaşırken; hasarsız sınıflar için sırasıyla 0,736 ve 0,585 değerleri elde edilmiştir. Benzer şekilde, MobileNetV2 omurgası


yıkılmış yapılar için ortalama 0,853 DSC ve 0,755 IoU performansı sunarken, hasarsız sınıflar için 0,688 DSC ve 0,527 IoU değerlerine ulaşmıştır. Tüm mimarilerde arka plan sınıfı için yüksek segmentasyon doğruluğu gözlemlenmiş olup, bu sınıfa ait DSC skorları 0,802 ile 0,844 arasında değişmektedir. Eğitimin daha ayrıntılı analizine olanak sağlamak amacıyla, her bir omurga ağının tahmin başarısını eğitim süreci boyunca elde edilen doğruluk ve kayıp eğrileri üzerinden incelenmiştir. Şekil 4.5, Kahramanmaraş veri kümesi üzerinde gerçekleştirilen eğitim iterasyonları sürecinde her bir segmentasyon mimarisine ait doğruluk ve kayıp eğrilerinin zamansal değişimini sunmakta olup, bu veriler mimarilerin genelleme yeteneklerine ilişkin daha kapsamlı çıkarımlarda bulunulmasına olanak tanımaktadır.



Şekil 4.5 Kahramanmaraş deprem veri seti üzerinde her bir segmentasyon ağı için eğitim doğruluğu ve kayıp eğrileri a)Deep&Res18 b)Deep&Res50 c)Deep&MobV2 d)Deep&Xception

Şekil 4.5, farklı segmentasyon ağlarının eğitim doğruluğu ve kayıp değerleri açısından benzer öğrenme eğilimleri sergilediğini ortaya koymaktadır. Eğitim kaybının yakınsama hızı, hem ResNet50 hem de MobileNetV2 omurgaları için ilk 100 iterasyon boyunca oldukça yüksek olup, bu mimariler genellikle 90 ila 100

iterasyon arasında %90 seviyelerinde eğitim doğruluğuna ulaşmaktadır. 200. iterasyon sonrasında doğruluk eğrilerindeki dalgalanmanın azaldığı gözlemlenmiş, bu durum ağların ağırlık güncellemelerinde daha hassas ayarlamalar gerçekleştirdiğini göstermiştir.



Orijinal Görüntü Ground Truth Deep&Res18 Deep&Res50 Deep&MobV2 Deep&Xception

Şekil 4.6 Kahramanmaraş depremi veri seti için segmentasyon sonuçlarının görselleştirilmesi: Kırmızı renk tamamen yıkılmış binaları (yıkılmış sınıf), yeşil renk hasarsız binaları (hasarsız sınıf), siyah renk ise diğer yapısal olmayan unsurları (arka plan sınıfı) temsil etmektedir.

Şekil 4.6’da, her bir modelin segmentasyon çıktıları, zemin gerçeği (ground truth) açıklamalarıyla birlikte görsel olarak sunulmakta ve mimarilerin performansına ilişkin niteliksel analiz yapılmasına olanak tanınmaktadır. Hava görüntüleri üzerinde yapılan değerlendirmelerde, özellikle MobileNetV2 ve Xception tabanlı mimarilerin hasarsız sınıfın segmentasyonunda daha yüksek doğruluk ve hassasiyet sağladığı görülmüştür. Öte yandan, yıkılmış yapıların segmentasyonu açısından ResNet50 omurgasının daha dayanıklı özellikler çıkartarak doğruluk oranlarını artırdığı tespit edilmiştir. Ayrıca, ResNet50 ve Xception tabanlı mimariler, yıkılmış binalarla arka

plan arasındaki düşük kontrast, düzensiz yapılar ve görüntü gürültüsü gibi zorlukların üstesinden daha etkili biçimde gelebilmektedir.

4.3 xBD Veri Seti Segmentasyon Sonuçları

Önerilen segmentasyon modelleri, xBD büyük ölçekli veri kümesinde yer alan ve Joplin Kasırgası felaketi sonrasında elde edilen uydu görüntüleri üzerinde de uygulanarak test edilmiş olup, deneysel çalışmada, her bir mimarinin eğitimi ve değerlendirilmesi sürecinde kullanılan veri ayırım oranları ile k-katlı çapraz doğrulama prosedürü, Kahramanmaraş veri kümesinde uygulanan yöntemle tutarlı şekilde gerçekleştirilmiştir. Joplin veri seti, özellikle arka plan sınıfına ait piksel yoğunluğunun oldukça yüksek olması ve hasarsız ile yıkılmış bina sınıflarının daha sınırlı örneklerle temsil edilmesi nedeniyle ciddi bir sınıf dengesizliği barındırmaktadır.

Genel değerlendirmede, tüm mimariler arka plan segmentasyonunda yüksek doğruluk sergileyerek en sağlam çıktıları bu sınıf üzerinde üretmiştir. Arka plan sınıfı için DSC 0.915 ile 0.925 arasında, IoU ise 0.843 ile 0.861 aralığında değişen sonuçlar vermiştir. ResNet50 omurgasına sahip segmentasyon mimarisi, sırasıyla arka plan, hasarsız ve yıkılmış sınıflar için 0.925, 0.658 ve 0.478 DSC değerlerine ulaşarak diğer mimarilerle karşılaştırıldığında daha üstün performans sergilemiştir.

MobileNetV2 mimarisi, görece daha az parametreye sahip olmasına karşın bütün sınıflarda tutarlı bir performans sergilemiştir. Özellikle yıkılmış ve hasarsız yapı sınıflarında sırasıyla 0.476 ve 0.613 DSC değerleriyle ResNet50'ye yakın sonuçlar üretmiştir. Bu yönüyle, sınırlı kaynak gereksinimi olan uygulamalarda tercih edilebilir bir alternatif olarak değerlendirilebilir.


ResNet18, özellikle yıkım sınıfında ResNet50'ye oldukça yakın bir performans sergilemiş (DSC: 0.469), ancak hasarsız sınıfta belirgin bir düşüş gözlemlenmiştir (DSC: 0.587). Derinlik açısından sınırlı olan bu mimarinin daha detaylı sınıf ayrımlarında yetersiz kaldığı değerlendirilmektedir. Xception mimarisi ise, incelenen tüm modeller arasında en düşük yıkım sınıfı başarımına sahiptir (DSC: 0.466). Modelin eğitim sürecinde de benzer bir zayıflık gözlemlenmiştir.

Şekil 4.7’deki doğruluk eğrileri incelendiğinde, ResNet50 ve MobileNetV2 modellerinin ilk 100 iterasyonda hızlı bir yakınsama sağladığı, eğitim sürecinin stabil ilerlediği görülmektedir. Buna karşılık Xception ve ResNet18 modellerinde, özellikle ilk 150 iterasyonda doğruluk değerlerinde belirgin dalgalanmalar gözlemlenmiş; bu durum modellerin daha geç yakınsadığını ve öğrenme sürecinde kararsızlık yaşadığını ortaya koymuştur.

Tablo 4.4, her bir mimarinin segmentasyon çıkarımına ilişkin detaylı performans metriklerini sunmaktadır. Ek olarak, Şekil 4.7, eğitim süreci boyunca ağların giriş verileri üzerindeki optimizasyon kabiliyetlerini değerlendirmek amacıyla elde edilen doğruluk ve kayıp eğrilerini göstermektedir.


Table 4.4 Joplin Kasırgası felaketinin beş kat çapraz doğrulamasından sonra elde edilen segmentasyon sonuçları

Network	Class	DSC		IoU		Hassasiyet		Özgüllük	
		μ	σ	μ	σ	μ	σ	μ	σ
Deep&ResNet18	Arka Plan	0.915	0.011	0.843	0.019	0.859	0.023	0.868	0.043
	Yıkılmış	0.469	0.103	0.311	0.088	0.752	0.152	0.950	0.030
	Hasarsız	0.587	0.022	0.416	0.022	0.807	0.062	0.908	0.022
Deep&ResNet50	Arka Plan	0.925	0.015	0.861	0.027	0.873	0.028	0.898	0.015
	Yıkılmış	0.478	0.054	0.315	0.048	0.807	0.087	0.946	0.033
	Hasarsız	0.658	0.031	0.419	0.034	0.848	0.041	0.927	0.025
Deep&MobileNetV2	Arka Plan	0.918	0.020	0.849	0.034	0.865	0.035	0.866	0.013
	Yıkılmış	0.476	0.047	0.314	0.040	0.746	0.129	0.950	0.041
	Hasarsız	0.613	0.024	0.442	0.025	0.822	0.017	0.916	0.015
Deep&Xception	Arka Plan	0.917	0.025	0.848	0.043	0.866	0.045	0.850	0.022
	Yıkılmış	0.466	0.030	0.304	0.026	0.727	0.169	0.945	0.049
	Hasarsız	0.619	0.036	0.449	0.038	0.803	0.051	0.922	0.024



Şekil 4.7 Joplin Kasırgası felaketi veri kümesi üzerinde her bir segmentasyon ağı için eğitim doğruluğu ve kayıp eğrileri a)Deep&Res18 b)Deep&Res50 c)Deep&MobV2 d)Deep&Xception

Şekil 4.7, farklı segmentasyon mimarilerinin eğitim sürecinde doğruluk ve kayıp eğrileri açısından benzer öğrenme dinamiklerine sahip olduğunu göstermektedir. Özellikle ResNet50 ve MobileNetV2 tabanlı ağlarda, ilk 50 iterasyon içerisinde eğitim kaybında hızlı bir yakınsama eğilimi gözlemlenmiş, bu mimariler genellikle 90 ila 100 iterasyon arasında %90'lık eğitim doğruluğuna ulaşmıştır. 150. iterasyondan itibaren doğruluk eğrilerindeki dalgalanmaların azaldığı gözlemlenmiş olup, bu durum ağların parametre güncellemelerinde daha hassas ayarlamalara geçtiğini göstermektedir. Her bir mimarinin çıkarım (inference) aşamasındaki performansına ilişkin görsel ve nicel veriler, Şekil 4.8'de detaylı biçimde sunulmuştur.



Şekil 4.8 xBD (Joplin Tornado felaketi) veri kümesi için segmentasyon sonuçlarının görselleştirilmesi: Kırmızı renk tamamen çökmüş binaları (yıkılmış sınıf), yeşil renk hasarsız binaları (hasar yok sınıfı) ve siyah renk diğer yapısal olmayan unsurları (arka plan sınıfı) temsil eder.

Kasırgalar, etkiledikleri bölgelerde yüksek düzeyde fiziksel yıkıma neden olmakta ve ortaya çıkan enkaz, depremlere kıyasla daha geniş alanlara yayılabilmektedir. Bu durum, afet öncesi haritalama ile tanımlanmış bina poligonlarının, özellikle yıkılmış yapıların, anlamsal segmentasyonunu önemli ölçüde zorlaştırmaktadır. Şekil 4.8 genel olarak tüm segmentasyon mimarilerinin yıkılmış yapıların tespiti konusunda güçlük yaşadığını ortaya koymaktadır. Özellikle Şekil 4.8'in 3. ve 4. satırlarında yer alan örneklerde, bina yıkıntılarının çevre alanlara dağılması nedeniyle, binaların yakınındaki arka plan piksellerinin model tarafından sıklıkla 'yıkılmış' sınıfına ait olarak sınıflandırıldığı gözlemlenmiştir. Ayrıca, Şekil 4.8'in son satırında sunulan örnek, segmentasyon mimarilerinin zemin ile düşük kontrasta sahip yapı sınırlarını doğru şekilde ayırtmakta zorlandığını ve bu tür örneklerde doğruluk seviyesinin düştüğünü göstermektedir.

4.4 Ön Görüntü Poligonlarına Dayalı Sınıflandırma Sonuçları


Bu çalışmada, afet öncesi uydu görüntülerinden elde edilen bina poligonları ile afet sonrası görüntüler üzerinde her bir segmentasyon ağı tarafından üretilen çıktı haritaları üst üste bindirilerek bina düzeyinde sınıflandırma işlemi gerçekleştirilmiştir. Bina ayak izi konumlarının hassasiyetle belirlenmesi, afet sonrası acil müdahale süreçlerinde yönlendirme ve kaynak tahsisi açısından kritik bir rol oynamaktadır. Etkili ve güvenilir haritalama sistemleri, özellikle kriz anlarında hızlı karar alma mekanizmalarının işletilebilmesi için temel gerekliliklerdendir. Bir binanın geometrik sınırlarının afet sırasında değişime uğrayabileceği öngörüsüyle, karşılaştırma temelini oluşturmak amacıyla, yalnızca afet öncesi görüntülerden türetilmiş olan bina poligon sınırları referans olarak kullanılmıştır. Uygulanan yöntem kapsamında, afet sonrası segmentasyon haritalarında bir poligonun sınırları içerisinde ‘yıkılmış’ olarak etiketlenmiş piksel sayısının, ‘hasarsız’ olarak etiketlenmiş piksel sayısından fazla olması durumunda, ilgili bina ayak izi ‘yıkılmış’ olarak sınıflandırılmıştır; aksi halde ‘hasarsız’ olarak değerlendirilmiştir. Afet öncesine ait toplam 139 görüntü üzerinde yapılan analiz sonucunda 34.450 bina poligonu tespit edilmiştir. Tablo 4.5, bina düzeyindeki sınıflandırma doğruluğunu değerlendirmek üzere her bir segmentasyon mimarisi için doğruluk, hassasiyet, özgüllük, kesinlik ve F1-skor gibi temel performans metriklerini sunmaktadır.

Tablo 4.5 Her bir segmentasyon ağı için bina poligon tabanlı sınıflandırmanın performansı detaylandırılmıştır, burada μ ortalama değeri ve σ standart sapmayı temsil etmektedir. Performans ölçütlerinin değerlendirilmesinde, yıkılmış binalar pozitif sınıf olarak kabul edilirken, geri kalan hasarsız binalar negatif sınıf olarak kabul edilir.

Temel Modeller	Doğruluk		Hassasiyet		Özgüllük		Kesinlik		F1-skoru	
	μ	σ	μ	σ	μ	σ	μ	σ	μ	σ
ResNet18	0.936	0.014	0.769	0.161	0.969	0.016	0.882	0.061	0.817	0.116
ResNet50	0.935	0.016	0.819	0.125	0.948	0.039	0.858	0.042	0.835	0.077
MobileNetV2	0.931	0.016	0.859	0.112	0.935	0.044	0.815	0.076	0.833	0.080
Xception	0.939	0.010	0.820	0.111	0.963	0.013	0.860	0.081	0.838	0.092

Tablo 4.5’te sunulan sonuçlar, incelenen tüm segmentasyon mimarilerinin bina düzeyinde benzer sınıflandırma doğruluklarına ulaştığını göstermektedir. Xception tabanlı mimari, %93,9 oranındaki doğruluk değeriyle diğer mimarilere kıyasla en

yüksek sınıflandırma başarımını sergilemiştir. Öte yandan, MobileNetV2 mimarisi, %85,9'luk hassasiyet (recall) değeri ile özellikle yıkılmış binaların tespitinde güçlü bir performans sergilemiştir. Genel olarak, tüm modellerin hasarsız binaların (hasarsız ve az hasarlı kategoriler) tanımlanmasında daha yüksek başarı düzeyi sağladığı tespit edilmiştir; bu durum, özgüllük (specificity) verileri ile de desteklenmektedir. Elde edilen özgüllük değerleri ResNet18 için %96,9, ResNet50 için %94,8, MobileNetV2 için %93,5 ve Xception için %96,3 olarak hesaplanmıştır. Ayrıca, sınıf dengesizliğiyle başa çıkma konusundaki başarımlar açısından değerlendirildiğinde, Xception ve ResNet50 mimarileri sırasıyla %83,8 ve %83,5 F1-skor değerleriyle öne çıkmaktadır. Şekil 4.9, çeşitli örnek görüntüler üzerinde her bir segmentasyon mimarisi tarafından gerçekleştirilen bina düzeyindeki sınıflandırma sonuçlarını görsel olarak karşılaştırmalı biçimde sunmaktadır.



Şekil 4.9 Joplin Tornado veri setinden örnek görüntüler için her bir segmentasyon ağınnın bina düzeyinde sınıflandırma sonuçları. TP doğru etiketlenmiş yıkılmış yapıları, FP önerilen model tarafından yıkılmış olarak etiketlenmiş hasarsız yapıları, FN önerilen model tarafından hasar sınıfı yok olarak etiketlenmiş yıkılmış yapıları ve TN önerilen model tarafından doğru etiketlenmiş hasarsız binaları temsil etmektedir.

4.5 Hesaplama Karmaşıklığı Analizi


Model karmaşıklığı ile segmentasyon doğruluğu arasındaki ilişkiyi analiz etmek amacıyla, Tablo 4.6’da ayrıntılı olarak sunulan ve Şekil 4.10’da görsel bir ifade ile desteklenen analiz kapsamında, Kahramanmaraş ve Joplin kasırga veri kümeleri üzerinde farklı segmentasyon mimarileri için parametre boyutu (toplam parametre sayısı), çıkarım süresi (inference time) ve segmentasyon başarımı karşılaştırmalı olarak incelenmiştir.

Tablo 4.6 Farklı modeller için toplam öğrenilebilir parametrelerin (M), ortalama çıkarım süresinin (ms) ve segmentasyon performansının karşılaştırılması.

Backbone model	Parametreler (M)	Kahramanmaraş Veri Seti			xBD (Joplin Tornado Veri Seti)		
		Inf.Süresi (ms)	DSC	mIoU	Inf.Süresi (ms)	DSC	mIoU
ResNet18	20.595	58.8	0.785	0.657	60.3	0.657	0.523
ResNet50	43.924	86.2	0.809	0.689	96.2	0.687	0.531
MobileNetV2	6.750	77.5	0.788	0.660	82.7	0.669	0.535
Xception	27.580	90.3	0.751	0.614	95.7	0.667	0.533

Çıkarım süresi, her bir modelin test aşamasında görüntü başına ortalama tahmin süresi olarak değerlendirilmiş olup, bu metrik aynı zamanda hesaplama verimliliğini ve modelin gerçek zamanlı uygulamalara uygunluğunu yansıtmaktadır. MobileNetV2 mimarisi, düşük parametre sayısına ve kısa çıkarım süresine rağmen tatmin edici bir segmentasyon performansı ortaya koyarak doğruluk ile hesaplama maliyeti arasında dengeli bir yapı sunmuştur.

Tablo 4.6’daki bulgular, ResNet50 omurgasına sahip segmentasyon mimarisinin artan derinliği sayesinde en yüksek doğruluk düzeylerine ulaştığını göstermektedir. Bu mimari, sahip olduğu yüksek parametre sayısına karşın 86,2 ila 96,2 milisaniye arasında değişen çıkarım süreleri ile rekabetçi bir gerçek zamanlı performans sunmayı başarmıştır.



Şekil 4.10 Farklı omurga tabanlı modeller için parametre boyutu (parametre sayısı), çıkarım süresi ve segmentasyon performansının görsel karşılaştırması. Sol sütun Kahramanmaraş veri setini, sağ sütun ise Joplin Tornado veri setini temsil etmektedir.

4.6 Tartışma

4.6.1 Çatlak Segmentasyonu

Semantik segmentasyon, bilgisayarla görme alanında temel araştırma başlıklarından biri olup, özellikle son yıllarda beton yüzeylere ait görüntülerin analizinde yaygın olarak kullanılmaktadır. Segmentasyon modellerinin başarımını artırmaya yönelik en yaygın stratejilerden biri, önceden büyük veri kümeleri üzerinde eğitilmiş olan ESA temelli omurga mimarilerinin kullanımıdır [82, 108, 112]. Çalışma sonuçları, ön eğitilmiş mimarilerin segmentasyon performansını doğrudan etkilediğini göstermiştir. Farklı ESA yapılarıyla elde edilen sınıflandırma performanslarının değişkenlik göstermesi, mimari seçimin model başarımını açısından önemli bir unsur olduğunu göstermektedir.

Yüksek doğruluk oranlarına sahip semantik segmentasyon modellerinin önemli sınırlılıklarından biri hesaplama yükünün fazlalığıdır [29]. Bu nedenle, hem segmentasyon doğruluğu hem de model karmaşıklığı (parametre sayısı) açısından dengeli mimarilerin geliştirilmesi önem arz etmekte olup, çalışma boyunca yapılan analizler, MobileNetV2 mimarisinin bu dengeyi en iyi sağlayan omurga yapı olduğunu ortaya koymuştur. Yaklaşık 6.7 milyon eğitilebilir parametreye sahip MobileNetV2 tabanlı DeepLabV3+ modeli, hem segmentasyon doğruluğu hem de hesaplama verimliliği bakımından en başarılı performansı sergilemiştir.

ESA mimarileri esasen büyük ölçekli görüntü sınıflandırma görevleri için tasarlanmış, güçlü özellik çıkarım kapasitelerine sahip yapılardır [23]. Bu çalışmada, hem derin hem de görece sığ ön eğitilmiş mimarilerin segmentasyon görevlerindeki etkinlikleri karşılaştırmalı olarak değerlendirilmiştir. Derin kodlayıcı mimarilerin ürettiği küçük boyutlu özellik haritaları, sınıflandırma görevlerinde avantaj sağlarken, segmentasyon açısından bazı dezavantajları da beraberinde getirmektedir [107]. Özellikle çatlak gibi küçük ve ince yapılarla temsil edilen bölgelerde, düşük çözünürlüklü özellik haritalarının uzamsal bilgiyi kaybetme eğiliminde olduğu gözlemlenmiştir. Bu bağlamda, Inception-ResNet gibi derin yapılarla elde edilen düşük segmentasyon başarımı, daha büyük özellik haritalarının beton çatlakları gibi ince ayrıntılar içeren uygulamalarda daha uygun olduğunu ortaya koymuştur.

Önerilen segmentasyon modelleri, DeepCrack ve CrackForest veri setleri üzerinde test edilmiştir. Her iki veri setiyle elde edilen performanslar arasında belirgin farklılıklar gözlemlenmiştir. Bu farklılığın temel nedenleri arasında çatlakların geometrik yapısı, boyutu, aydınlatma koşulları ve gölgeleme gibi görüntüleme şartlarının veri setleri arasında farklılık göstermesi yer almaktadır. Ayrıca, DeepCrack veri setinin daha büyük boyutta olması, bu veri seti üzerinde elde edilen segmentasyon başarımının daha yüksek olmasında etkili bir unsur olarak değerlendirilmektedir. Bununla birlikte, her iki veri setinin sınırlı sayıda örnek içermesi nedeniyle, model genelleme kabiliyetinde bazı sınırlamalar oluşmuş, bu durumu aşmak adına literatürde yaygın olarak veri artırımı (data augmentation) yöntemlerine başvurulduğu gözlemlenmiştir.

Tablo 2.5'te literatürdeki örnekler incelendiğinde, Qayyum vd. çalışmasında ResNet-50 modeli %81.7 DSC ve %69.1 IoU değerlerine ulaşmıştır. Inception V3 mimarisi ile %88 DSC ve %78.6 IoU değerlerine ulaşmıştır [34]. Benzer şekilde, Jenkins vd. tarafından önerilen U-Net tabanlı mimari %87.3 DSC ile yüksek bir başarı sağlamıştır [93]. Fan vd. çalışmasında ESA tabanlı modelin %95.3 DSC elde ettiği bildirilmiştir [94]. Ayrıca Ali vd. çalışmasında VGG16 tabanlı mimari ile %99.9 DSC, %99.8 IoU değerlerine ulaştığı belirtilmiştir [97]. Bu farkların temel nedenleri arasında, literatürde genellikle daha geniş veri setlerinin kullanılması, veri artırımı tekniklerinin (örneğin CutMix, Temporal Data Fusion) uygulanması ve daha uzun

sürekli eğitim süreçlerinin (örneğin 100–300 epoch) tercih edilmesi gösterilebilir. Bu çalışmada ise veri artırımı yapılmamış ve eğitim epoch sayısı sınırlı tutulmuştur (10 epoch).

Bununla birlikte, kullanılan DeepCrack veri setinin doğası gereği çatlakların kalınlığı ve morfolojisinin daha homojen olması, önerilen MobileNetV2 tabanlı modelin stabil ve güvenilir sonuçlar vermesine katkı sağlamıştır. Derin ve karmaşık modellerin (örneğin Inception-ResNet) segmentasyon performansında geride kalması, küçük çatlak bölgelerinin daha hassas segmentasyonunda sık ve hafif mimarilerin (MobileNetV2 gibi) daha avantajlı olduğunu bir kez daha kanıtlamıştır.

Tablo 2.5 incelendiğinde, Hadinata vd. çalışmasında U-Net tabanlı bir model %87.5 DSC [99]; Jamshidi vd. çalışmasında ise CutMix ve Temporal Data Fusion teknikleri ile güçlendirilmiş U-Net modelinin %65.6 DSC başarımına ulaştığı rapor edilmiştir [37]. Ayrıca, Ye vd. tarafından geliştirilen YOLOv7-AMF modelinde %94.1 doğruluk sağlanmıştır [92]. Literatürdeki çalışmalarla karşılaştırıldığında, CrackForest çalışmasındaki oranların düşük kaldığı görülmektedir. Bu farkın temel sebebi olarak CrackForest veri setinin daha az sayıda görüntü içermesi (sadece 118 görüntü) ve çatlakların daha ince, düşük kontrastlı ve düzensiz yapıda olması gösterilebilir. Ayrıca, veri setinde gölgeleme ve zemin kirliliği gibi gürültü faktörlerinin bulunması segmentasyon başarımını olumsuz yönde etkilemiştir. Literatürdeki yüksek başarılı çalışmaların çoğunda veri artırımı, ön işleme adımları (gürültü azaltma, histogram eşitleme vb.) ve daha yoğun eğitim süreçleri kullanılırken, bu çalışmada veri setlerine doğrudan müdahale edilmemiştir.

Kodlayıcı mimarilerin etkinliği üzerine değerlendirme yaptığımızda, elde edilen sonuçlar, derin omurga mimarilerinin (örneğin ResNet-50 ve Inception-ResNet) segmentasyon başarımını artırmada her zaman avantaj sağlamadığını açıkça ortaya koymuştur.

Literatürde raporlanan performans değerleri ile karşılaştırıldığında, veri artırımı ve ileri eğitim tekniklerinin eksikliği nedeniyle doğrudan bir üstünlük sağlanamasa da, önerilen modellerin makul bir performans sergilediği görülmüştür. Bulgular, beton çatlaklarının segmentasyonunda hafif ağların derin ağlara kıyasla daha verimli

olduğunu ve ağ seçiminde model karmaşıklığından ziyade problem yapısının ön planda tutulması gerektiğini göstermektedir.

Sonuçlar, bu çalışmanın mevcut literatürdeki yaklaşımlar ile uyumlu olmakla birlikte, eğitim verisinin büyüklüğü, veri seti çeşitliliği ve ileri seviye düzenleme tekniklerinin (data augmentation, dikkat mekanizmaları, multi-scale feature extraction gibi) segmentasyon başarımında belirleyici olduğunu göstermektedir. Ayrıca, DeepLabV3+ çerçevesinde kullanılan kodlayıcı mimarinin segmentasyon kalitesi üzerinde doğrudan etkili olduğu; daha derin ağların değil, problem odaklı hafif ağların seçilmesinin daha stratejik bir tercih olabileceği sonucuna varılmıştır.

4.6.2 Uydu ve Drone Görüntüleri

Bu çalışmada, uzaktan algılama görüntülerini kullanarak, deprem sonrası yıkılan yapıların tespitinde derin öğrenme tabanlı segmentasyon modellerinin performansı karşılaştırılmakta ve farklı ağ mimarilerinin segmentasyon başarısı ile genel etkinlikleri değerlendirilmektedir.

Yüksek çözünürlüklü görüntülerin uzamsal çözünürlüğünün artırılması, derin öğrenme teknikleri ile birlikte hasar tespitinin doğruluğunu önemli ölçüde artırmaktadır [5]. Ancak, derin öğrenme modellerinin eğitim süreçlerinde aşırı uyumun önüne geçebilmek için veri setlerinin çeşitlendirilmesi kritik bir gerekliliktir. Deprem sonrası yüksek çözünürlüklü uzaktan algılama görüntülerinde arka plan ortamının karmaşıklığı, doğal görüntülerden daha farklıdır; bu da sınıflandırma çıktıları üzerinde daha belirgin bir etkiye yol açmaktadır. Örneğin, yıkılmış kerpiç ev ile çıplak toprağın özelliklerinin benzerliği, çıplak toprağı yıkılmış yapı olarak değerlendirmeyi kolaylaştırmaktadır [56]. Uzaktan algılama verilerinin analizinde, çok zamanlı yaklaşımların tek zamanlı yaklaşımlara kıyasla daha üstün performans sergilediği görülmektedir [40]. Ancak, karmaşık arka planlar ve benzer özelliklere sahip hasarlı binalar nedeniyle yanlış sınıflandırmalar yaygın olarak karşılaşılan bir durumdur [69]. Özellikle, deprem sonrası yüksek çözünürlüklü uzaktan algılama görüntülerinin arka planının karmaşıklığı, doğal görüntülerden daha belirgin etkiye sahiptir ve bu da sınıflandırma sonuçlarını önemli ölçüde etkilemektedir. Gerçek zamanlı afet müdahalelerinde kritik öneme sahip olan hızlı ve daha hafif eğitim süreçlerine sahip modellerin geliştirilmesi gerekmektedir [58]. Ayrıca, büyük çaba

sarf edilerek yüksek kaliteli açıklamalı veri kümeleri oluşturulmalı ve çok modlu veri kümeleri, hasar tespitinde daha kapsamlı ve doğru bilgi sunma amacıyla kullanılmalıdır [40]. Bu noktada, derin sinir ağlarının, özellikle anlamsal segmentasyon modellerinin eğitilmesi genellikle uzun zaman alırken, büyük miktarda açıklamalı veri gerektirmektedir. Bu durum, hızlı karar alınması gereken gerçek dünya afet senaryoları için uygun olmayabilir. Daha sağlam ve hafif modellerin geliştirilmesi, bu sınırlamaların aşılmasında önemli bir adım olacaktır.

Bu çalışmada yer alan derin öğrenme modellerinin performansı, Kahramanmaraş veri setinde elde edilen segmentasyon doğrulukları ve literatürdeki başarılı modellerle karşılaştırıldığında oldukça tatmin edici sonuçlar sunmaktadır. BoW+DVM, Histogram tabanlı sınıflandırıcılar, KNN, MLP vb. genellikle %64-%91 doğruluk ve %79-%83 DSC aralığında sonuçlar sunmuştur (Tablo 2.1). ESA ve transfer öğrenimi tabanlı modellerle yapılan kıyaslamalarda ise, bazı modeller (YOLOv4 + ResNext + Focal-EIOU Loss gibi) %87.2 DSC'ye ulaşmıştır (Tablo 2.2 ve 2.3). Ancak bu modellerin çok büyük veri setlerine ve GPU gücüne ihtiyaç duyduğu bilinmektedir. ResNet50 ve MobileNetV2'nin, eğitim süreci ve donanım maliyetleri göz önünde bulundurulduğunda benzer doğruluklara düşük karmaşıklıkla ulaşabilmesi, önemli bir avantajdır. Tablo 2.2'de yer alan BDANet modeli, xBD veri setinde 0,806 DSC ve 0,675 IoU [3], VGG16 modeli, 0.825 DSC ve 0.702 IoU [52] değerleriyle oldukça iyi bir segmentasyon performansı sunmasına rağmen, Kahramanmaraş veri setinde test edilen modellerin daha yüksek doğruluklar elde etmesi, önerilen modellerin özellikle deprem sonrası hasar tespiti için optimize edilebileceğini göstermektedir. Levir-CD veri setinde U-Net++ modeli, 0.940 DSC ve 0.887 IoU [3] performans sunmasına karşın, Kahramanmaraş veri setindeki ResNet50 ve MobileNetV2'nin başarıları, bu modellerin yüksek çözünürlüklü drone görüntüleri ile daha verimli öğrenebileceğini ortaya koymaktadır.

Tablo 4.5'te yer alan bina bazlı sınıflandırma analizine göre, Xception modeli doğruluk oranıyla genel başarıda öne çıkarken, MobileNetV2 modeli hassasiyet oranıyla yıkılmış binaların tespitinde üstünlük sağlamıştır. Bu bulgular, özellikle afet sonrası hızlı müdahale gerektiren durumlarda, yüksek doğruluk oranlarına sahip MobileNetV2 gibi hafif ve verimli modellerin önemini vurgulamaktadır. Tablo

4.6’da ise hesaplama karmaşıklığı açısından MobileNetV2’nin parametre ve çıkarma süresi ile en verimli model olduğu, buna karşın ResNet50’nin daha fazla hesaplama gücü gerektirdiği gözlemlenmiştir. Kahramanmaraş veri setindeki segmentasyon başarı oranları, afet sonrası hızlı ve hassas hasar tespiti için mevcuttaki en başarılı yöntemlerden biri olarak kabul edilebilir. Ancak xBD veri setindeki performans düşüşü, sınıf dengesizliği ve enkaz yayılımının model performansını etkilediğini göstermektedir. Bu bağlamda, gelecek çalışmalarda çok zamanlı görüntü analizi ve hibrit model yaklaşımlarının entegrasyonu ile modelin genelleme yeteneği artırılabilir, böylece farklı afet senaryolarında daha başarılı tespitler sağlanabilir.

Bu çalışmada kullanılan daha büyük ve çeşitlendirilmiş veri setinde, modellerin genellenebilirliğini artırmada önemli bir rol oynamıştır. Modellerin hiperparametre ayarlarının optimize edilmesi, performans artışına önemli ölçüde katkı sağlamıştır. Ayrıca, daha derin ağ yapıları ve farklı mimariler kullanılarak model performansı iyileştirilmiştir. Birden fazla modelin bir arada kullanılması ise farklı modellerin güçlü yönlerini birleştirerek daha üstün sonuçlar elde edilmesini sağlamıştır. Eğitim verilerinin artırılması, modelin daha sağlam hale gelmesine yardımcı olmuştur. Veri artırımı, rotasyon, öteleme ve ölçekleme gibi tekniklerle gerçekleştirilmiştir. Model çıktılarının daha fazla analiz edilmesi, yanlış sınıflandırmaların nedenlerini anlamak ve düzeltmek için kritiktir. Bu analizler, modelin zayıf yönlerinin belirlenmesine olanak tanıyarak, iyileştirme stratejilerinin geliştirilmesine katkı sağlayabilir. Bu öneriler, uzaktan algılama görüntüleri kullanılarak derin öğrenme tabanlı modellerin performansını artırmak ve yıkılmış yapıların tespiti konusunda daha etkili bir yaklaşım benimsemek adına değerli katkılar sunacaktır.

Bununla birlikte, genel başarıya rağmen, bazı yanlış sınıflandırma örneklerinin çeşitli faktörlere atfedilebileceği gözlemlenmiştir. Öne çıkan faktörlerden biri, deprem sonrası hava görüntülerindeki karmaşık arka plan ortamıdır. Ayrıca, hasarlı bina enkazının ve açıkta kalan toprağın görsel özelliklerinin benzerliği, yanlış sınıflandırma olasılığını artırmaktadır. Bu durum, gelecekteki çalışmalarda bu tür karmaşık arka planların daha iyi işlenmesi için daha sofistike model yaklaşımlarının geliştirilmesi gerektiğini ortaya koymaktadır.

5. SONUÇLAR VE ÖNERİLER

5.1 Sonuçlar

Tez çalışması, yapı sağlığı izleme ve afet sonrası hasar tespiti alanlarında, derin öğrenme tabanlı semantik segmentasyon yöntemlerinin etkinliğini değerlendirmek ve geliştirmek amacıyla iki aşamalı bir yaklaşım ile yürütülmüştür. İlk aşamada, beton yüzeylerde meydana gelen çatlakların piksel düzeyinde segmentasyonu hedeflenmiş, farklı omurga mimarilerine sahip DeepLabV3+ modelleri kullanılarak çatlak tespit performansları karşılaştırılmıştır. İkinci aşamada ise, büyük ölçekli doğal afetler sonrasında elde edilen uzaktan algılama görüntüleri üzerinden bina bazlı hasar segmentasyonu ve sınıflandırması gerçekleştirilmiştir.

Her iki çalışma, farklı veri kaynaklarına ve problem ölçeklerine (mikro düzeyde yapı malzemesi hasarı ve makro düzeyde bina yıkımı) odaklanmış olsa da, ortak bir metodolojik çerçeve olan derin öğrenme tabanlı semantik segmentasyon yaklaşımı altında bütünleştirilmiştir. Bu yaklaşım sayesinde, hem yapı malzemesi bazlı erken hasar tespiti hem de afet sonrası hızlı müdahale planlaması için otomatik, güvenilir ve hesaplama açısından verimli çözümler geliştirilmiştir.

Bu kapsamda, beton çatlak tespitinde DeepCrack ve CrackForest veri setleri; afet sonrası bina hasar analizinde ise xBD uydu görüntüleri veri seti ve Kahramanmaraş Depremi sonrası oluşturulan özel drone veri seti kullanılarak modellerin başarımları sistematik olarak test edilmiştir. Çalışmanın nihai amacı, yapı sağlığı izleme ve afet yönetimi alanlarına derin öğrenme teknolojilerinin sunduğu olanaklarla yenilikçi katkılar sağlamaktır.

5.1.1 Çatlak Segmentasyonu

Bu çalışmada, beton yüzeylerdeki çatlakların semantik segmentasyonu amacıyla kullanılan DeepLabV3+ mimarisi kapsamında, farklı omurga yapılarının etkinlikleri kapsamlı bir şekilde analiz edilmiştir. Kodlayıcı blokta görev alan ESA tabanlı omurga mimarilerinin hem özellik çıkarım yetenekleri hem de eğitilebilir parametre sayısı açısından verimlilikleri detaylı biçimde değerlendirilmiştir. Bu doğrultuda, Xception, ResNet-18, ResNet-50, MobileNetV2 ve Inception-ResNet mimarileri,

herhangi bir veri artırımı yöntemi kullanılmaksızın, sabit koşullar altında iki farklı kamuya açık veri seti (DeepCrack ve CrackForest) üzerinde test edilmiştir.

Sonuçlar, veri setleri özelinde MobileNetV2 mimarisinin gerek segmentasyon başarımı gerekse model karmaşıklığı bakımından en verimli yapı olduğunu ortaya koymuştur. Yaklaşık 6.7 milyon eğitilebilir parametreye sahip MobileNetV2 tabanlı DeepLabV3+ segmentasyon modeli, DeepCrack ve CrackForest veri setleri üzerinde sırasıyla %81 ve %70 DSC bulgularına ulaşmıştır.

Bu bulgular, DeepLabV3+ çerçevesinin başarımının doğrudan kodlayıcı blokta tercih edilen ESA mimarisine bağlı olduğunu ortaya koymaktadır. Ayrıca, omurga yapılarında artan ağ derinliği ve mimari karmaşıklığın, segmentasyon başarımı üzerinde beklenen pozitif etkiyi yaratmadığı gözlemlenmiştir. Bunun yerine, karmaşık ve derin yapıların yüksek hesaplama maliyeti ve daha yavaş öğrenme süreçleriyle birlikte eğitim sürecini daha hantal hale getirdiği belirlenmiştir. Bu nedenle, segmentasyon başarımı ile hesaplama verimliliği arasında optimal denge sağlayan mimarilerin tercih edilmesi, uygulama açısından ana unsurlardandır.

Elde edilen segmentasyon başarımları, mevcut literatürde önerilen yöntemlerle karşılaştırıldığında hem güçlü yönler hem de iyileştirmeye açık noktalar ortaya koymaktadır. DeepCrack veri setinde, en yüksek segmentasyon performansı MobileNetV2 ile elde edilmiştir. Bu model çatlak sınıfı için %63.1 DSC, %46.7 IoU ve %97.0 doğruluk değerlerine ulaşmıştır. Ancak bu sonuçlar, literatürde Inception-V3, ResNet-101 ve U-Net gibi gelişmiş modellerle raporlanan başarımların altında kalmaktadır. Bu fark, kullanılan modellerin mimari derinlikleri, veri artırımı stratejileri (ör. CutMix, temporal fusion) ve eğitim süresine bağlı olarak açıklanabilir.

CrackForest veri setinde, çatlak sınıfı için en yüksek başarı yine MobileNetV2 ile sağlanmış; burada %41.9 DSC ve %26.6 IoU değerleri elde edilmiştir. CrackForest veri setindeki düşük performans, sınırlı görüntü sayısı (118 adet), çatlakların düzensiz, ince ve düşük kontrastlı yapısı, ayrıca gölgelenme ve yüzey gürültüsü gibi faktörlerle ilişkilidir.

Buna karşın, literatürde U-Net + CutMix + Temporal Fusion, YOLOv8 ve ESA tabanlı bazı modellerle son derece yüksek başarımlar rapor edilmiştir. Bu yüksek başarımların çoğu, ileri seviye veri işleme adımları, yoğun eğitim döngüleri (100–300 epoch) ve özel mimari optimizasyonlar kullanılarak sağlanmıştır.

Elde edilen veriler, önerilen modellerin segmentasyon performansının; modelin derinliği, eğitim süreci, veri setinin yapısal özellikleri ve ön işleme teknikleri ile doğrudan ilişkili olduğunu göstermektedir. MobileNetV2 gibi daha az parametrelili, hafif modeller; özellikle düşük örneklem sayısına sahip veri setlerinde dengeli ve genellenebilir sonuçlar sunarken, derin mimariler (örneğin Inception-ResNet) veri yetersizliği durumunda aşırı uyum riskine sahiptir.

Sonuç olarak, bu çalışmada önerilen çerçeve, veri setlerine doğrudan müdahale edilmeden uygulandığında dahi kabul edilebilir düzeyde performans sergilemiştir. Ancak, literatürdeki yüksek doğruluk seviyelerine ulaşmak için model mimarilerinde dikkat mekanizmaları, çok ölçekli özellik füzyonu ve domain-adaptation gibi ileri düzey yaklaşımların entegrasyonu gerekmektedir.

5.1.2 Uydu ve Drone Görüntüleri

İkinci çalışma kapsamında, afet sonrası yapı hasar tespitine yönelik olarak geliştirilen derin öğrenme tabanlı semantik segmentasyon modelleri; doğruluk, genellenebilirlik ve hesaplama verimliliği açısından sistematik olarak değerlendirilmiştir. Bu amaçla, çalışma kapsamında özel olarak oluşturulan Kahramanmaraş Depremi veri seti ile birlikte Joplin Kasırgası ve xBD'ye ait yüksek çözünürlüklü drone ve uydu görüntülerinden oluşan veri kümeleri kullanılmış; bina bazında hasar tespiti gerçekleştirilmiştir. DeepLabV3+ mimarisi, farklı evrimsel omurga yapıları (Xception, ResNet-18, ResNet-50, MobileNetV2) ile entegre edilerek test edilmiştir. Bina düzeyinde sınıflandırma için afet öncesi görüntülerden çıkarılan poligon verileri ile model çıktıları birleştirilerek hasar seviyesi tayin edilmiştir. Deneysel bulgular, ResNet-50 ve MobileNetV2 omurgalarının segmentasyon doğruluğu açısından üstün performans sergilediğini ortaya koyarken, Xception mimarisinin düşük hesaplama yükü ve daha hızlı çalışması sayesinde gerçek zamanlı uygulamalarda avantaj sağladığı belirlenmiştir. Öte yandan, sınıf dengesizliği ve karmaşık enkaz yapısı,

özellikle yıkılmış binaların tespitinde tüm modellerin performansını olumsuz etkilemiş olup; bundan en çok düşük katman derinliğine sahip modellerin etkilendiği gözlemlenmiştir.

Elde edilen sonuçlar, önerilen modellerin literatürdeki öncül yaklaşımlarla kıyaslandığında rekabetçi bir performans sergilediğini göstermektedir. Özellikle Kahramanmaraş veri setinde yıkılmış sınıfında, Deep&MobileNetV2 modeli 0.853 DSC ve 0.755 IoU değerleri ve Deep&ResNet50 mimarisi DSC: 0.849, IoU: 0.750 değerleri ile segmentasyon başarımı açısından öne çıkarken; gerçek zamanlı uygulamalara uygunluğu açısından dikkat çekmiştir. Benzer şekilde, bina düzeyinde sınıflandırma açısından değerlendirildiğinde, Xception mimarisi %93,9 doğruluk ve %83,8 F1-skor değerleriyle literatürdeki birçok derin model ile kıyaslandığında üstün performans ortaya koymuştur.

Literatürde önerilen yöntemlerden, BDANet (Levir-CD) modeli DSC ve IoU başarımıyla oldukça yüksek performans sergilemişken, bu tezde önerilen Deep&MobileNetV2 ve Deep&ResNet50 mimarileri bu seviyeye yaklaşmaktadır. Ayrıca, MobileNetV2 mimarisi, düşük hesaplama karmaşıklığı ile BDANet gibi daha yüksek parametrelili modellere göre pratik uygulamalarda avantaj sağlamaktadır.

Tüm modeller arasında, doğruluk ve duyarlılık açısından dengeli sonuçlar veren mimariler, özellikle sınıf dengesizliğinin belirgin olduğu yıkım sınıfında yüksek duyarlılık değerleri ile afet sonrası haritalama için güvenilirlik sunmaktadır. Buna karşılık, literatürde bazı yaklaşımlarda yüksek DSC ve IoU değerlerine rağmen, hesaplama verimliliğine dair veri sunulmaması, bu tezdeki modellerin bütüncül değerlendirmeye olanak tanıyan yönünü öne çıkarmaktadır.

xBD veri seti kapsamında bina poligonlarının (vektör tabanlı bina ayak izlerinin) kullanılması, hem model doğruluğunu artırmak hem de bina düzeyinde yapılan hasar sınıflandırmalarını daha güvenilir ve anlamlı kılmak açısından önemli avantajlar sağlamıştır. Segmentasyon çıktılarının, afet öncesine ait bina poligonları ile karşılaştırılması, sadece piksel düzeyinde değil, her bina için bütüncül bir hasar sınıflandırması yapılmasına olanak sağlamıştır. Bu sayede, her binaya ait ortalama

hasar seviyesi belirlenebilmiş ve analizler daha anlamlı hale gelmiştir. Coğrafi koordinatlarla eşleşen poligonlar, modelin çıktılarının konumsal olarak doğrulanmasını ve bina sınırları içindeki sınıflandırma hatalarının azaltılmasını sağlamıştır. Bu durum özellikle hak sahipliği gibi konumsal tutarlılık gerektiren süreçlerde kritik önem taşımaktadır. Her bina poligonu için görüntü verilerinden elde edilen ortalama spektral değerler gibi öznitelikler, makine öğrenimi modellerinde sınıflar arası ayrımın artırılmasına katkı sağlamıştır. Bu yöntem sayesinde, hasarlı ve hasarsız binalar arasında istatistiksel anlamda belirgin farklar ortaya konulabilmektedir. Poligonlar, görsel harita arayüzlerinde segmentasyon sonuçlarının katmanlı olarak sunulmasına imkân tanımış ve karar vericiler için daha sezgisel analiz ortamları oluşturmuştur.

Sonuç olarak, bu çalışma kapsamında geliştirilen derin öğrenme tabanlı modeller, afet sonrası yapı hasarlarının tespiti ve haritalanmasına yönelik olarak hem semantik segmentasyon hem de bina düzeyinde sınıflandırma görevlerinde yüksek doğruluk ve hesaplama verimliliği sergilemiştir. Klasik başarı ölçütlerinde elde edilen üstün performanslara ek olarak, önerilen yöntemlerin düşük hesaplama maliyetleri sayesinde, mevcut literatürdeki çözümlerle karşılaştırıldığında pratik uygulamalara uygun, hızlı ve güvenilir alternatifler sunduğu ortaya konmuştur.

5.2 Öneriler

Tez kapsamında, afet sonrası yapı hasarlarının tespiti amacıyla derin öğrenme tabanlı semantik segmentasyon yöntemleri kullanılmış ve farklı omurga mimarilerin performansları karşılaştırmalı olarak analiz edilmiştir. Ancak çalışma bazı kısıtlamaları da beraberinde getirmektedir. Bu kısıtlamalar doğrultusunda ileriki çalışmalara ışık tutmak üzere belirlenen öneriler aşağıda listelenmiştir.

- Kullanılan veri kümeleri belirli afet türleri (deprem, kasırga v.b.) ve coğrafi bölgelerle sınırlı olup, önerilen modellerin diğer afet türleri ve farklı bölgelere doğrudan genellenebilirliği sınırlı kalmıştır. Ayrıca, sınıf dengesizliği ve karmaşık enkaz yapıları, özellikle yıkılmış binaların tespiti açısından model performansını olumsuz yönde etkilemiştir. Gerçek zamanlı uygulamalarda

ihtiyaç duyulan işlem süresi ve donanım gereksinimleri de göz ardı edilmemesi gereken diğer önemli sınırlamalar arasında yer almaktadır.

- Hasarlı ve hasarsız yapıların doğru sınıflandırılabilmesi için, farklı coğrafi bölgelerden ve çeşitli afet türlerinden toplanan görüntülerin dahil edildiği daha geniş ve çeşitlendirilmiş veri kümeleri kullanılmalıdır. Bu, modelin genelleme yeteneğini artıracak ve farklı sahalarda uygulanabilirliğini güçlendirecektir. Yükseklik verileri, arazi örtüsü haritaları, tarihsel veriler ve bina kullanım bilgileri gibi tamamlayıcı veri kaynaklarının entegrasyonu, makine öğrenimi modellerinin sınıflandırma doğruluğunu artırmada değerlendirilebilir.
- Gelecek çalışmalarda, daha geniş ve dengeli veri setleri oluşturularak, model başarımının artırılması hedeflenmektedir. Özellikle eğik (oblique) görüntülerin kullanılmasıyla bina cephelerindeki hasarların tespitine yönelik çalışmaların genişletilmesi, çok modlu veri kaynaklarının (örneğin LiDAR, DEM, SAR) entegre edilerek daha zengin özelliklerin çıkarılması önemli bir katkı sağlayacaktır. Ayrıca, model genellenebilirliğini artırmak amacıyla transfer öğrenme gibi ileri tekniklerin etkin kullanımı da gelecek çalışmalarda değerlendirilebilir. Bu kapsamda geliştirilecek hafif ve hızlı çalışan derin öğrenme modellerinin, afet yönetimi süreçlerine entegre edilerek sahada gerçek zamanlı karar destek sistemleri olarak kullanılması hedeflenmektedir.
- Model genelleme yeteneğinin artırılması, sınıf dengesizliği ve karmaşık enkaz yapıları nedeniyle gözlemlenen yanlış sınıflandırmaların azaltılması için çok zamanlı görüntü analizleri ve domain adaptation (alan uyarlaması) teknikleriyle desteklenmiş modelleri geliştirilebilir. Özellikle afet öncesi ve sonrası görüntü çiftlerinin kullanımı, zamansal farklılıkların daha etkin analiz edilmesine olanak sağlayacaktır.
- Hibrit model yaklaşımları, ESA tabanlı mimarilerin transformer tabanlı yaklaşımlar ile birleştirilmesi veya çok modlu (multi-modal) öğrenme

stratejilerinin uygulanması, yapı hasar tespiti görevlerinde hem mekânsal hem de bağlamsal bilgilerin daha etkin kullanılmasını mümkün kılabilir.

- Gerçek zamanlı uygulamalar için model hafifletme, MobileNetV2 gibi düşük parametrelili mimarilerin daha fazla optimize edilmesiyle, sınırlı kaynaklara sahip mobil cihazlar veya İHA sistemlerinde gerçek zamanlı hasar tespit uygulamaları geliştirilebilir. Bu doğrultuda kuantizasyon, budama (pruning) ve bilgi sıkıştırma (knowledge distillation) gibi model sıkıştırma teknikleri uygulanabilir.
- Yanlış sınıflandırma analizi, modellerin başarısız olduğu örneklerin sistematik olarak analiz edilmesi, özellikle ‘yıkılmış’ sınıfında enkaz-toprak benzerliğinin neden olduğu karışıklıkları azaltmak için özellik mühendisliği veya sınıfa özgü veri artırma stratejilerinin geliştirilmesine ışık tutabilir.
- Çalışma kapsamında geliştirilen yöntem ve yaklaşımlar, yalnızca doğal afetler sonrası yapı hasarlarının tespitiyle sınırlı kalmayıp; savaş, terör saldırısı ve diğer insan kaynaklı felaket senaryolarında meydana gelebilecek yapısal yıkımların analizinde de uygulanabilir niteliktedir. Dolayısıyla önerilen sistem, afet ve kriz yönetimi kapsamında geniş bir kullanım yelpazesi sunmaktadır.
- CBS entegrasyonu ile karar destek sistemleri, uzaktan algılama temelli hasar tespit çıktılarının, CBS ile entegre edilmesi; kullanıcı dostu, görsel analiz destekli ve müdahale önceliklendirmesini sağlayan interaktif platformların oluşturulmasına katkı sağlayacaktır.
- Bu çalışma kapsamında geliştirilen derin öğrenme tabanlı hasar tespit mimarilerinin saha uygulamalarında etkinliğinin artırılabilmesi için, mevcut kurumsal veri altyapıları ile entegrasyonun sağlanması büyük önem arz etmektedir. Özellikle, Mekânsal Adres Kayıt Sistemi (MAKS) ile afet yönetimi sistemleri arasında coğrafi veri uyumluluğunun tesis edilmesi, hasar tespit süreçlerinin doğruluğu ve operasyonel karar destek sistemlerinin verimliliği

açısından kritik bir gerekliliktir. Kahramanmaraş merkezli depremlerden sonra yaşanan deneyimler, hasar tespitine ilişkin koordinat bilgilerinin MAKS ile örtüşmemesi durumunda hak sahipliği belirleme, müdahale planlaması ve kaynak tahsisi süreçlerinde ciddi sistemsel aksamalara yol açtığını göstermiştir. Bu doğrultuda, afet sonrası yapı hasar tespit sürecinin dijitalleştirilmesi ve bütünleşik bir bilgi yönetimi altyapısı oluşturulabilir. Bu öneri çerçevesinde: MAKS Uyumlu Web Tabanlı Hasar Yönetim Sistemi adında, ilk aşamada, MAKS koordinat sistemine entegre çalışan bir web tabanlı hasar yönetim portalı geliştirilebilir. Bu sistem üzerinden kamu kurumları tarafından sağlanan yüksek çözünürlüklü drone ve uydu görüntüleri, coğrafi referanslı olarak sisteme yüklenebilir. Yüklenen bu görüntüler, tez kapsamında önerilen DeepLabV3+ tabanlı semantik segmentasyon modelleriyle otomatik olarak analiz edilerek, bina ölçeğinde hasar sınıflandırmaları üretilebilir. Elde edilen sonuçlar, CBS tabanlı katmanlı harita arayüzleriyle görselleştirilerek karar vericilere operasyonel planlama desteği sağlamalıdır. Sürece vatandaş katkısının artırılması için, e-Devlet altyapısına entegre çalışan ve kimlik doğrulaması üzerinden erişilebilen bir Mobil Vatandaş Hasar Bildirim Uygulaması geliştirilebilir. Bu uygulama aracılığıyla kullanıcılar, yalnızca ikamet ettikleri adreslere ilişkin iç ve dış mekân görüntülerini (fotoğraf veya video) çekerek, anlık GPS koordinatları ile birlikte sisteme yükleyebilmelidir. MAKS veri yapısıyla eşleştirilecek bu içerikler, kamu kaynaklı drone/uydu görüntüleri ile birlikte analiz edilerek hasar değerlendirmesinin çok kaynaklı veri üzerinden gerçekleştirilmesine olanak tanıyacaktır. Özellikle dış cephesinden hasarsız görünen yapıların, iç mekânda hasar barındırma olasılığına karşı, zemin ve bodrum katlarla sınırlı kalmayan, tüm katlardan veri toplanabilmesi sağlanmalıdır. Bu amaçla, yapı içerisine yönlendirilebilecek otonom ya da yarı otonom robotik kat bazlı görüntüleme sistemleri aracılığıyla, taşıyıcı sistem elemanlarının bütün katlarda görüntülenmesi ve derin öğrenme mimarileri ile analiz edilmesi önerilmektedir.

- Gerek kamu kurumları gerekse bireysel kullanıcılar ve otonom sistemlerden elde edilen görüntülerin, tekil MAKS adres kimliği ile eşlenerek merkezi bir veri havuzunda bütünleştirilebilir. Bu yaklaşım, afet sonrası müdahale

planlamalarının hızlandırılmasını, hak sahipliği tespitlerinin dijital olarak doğrulanmasını ve kaynakların etkin tahsisini mümkün kılacaktır. Sonuç olarak, bu önerilen bütünleşik sistem mimarisi; yapay zekâ destekli otomatik hasar tespiti yaklaşımlarının saha ölçeğinde uygulanabilirliğini artırabilecek, afet yönetimi süreçlerine dijital dönüşüm perspektifinden doğrudan katkı sağlayacaktır. Sistem; çok kaynaklı veri entegrasyonu, vatandaş katılımı, kurumsal CBS altyapısı ve derin öğrenme temelli analizlerin bütüncül biçimde senkronize edildiği yeni nesil bir karar destek yapısını temsil edebilecektir.

- Kahramanmaraş depremi sonrası oluşturulan veri seti üzerinde yürütülecek gelecekteki çalışmalarda, bina poligonlarının doğrudan kullanılması, hem model performansı hem de karar destek sistemlerinin doğruluğu açısından önemli avantajlar sağlayacaktır. Özellikle semantik segmentasyon çıktılarının afet öncesine ait bina poligonları ile karşılaştırılması, piksel düzeyinde elde edilen hasar tespit sonuçlarının bina bazında bütünleştirilmesine olanak tanımakta olup, bu durumda her bir yapı için ortalama hasar skorları üretilebilmekte ve sınıflandırma kararları, mekânsal tutarlılığı yüksek, bağlamsal olarak doğrulanabilir bir biçimde yapılabilmektedir. Ayrıca, bina poligonları aracılığıyla görsel özniteliklerin doğrudan çıkarılması, makine öğrenimi algoritmalarının sınıflar arası ayırt ediciliğini artırmakta; böylece ‘hasarlı’ ve ‘hasarsız’ yapı ayrımı daha hassas bir biçimde gerçekleştirilebilmektedir. Bu yöntemin, hem bina düzeyinde doğruluk metriklerinin iyileştirilmesine hem de CBS tabanlı hasar haritalarının daha sezgisel ve güvenilir biçimde sunulmasına katkı sunması beklenmektedir.

KAYNAKLAR

- [1] S. Cotrufo, C. Sandu, F. G. Tonolo and P. Boccoardo, "Building damage assessment scale tailored to remote sensing vertical imagery", *European Journal of Remote Sensing*, cilt 51, sayı 1, ss. 991–1005, 2018, doi: 10.1080/22797254.2018.1527662.
- [2] D. Kim, J. Won, E. Lee, K. R. Park, J. Kim, S. Park, H. Yang, and M. Cha, "Disaster assessment using computer vision and satellite imagery: Applications in detecting water-related building damages", *Front. Environ. Sci.*, vol. 10, 2022, doi:10.3389/fenvs.2022.969758
- [3] Y. Shen, S. Zhu, T. Yang, C. Chen, D. Pan, J. Chen, L. Xiao and Q. Du, "BDANet: Multiscale convolutional neural network with cross-directional attention for building damage assessment from satellite images", *IEEE Transactions on Geoscience and Remote Sensing*, cilt 60, ss. 1–14, 2021, doi: 10.1109/TGRS.2021.3080580.
- [4] N. Kaur, C. Lee, A. Mostafavi and A. Mahdavi-Amiri, "Large-scale building damage assessment using a novel hierarchical transformer architecture on satellite images", *Computer-Aided Civil and Infrastructure Engineering*, cilt 38, ss. 2072–2091, 2022, doi: 10.1111/mice.12981.
- [5] C. Wang, Y. Zhang, T. Xie, L. Guo, S. Chen, J. Li and F. Shi, "A detection method for collapsed buildings combining post-earthquake high-resolution optical and synthetic aperture radar images", *Remote Sensing*, cilt 14, sayı 5, s. 1100, 2022, doi: 10.3390/rs14051100.
- [6] X. Jiang, Y. He, G. Li, Y. Liu and X. Zhang, "Building damage detection via superpixel-based belief fusion of space-borne SAR and optical images", *IEEE Sensors Journal*, cilt 20, ss. 2008–2022, 2020, doi: 10.1109/JSEN.2019.2948582.
- [7] Q. D. Cao and Y. Choe, "Building damage annotation on post-hurricane satellite imagery based on convolutional neural network", *Natural Hazards*, ss. 1–20, 2018, doi: 10.1007/s11069-020-04133-2.
- [8] D. McNamara, W. Mell and A. Maranghides, "Object-based post-fire aerial image classification for building damage, destruction and defensive actions at the 2012 Colorado Waldo Canyon Fire", *International Journal of Wildland Fire*, cilt 29, sayı 2, ss. 174–189, 2020, doi: 10.1071/WF19041.
- [9] Q. Chen, H. Yang, L. Li and X. Liu, "A novel statistical texture feature for sar building damage assessment in different polarization modes", *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, cilt 13, ss. 154–165, 2020, doi: 10.1109/JSTARS.2019.2954292.
- [10] J. Tu, D. Li, W. Feng, Q. Han and H. Sui, "Detecting damaged building regions based on semantic scene change from multi-temporal high-resolution remote sensing images", *ISPRS International Journal of Geo-Information*, cilt 6, sayı 5, s. 131, 2017, doi: 10.3390/ijgi6050131.

- [11] L. Jun and L. Pei, "Extraction of earthquake-induced collapsed buildings from bi-temporal VHR images using object-level homogeneity index and histogram", *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, cilt 12, ss. 2755–2770, 2019, doi: 10.1109/JSTARS.2019.2904670.
- [12] Z. Zhou, J. Gong and X. Hu, "Community-scale multi-level post-hurricane damage assessment of residential buildings using multi-temporal airborne LiDAR data", *Automation in Construction*, cilt 98, ss. 30–45, 2019, doi: 10.1016/j.autcon.2018.10.018.
- [13] H. Gokon and S. Koshimura, "Mapping of building damage of the 2011 Tohoku earthquake tsunami in Miyagi prefecture", *Coastal Engineering Journal*, cilt 54, sayı 1, ss. 1250006-1–1250006-12, 2012, doi: 10.1142/S0578563412500064.
- [14] G. Novikov, A. Trekin, G. Potapov, V. Ignatiev and E. Burnaev, "Satellite imagery analysis for operational damage assessment in emergency situations", *International Conference on Business Information Systems, Proceedings*, ss. 347–358, Springer, 2018, doi: 10.1007/978-3-319-93931-5_25.
- [15] W. Zheng, D. Hu and J. Wang, "Fault localization analysis based on deep neural network", *Mathematical Problems in Engineering*, cilt 2016, ss. 1–11, 2016, doi: 10.1155/2016/1820454.
- [16] R. Gupta and M. Shah, "RescueNet: Joint building segmentation and damage assessment from satellite imagery", *2020 25th International Conference on Pattern Recognition (ICPR)*, ss. 4405–4411, 2020, doi: 10.1109/ICPR48806.2021.9412295.
- [17] H. Hao, S. Baireddy, E. R. Bartusiak, L. Konz, K. LaTourette, M. Gribbons, M. Chan, E. J. Delp and M. L. Comer, "An attention-based system for damage assessment using satellite imagery", *2021 IEEE International Geoscience and Remote Sensing Symposium IGARSS*, Brüksel, Belçika, ss. 4396–4399, 2021, doi: 10.1109/IGARSS47720.2021.9554054.
- [18] H. Xia, J. Wu, J. Yao, H. Zhu, A. Gong, J. Yang, L. Hu and F. Mo, "A Deep Learning Application for Building Damage Assessment Using Ultra-High-Resolution Remote Sensing Imagery in Turkey Earthquake", *International Journal of Disaster Risk Science*, cilt 14, ss. 947–962, 2023, doi: 10.1007/s13753-023-00526-6.
- [19] E. Weber and H. Kané, "Building disaster damage assessment in satellite imagery with multi-temporal fusion", *ArXiv*, abs/2004.05525, 2020, doi: 10.48550/arXiv.2004.05525.
- [20] G. Abdi, M. Esfandiari and S. Jabari, "A deep transfer learning-based damage assessment on post-event very high-resolution orthophotos", *Geomatica*, 2022, doi: 10.1139/geomat-2021-0014.
- [21] Y. Zhang, G. Yang, A. Gao, W. Lv, R. Xie, M. Huang and S. Liu, "An efficient change detection method for disaster-affected buildings based on a lightweight residual block in high-resolution remote sensing images", *International Journal of Remote Sensing*, cilt 44, sayı 9, ss. 2959–2981, 2023, doi:

10.1080/01431161.2023.2214274.

- [22] L. Yang, H. Huang, S. Kong and Y. Liu, "A deep segmentation network for crack detection with progressive and hierarchical context fusion", *Journal of Building Engineering*, cilt 75, s. 106886, 2023, doi: 10.1016/j.jobbe.2023.106886.
- [23] J. König, M. D. Jenkins, M. Mannion, P. Barrie and G. Morison, "Optimized deep encoder-decoder methods for crack segmentation", *Digital Signal Processing*, cilt 108, s. 102907, 2021, doi: 10.1016/j.dsp.2020.102907.
- [24] W. Wang, C. Su, G. Han and H. Zhang, "A lightweight crack segmentation network based on knowledge distillation", *Journal of Building Engineering*, cilt 76, s. 107200, 2023, doi: 10.1016/j.jobbe.2023.107200.
- [25] A. M. A. Talab, Z. Huang, F. Xi and L. Haiming, "Detection crack in image using Otsu method and multiple filtering in image processing techniques", *Optik - International Journal for Light and Electron Optics*, cilt 127, sayı 1, ss. 1–4, 2015, doi: 10.1016/j.ijleo.2015.09.147.
- [26] P. Chun, S. Izumi and T. Yamane, "Automatic detection method of cracks from concrete surface imagery using two-step light gradient boosting machine", *Computer-Aided Civil and Infrastructure Engineering*, cilt 36, sayı 1, ss. 61–72, 2020, doi: 10.1111/mice.12564.
- [27] Q. Zou, Y. Cao, Q. Li, Q. Mao and S. Wang, "CrackTree: Automatic crack detection from pavement images", *Pattern Recognition Letters*, cilt 33, sayı 3, ss. 227–238, 2012, doi: 10.1016/j.patrec.2011.11.004.
- [28] Y. Zhang, L. Yang, Y. Zhang and Z. Dong, "A review of deep learning-based crack detection approaches", *Measurement*, vol. 187, Art. no. 110280, 2022, doi: 10.1016/j.measurement.2021.110280.
- [29] L. Song, H. Sun, J. Liu, Z. Yu and C. Cui, "Automatic segmentation and quantification of global cracks in concrete structures based on deep learning", *Measurement*, cilt 199, Haziran 2022, doi: 10.1016/j.measurement.2022.111550.
- [30] R. Pu, G. Ren, H. Li, W. Jiang, J. Zhang and H. Qin, "Autonomous concrete crack semantic segmentation using deep fully convolutional encoder–decoder network in concrete structures inspection", *Buildings*, cilt 12, sayı 11, 2022, doi: 10.3390/buildings12112019.
- [31] K. Makantasis, E. Protopapadakis, A. Doulamis, N. Doulamis and C. Loupos, "Deep convolutional neural networks for efficient vision based tunnel inspection", *Proc. - 2015 IEEE 11th Int. Conf. Intell. Comput. Commun. Process. ICCP 2015*, ss. 335–342, 2015, doi: 10.1109/ICCP.2015.7312681.
- [32] F. Bahreini and A. Hammad, "Dynamic graph CNN based semantic segmentation of concrete defects and as-inspected modeling", *Automation in Construction*, c. 159, s. 105282, 2024, doi: 10.1016/j.autcon.2024.105282.
- [33] H. Li, H. Zhang, H. Zhu, K. Gao, H. Liang and J. Yang, "Automatic crack

detection on concrete and asphalt surfaces using semantic segmentation network with hierarchical transformer", *Engineering Structures*, c. 307, s. 117903, 2024, doi: 10.1016/j.engstruct.2024.117903.

- [34] W. Qayyum, R. Ehtisham, A. Bahrami, C. Camp, J. Mir and A. Ahmad, "Assessment of convolutional neural network pre-trained models for detection and orientation of cracks", *Materials*, c. 16, s. 826, 2023, doi: 10.3390/ma16020826.
- [35] Y. J. Cha, W. Choi, G. Suh, S. Mahmoudkhani and O. Büyüköztürk, "Autonomous structural visual inspection using region-based deep learning for detecting multiple damage types", *Computer-Aided Civil and Infrastructure Engineering*, c. 33, s. 731–747, 2018, doi: 10.1111/mice.12334.
- [36] F. Panella, A. Lipani, and J. Boehm, "Semantic segmentation of cracks: Data challenges and architecture", *Automation in Construction*, vol. 135, no. December 2021, p. 104110, 2022, doi: 10.1016/j.autcon.2021.104110.
- [37] M. Jamshidi, M. El-Badry, and N. Nourian, "Improving concrete crack segmentation networks through CutMix data synthesis and temporal data fusion", *Sensors*, vol. 23, no. 1, 2023, doi: 10.3390/s23010504.
- [38] H. Polat, S. Alpergin ve M. S. Özerdem, "Beton çatlakların derin öğrenme tabanlı semantik segmentasyonunda kodlayıcı değişkenlerinin karşılaştırmalı analizi", *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, c. 15, sy. 3, ss. 581–593, 2024, doi: 10.24012/dumf.1465724.
- [39] A. Vetrivel, M. Gerke, N. Kerle, F. C. Nex ve G. Vosselman, "Disaster damage detection through synergistic use of deep learning and 3D point cloud features derived from very high resolution oblique aerial images, and Multiple-Kernel-Learning", *ISPRS Journal of Photogrammetry and Remote Sensing*, c. 140, ss. 45–59, 2018, doi: 10.1016/j.isprsjprs.2017.03.001.
- [40] W. Qiao, L. Shen, Q. Wen, S. Tang and Z. Li, "Revolutionizing building damage detection: A novel weakly supervised approach using high-resolution remote sensing images", *International Journal of Digital Earth*, c. 17, s. 1, 2024, doi: 10.1080/17538947.2023.2298245.
- [41] X. Han, Z. Zhao, L. Chen, X. Hu, Y. Tian, C. Zhai, L. Wang and X. Huang, "Structural damage-causing concrete cracking detection based on a deep-learning method", *Construction and Building Materials*, c. 337, 27 Haziran 2022, s. 127562, doi: 10.1016/j.conbuildmat.2022.127562.
- [42] Y. Bai, H. Sezen, and A. Yilmaz, "End-to-End Deep Learning Methods for automated damage detection in extreme events at various scales", *Proc. - Int. Conf. Pattern Recognit.*, no. c, pp. 5736–5743, 2020, doi: 10.1109/ICPR48806.2021.9413041.
- [43] J. Deng, A. Singh, Y. Zhou, Y. Lu and V. C.-S. Lee, "Review on computer vision-based crack detection and quantification methodologies for civil structures", *Construction and Building Materials*, vol. 356, p. 129238, Nov. 2022, doi: 10.1016/j.conbuildmat.2022.129238.

- [44] Ö. Kaya, "Comparative Analysis Of Multiple Machine Learning Algorithms For Post-Earthquake Building Damage Assessment in Hatay City Following The 2023 Earthquake", Yüksek Lisans Tezi, Middle East Technical University, 2024.
- [45] Y. Bai, B. Adriano, E. Mas and S. Koshimura, "Building damage assessment in the 2015 Gorkha, Nepal, earthquake using only postevent dual polarization synthetic aperture radar imagery", *Earthquake Spectra*, c. 33, ss. 185–195, 2017, doi: 10.1193/121516EQS232M.
- [46] N. Khodaverdi, H. Rastiveis and A. Jouybari, "Combination of post-earthquake LiDAR data and satellite imagery for buildings damage detection", *Earth Observation and Geomatics Engineering*, vol. 3, no. 1, pp. 12–20, 2019, doi: 10.22059/eoge.2019.278307.1046.
- [47] A. Rao, J. Jung, V. Silva, G. Molinario and S. H. Yun, "Earthquake building damage detection based on Synthetic-Aperture-Radar imagery and machine learning", *Natural Hazards and Earth System Sciences*, vol. 23, no. 2, pp. 789–807, 2023, doi: 10.5194/nhess-23-789-2023.
- [48] M. Hajeb, S. Karimzadeh and M. Matsuoka, "SAR and LiDAR datasets for building damage evaluation based on support Vector Machine and Random Forest Algorithms—A case study of Kumamoto Earthquake, Japan", *Applied Sciences*, vol. 10, no. 24, p. 8932, 2020, doi: 10.3390/app10248932.
- [49] N. Takhtkeshha, A. Mohammadzadeh and B. Salehi, "A rapid self-supervised deep-learning-based method for post-earthquake damage detection using UAV data (Case Study: Sarpol-e Zahab, Iran)", *Remote Sensing*, vol. 15, no. 1, p. 123, 2023, doi: 10.3390/rs15010123.
- [50] P. V. Mittal, R. Bafna and A. Mittal, "Unsupervised learning framework for region-based damage assessment on xBD, a large satellite imagery", *Natural Hazards*, vol. 118, pp. 1619–1643, 2023, doi: 10.1007/s11069-023-06074-y.
- [51] S. Karimzadeh, M. Ghasemi, M. Matsuoka, K. Yagi and A. C. Zulfikar, "A deep learning model for road damage detection after an earthquake based on Synthetic Aperture Radar (SAR) and field datasets", *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 15, pp. 5753–5765, 2022, doi: 10.1109/JSTARS.2022.3189875.
- [52] W. Yang, X. Zhang and P. Luo, "Transferability of convolutional neural network models for identifying damaged buildings due to earthquake", *Remote Sensing*, vol. 13, no. 3, p. 504, 2021, doi: 10.3390/rs13030504.
- [53] E. E. Maraş and H. İ. Sarıyıldız, "Detection of damaged structures using deep learning algorithms with UAV", *Afyon Kocatepe University Journal of Science and Engineering*, vol. 23, no. 2, pp. 427–437, 2023, doi: 10.35414/akufemubid.1171393.
- [54] U. M. Bhangale, S. S. Durbha, A. V. Potnis and R. C. Shinde, "Rapid earthquake damage detection using deep learning from VHR remote sensing images", in *2019 IEEE International Geoscience and Remote Sensing*

Symposium (IGARSS), Yokohama, Japan, 2019, pp. 2654–2657, doi: 10.1109/IGARSS.2019.8898147.

- [55] F. Nex, D. Duarte, A. Steenbeek and N. Kerle, "Towards real-time building damage mapping with low-cost UAV Solutions", *Remote Sensing*, vol. 11, no. 3, p. 287, 2019, doi: 10.3390/rs11030287.
- [56] H. Ma, Y. Liu, Y. Ren, D. Wang, L. Yu and J. Yu, "Improved CNN classification method for groups of buildings damaged by earthquake, based on high resolution remote sensing images", *Remote Sensing*, vol. 12, no. 2, p. 260, 2020, doi: 10.3390/rs12020260.
- [57] L. Deng and Y. Wang, "Post-disaster building damage assessment based on improved U-Net", *Scientific Reports*, vol. 12, p. 15862, 2022, doi: 10.1038/s41598-022-20114-w.
- [58] S. A. Ahmadi, A. Mohammadzadeh, N. Yokoya and A. Ghorbanian, "BD-SKUNet: Selective-Kernel UNets for building damage assessment in high-resolution satellite images", *Remote Sensing*, vol. 16, no. 1, p. 182, 2024, doi: 10.3390/rs16010182.
- [59] Y. Xie, D. Feng, H. Chen, Z. Liu, W. Mao, J. Zhu, Y. Hu and S. W. Baik, "Damaged building detection from post-earthquake remote sensing imagery considering heterogeneity characteristics", *IEEE Transactions on Geoscience and Remote Sensing*, vol. 60, pp. 1–17, 2022, doi: 10.1109/TGRS.2022.3200872.
- [60] Y. Qing, D. Ming, Q. Wen, Q. Weng, L. Xu, Y. Chen, Y. Zhang and B. Zeng, "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*, vol. 112, Article 102899, 2022, doi: 10.1016/j.jag.2022.102899.
- [61] J. Mei, Y. B. Zheng and M. M. Cheng, "D2ANet: Difference-aware attention network for multi-level change detection from satellite imagery", *Computational Visual Media*, vol. 9, no. 3, pp. 563–579, 2023, doi: 10.1007/s41095-022-0325-1.
- [62] C. Wu, F. Zhang, J. Xia, Y. Xu, G. Li, J. Xie, Z. Du and R. Liu, "Building damage detection using U-Net with attention mechanism from pre- and post-disaster remote sensing datasets", *Remote Sensing*, vol. 13, no. 5, p. 905, 2021, doi: 10.3390/rs13050905.
- [63] A. S. Gupta, S. Watson and H. Yin, "Deep Learning-based aerial image segmentation with open data for disaster impact assessment", *arXiv preprint arXiv:2006.05575*, 2020. doi: 10.1016/j.neucom.2020.02.139.
- [64] M. Moradi and R. Shah-Hosseini, "Earthquake damage assessment based on deep learning method using VHR images", *Environ. Sci. Proc.*, vol. 5, p. 16, 2021, doi: 10.3390/IECG2020-08545.
- [65] H. Miura, T. Aridome and M. Matsuoka, "Deep learning-based identification of

- collapsed, non-collapsed and blue tarp-covered buildings from post-disaster aerial images", *Remote Sensing*, vol. 12, 2020, doi: 10.3390/rs12121924.
- [66] T. Çarkıt, "Post-earthquake rapid damage determination from satellite photos using image processing techniques: Case study on Hatay Antakya", *Current Debates on Natural and Engineering Sciences*, 2023.
- [67] Y. Li, W. Hu, H. Dong and X. Zhang, "Building damage detection from post-event aerial imagery using single Shot Multibox Detector", *Applied Sciences*, vol. 9, no. 6, p. 1128, 2019, doi: 10.3390/app9061128.
- [68] L. Shi, F. Zhang, J. Xia, J. Xie, Z. Zhang, Z. Du and R. Liu, "Identifying damaged buildings in aerial images using the object detection method", *Remote Sensing*, vol. 13, no. 21, p. 4213, 2021, doi: 10.3390/rs13214213.
- [69] L. Shi, F. Zhang, J. Xia and J. Xie, "Scene-level buildings damage recognition based on Cross Conv-Transformer", *International Journal of Digital Earth*, vol. 16, no. 2, pp. 3987–4007, 2023, doi: 10.1080/17538947.2023.2261770.
- [70] Y. Hu and H. Tang, "On the generalization ability of a global model for rapid building mapping from heterogeneous satellite images of multiple natural disaster scenarios", *Remote Sensing*, vol. 13, no. 5, p. 984, 2021, doi: 10.3390/rs13050984.
- [71] Y. Da, Z. Ji and Y. Zhou, "Building damage assessment based on Siamese Hierarchical Transformer Framework", *Mathematics*, vol. 10, no. 11, p. 1898, 2022, doi: 10.3390/math10111898.
- [72] H. Ma, Y. Liu, Y. Ren and J. Yu, "Detection of collapsed buildings in post-earthquake remote sensing images based on the improved YOLOv3," *Remote Sensing*, vol. 12, no. 1, p. 44, 2020, doi: 10.3390/rs12010044.
- [73] D. Duarte, F. Nex, N. Kerle and G. Vosselman, "Detection of seismic façade damages with multi-temporal oblique aerial imagery", *GIScience & Remote Sensing*, vol. 57, no. 5, pp. 670–686, 2020, doi: 10.1080/15481603.2020.1768768.
- [74] M. Kakooei and Y. Baleghi, "Fusion of vertical and oblique images using Intra-Cluster-Classification for building damage assessment", *Computers & Electrical Engineering*, vol. 105, p. 108536, 2023, doi: 10.1016/j.compeleceng.2022.108536.
- [75] J. Tu, H. Sui, W. Feng, and Q. Jia, "Detecting facade damage on moderate damaged type from high-resolution oblique aerial images", *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 10, no. 12, pp. 5598–5607, Dec. 2017, doi: 10.1109/JSTARS.2017.2750170.
- [76] A. Vetrivel, M. Gerke, N. Kerle and G. Vosselman, "Identification of structurally damaged areas in airborne oblique images using a Visual-Bag-of-Words Approach", *Remote Sensing*, vol. 8, no. 3, p. 231, 2016, doi: 10.3390/rs8030231.
- [77] O. Ronneberger, P. Fischer and T. Brox, "U-net: Convolutional networks for biomedical image segmentation", in *Lect. Notes Comput. Sci.*, vol. 9351, pp.

234–241, 2015, doi: 10.1007/978-3-319-24574-4_28.

- [78] V. Badrinarayanan, A. Kendall and R. Cipolla, "SegNet: A Deep Convolutional Encoder-Decoder Architecture for image segmentation", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 39, no. 12, pp. 2481–2495, Dec. 2017, doi: 10.1109/TPAMI.2016.2644615.
- [79] E. Shelhamer, J. Long and T. Darrell, "Fully Convolutional Networks for semantic segmentation", *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 39, no. 4, pp. 640–651, Apr. 2017, doi: 10.1109/TPAMI.2016.2572683.
- [80] L. C. Chen, Y. Zhu, G. Papandreou, F. Schroff, and H. Adam, "Encoder-decoder with atrous separable convolution for semantic image segmentation", *Lect. Notes Comput. Sci.* (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics), vol. 11211 LNCS, pp. 833–851, 2018, doi: 10.1007/978-3-030-01234-2_49.
- [81] Zhang, Y., Gao, X., and Zhang, H., "Deep Learning-Based semantic segmentation methods for pavement cracks", *Information*, vol. 14, no. 3, p. 182, 2023, doi: 10.3390/info14030182.
- [82] T. Lee, J. H. Kim, S. J. Lee, S. K. Ryu and B. C. Joo, "Improvement of concrete crack segmentation performance using Stacking Ensemble Learning", *Applied Sciences*, vol. 13, no. 4, 2023, doi: 10.3390/app13042367.
- [83] Z. Al-Huda, B. Peng, R. N. A. Algburi, M. A. Al-antari, R. Al-Jarazi, and D. Zhai, "A hybrid deep learning pavement crack semantic segmentation", *Engineering Applications of Artificial Intelligence*, vol. 122, p. 106142, 2023, doi: 10.1016/j.engappai.2023.106142.
- [84] A. N. Soni, "Crack detection in buildings using convolutional neural network", *Journal for Innovative Development in Pharmaceutical and Technical Science*, vol. 2, no. 6, pp. 54–59, Jun. 2019.
- [85] A. Liu, W. Hua, J. Xu, Z. Yang, and J. Fu, "Concrete crack segmentation based on multi-dimensional structure information fusion-based network", *Construction and Building Materials*, vol. 414, 2024, doi: 10.1016/j.conbuildmat.2024.134982.
- [86] H. Lang, Y. Yuan, J. Chen, S. Ding, J. J. Lu, and Y. Zhang, "Augmented concrete crack segmentation: Learning complete representation to defend background interference in concrete pavements", *IEEE Trans. Instrum. Meas.*, vol. 73, pp. 1–13, 2024, doi: 10.1109/TIM.2024.3378205.
- [87] Ç. F. Özgenel, "Crack detection with deep learning: An exemplary study of data design in architecture" Doktora Tezi, Middle East Technical University, Türkiye, 2018.
- [88] Ç. F. Özgenel and A. G. Sorguç, "Performance comparison of pretrained convolutional neural networks on crack detection in buildings", in *Proc. 35th Int. Symp. on Automation and Robotics in Construction (ISARC)*, Berlin, Germany, 2018, , pp. 693–700. doi: 10.22260/ISARC2018/0094.

- [89] Ç. F. Özgenel, “Concrete crack segmentation dataset”, *Mendeley Data*, V1, 2019, doi: 10.17632/jwsn7tfbrp.1.
- [90] M. Yilmaz, G. Dogan, M. H. Arslan and A. Ilki, “Categorization of post-earthquake damages in RC structural elements with deep learning approach”, *Journal of Earthquake Engineering*, vol. 28, no. 9, pp. 2620–2651, 2024. doi: 10.1080/13632469.2024.2302033
- [91] R. E. Cangür, “Evrişimli sinir ağları modellerinin betonarme yapılarda deprem hasarı sınıflandırması üzerinden karşılaştırılması: Kahramanmaraş örneği”, Yüksek lisans tezi, Yıldız Teknik Üniversitesi, Türkiye, 2024.
- [92] G. Ye, J. Qu, J. Tao, W. Dai, Y. Mao, and Q. Jin, “Autonomous surface crack identification of concrete structures based on the YOLOv7 algorithm”, *Journal of Building Engineering*, 2023, doi: 10.1016/j.jobbe.2023.106688.
- [93] M. D. Jenkins, T. A. Carr, M. I. Iglesias, T. Buggy and G. Morison, “A deep convolutional neural network for semantic pixel-wise segmentation of road and pavement surface cracks”, in *Proc. Eur. Signal Process. Conf. (EUSIPCO)*, 2018, pp. 2120–2124, doi: 10.23919/EUSIPCO.2018.8553280.
- [94] Z. Fan, C. Li, Y. Chen, P. D. Mascio, X. Chen, G. Zhu and G. Loprencipe, “Ensemble of deep convolutional neural networks for automatic pavement crack detection and measurement”, *Coatings*, vol. 10, no. 2, p. 152, 2020, doi: 10.3390/coatings10020152.
- [95] J. König, M. D. Jenkins, P. Barrie, M. Mannion and G. Morison, “A convolutional neural network for pavement surface crack segmentation using residual connections and attention gating”, in *Proc. IEEE Int. Conf. Image Process. (ICIP)*, 2019, pp. 1460–1464, doi: 10.1109/ICIP.2019.8803060.
- [96] M. G. Altun and A. H. Altun, “Beton yüzey çatlaklarının YOLOv8 derin öğrenme algoritması ile tespit edilmesi”, *Çukurova Üniversitesi Mühendislik Fakültesi Dergisi*, vol. 39, no. 3, pp. 667–678, 2024.
- [97] L. Ali, F. Alnajjar, H. A. Jassmi, M. Gocho, W. Khan, and M. A. Serhani, “Performance evaluation of deep CNN-based crack detection and localization techniques for concrete structures”, *Sensors*, vol. 21, no.5, p. 1688, 2021, doi: 10.3390/s21051688.
- [98] F. Fang, L. Li, Y. Gu, H. Zhu and J.-H. Lim, “A novel hybrid approach for crack detection”, *Pattern Recognition*, vol. 107, p. 107474, 2020, doi: 10.1016/j.patcog.2020.107474.
- [99] P. N. Hadinata, D. Simanta, L. Eddy and K. Nagai, “Crack detection on concrete surfaces using deep encoder-decoder convolutional neural network: A comparison study between U-Net and DeepLabV3+”, *Journal of the Civil Engineering Forum*, vol. 7, no. 3, p. 323, 2021, doi: 10.22146/jcef.65288.
- [100] P. Arafin, A. Issa and A. H. M. M. Billah, “Performance comparison of multiple convolutional neural networks for concrete defects classification”, *Sensors*, vol. 22, p. 8714, 2022. doi:10.3390/s22228714

- [101] M. M. Islam, M. B. Hossain, M. N. Akhtar, M. A. Moni and K. F. Hasan, “CNN based on transfer learning models using data augmentation and transformation for detection of concrete crack”, *Algorithms*, vol. 15, no. 8, p. 287, 2022, doi: 10.3390/a15080287.
- [102] İ. S. Üncü, M. Kayakuş, C. A. Yavru and N. İbadov, “Binalarda çatlak kontrolünde CNN tabanlı görüntü işleme ölçüm sisteminin kullanılması”, *GMBD*, vol. 9, no. 4, pp. 257–267, 2023.
- [103] C. Yang, J. Chen, Z. Li, and Y. Huang, “Structural crack detection and recognition based on deep learning”, *Appl. Sci.*, vol. 11, p. 2868, 2021, doi: 10.3390/app11062868.
- [104] M. Zeeshan, S. M. Adnan, W. Ahmad, and F. Z. Khan, “Structural crack detection and classification using deep convolutional neural network”, *Multidisciplinary & Peer Reviewed*, vol. 4, no. 4, pp. 50–56, 2021. doi: 10.51846/vol4iss4pp50-56
- [105] Y. Liu, J. Yao, X. Lu, R. Xie, and L. Li, “DeepCrack: A deep hierarchical feature learning architecture for crack segmentation”, *Neurocomputing*, vol. 338, pp. 139–153, 2019, doi: 10.1016/j.neucom.2019.01.036.
- [106] Y. Shi, L. Cui, Z. Qi, F. Meng, and Z. Chen, “Automatic road crack detection using random structured forests”, *IEEE Trans. Intell. Transp. Syst.*, vol. 17, no. 12, pp. 3434–3445, 2016, doi: 10.1109/TITS.2016.2552248.
- [107] B. Baheti, S. Innani, S. Gajre, and S. Talbar, “Semantic scene segmentation in unstructured environment with modified DeepLabV3+”, *Pattern Recognit. Lett.*, vol. 138, pp. 223–229, 2020, doi: 10.1016/j.patrec.2020.07.029.
- [108] T. Ahmad, V. Gharehbaghi, J. Li, C. Bennett, and R. Lequesne, “Crack segmentation in the wild using convolutional neural networks and bootstrapping”, *Earthq. Eng. Resil.*, vol. 2, no. 3, pp. 348–363, 2023, doi: 10.1002/eer2.52.
- [109] Jia Deng, Wei Dong, R. Socher, Li-Jia Li, Kai Li, and Li Fei-Fei, “ImageNet: A large-scale hierarchical image database”, pp. 248–255, 2009, doi: 10.1109/cvprw.2009.5206848.
- [110] K. He, X. Zhang, S. Ren, and J. Sun, “Deep residual learning for image recognition”, *Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit.*, vol. 2016-Decem, pp. 770–778, 2016, doi: 10.1109/CVPR.2016.90.
- [111] F. Chollet, “Xception: Deep learning with depthwise separable convolutions”, *Proc. - 30th IEEE Conf. Comput. Vis. Pattern Recognition*, CVPR 2017, vol. 2017-Janua, pp. 1800–1807, 2017, doi: 10.1109/CVPR.2017.195.
- [112] R. E. Philip, A. D. Andrushia, A. Nammalvar, B. G. A. Gurupatham, and K. Roy, “A Comparative Study on Crack Detection in Concrete Walls Using Transfer Learning Techniques”, *J. Compos. Sci.*, vol. 7, no. 4, 2023, doi: 10.3390/jcs7040169.

- [113] C. Szegedy, W. Liu, Y. Jia, P. Sermanet, S. Reed, D. Anguelov, D. Erhan, V. Vanhoucke, and A. Rabinovich, “Going deeper with convolutions”, in *Proc. IEEE Conf. Comput. Vis. Pattern Recognit.*, 2015, pp. 1–9, doi: 10.1109/CVPR.2015.7298594.
- [114] A. G. Howard, M. Zhu, B. Chen, D. Kalenichenko, W. Wang, T. Weyand, M. Andreetto, and H. Adam, “MobileNets: Efficient convolutional neural networks for mobile vision applications”, *arXiv preprint*, arXiv:1704.04861, 2017. doi: 10.48550/arXiv.1704.04861.
- [115] M. Sandler, A. Howard, M. Zhu, A. Zhmoginov, and L. C. Chen, “MobileNetV2: Inverted Residuals and Linear Bottlenecks”, *Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit.*, pp. 4510–4520, 2018, doi: 10.1109/CVPR.2018.00474.
- [116] C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens, and Z. Wojna, “Rethinking the Inception Architecture for Computer Vision”, *Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit.*, vol. 2016-Decem, pp. 2818–2826, 2016, doi: 10.1109/CVPR.2016.308.
- [117] K. He, X. Zhang, S. Ren, and J. Sun, “Spatial pyramid pooling in deep convolutional networks for visual recognition”, *Lect. Notes Comput. Sci.* (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics), vol. 8691 LNCS, no. PART 3, pp. 346–361, 2014, doi: 10.1007/978-3-319-10578-9_23.
- [118] D. Tabernik, M. Šuc, and D. Skočaj, “Automated detection and segmentation of cracks in concrete surfaces using joined segmentation and classification deep neural network”, *Constr. Build. Mater.*, vol. 408, no. September, p. 133582, 2023, doi: 10.1016/j.conbuildmat.2023.133582.
- [119] Harita Genel Müdürlüğü, “Ortofoto ürünleri,” 2024. [Online]. Available: <https://www.harita.gov.tr/urun/ortofoto/98> [Accessed: Mar. 5, 2024].
- [120] CBS, “CBS Atlas,” 2024. [Online]. Available: <https://cbs.csb.gov.tr/atlas-i-5439> [Accessed: Jan. 5, 2025].
- [121] R. Gupta, R. Hosfelt, S. Sajeve, N. Patel, B. Goodman, J. Doshi, E. Heim, H. Choset, and M. Gaston, “XBD: A dataset for assessing building damage from satellite imagery”, *arXiv preprint*, 2019. doi: 10.48550/arXiv.1911.09296.
- [122] R. Gupta, B. Goodman, N. Patel, R. Hosfelt, S. Sajeve, E. Heim, J. Doshi, K. Lucas, H. Choset, and M. Gaston, “Creating XBD: A dataset for assessing building damage from satellite imagery”, in *Proc. IEEE/CVF Conf. Comput. Vis. Pattern Recognit. Workshops*, Long Beach, CA, USA, Jun. 2019, pp. 10–17, doi: 10.48550/arXiv.1911.09296.

ÖZGEÇMİŞ

Kişisel Bilgiler

Soyad, Ad

ALPERGİN, Serhat

Web sayfası

(Research Gate, Academia, vs.)

Eğitim Bilgileri

Derece	Kurum	Mezuniyet Yılı
Yüksek Lisans	Dicle Üniversitesi	2025
Yüksek Lisans	Hacettepe Üniversitesi	2021
Lisans	Çukurova Üniversitesi	2008
Lise	Diyarbakır Anadolu Lisesi	2003

İş Deneyimi

Dönem (Yıl)	Şirket, Kurum	Görev
2008-2009	Türk Telekom Diyarbakır İl Müdürlüğü	Mühendis
2009-2012	Siirt Çevre, Şehircilik ve İklim Değ. İl Müdürlüğü	Mühendis-Şube Müdürü
2012-2023	Diyarbakır Çevre, Şehircilik ve İklim Değ. İl Müdürlüğü	Mühendis-Şube Müdürü- İl Müdür Yardımcısı
2023-Devam Ediyor	Diyarbakır Valiliği	İl Enerji Yöneticisi

Yabancı Dil

İngilizce

Yayınlar

1. H. Polat, S. Alpergin ve M. S. Özerdem, “Beton çatlakların derin öğrenme tabanlı semantik segmentasyonunda kodlayıcı değişkenlerinin karşılaştırmalı analizi”, DÜMF MD, c. 15, sy. 3, ss. 581–593, 2024, doi: 10.24012/dumf.1465724.

Özel İlgiler

DİCLE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
TEZ BENZERLİK BİLDİRİMİ FORMU

Öğrencinin Adı, Soyadı	Serhat ALPERGİN
Öğrenci No	09805402
Ana Bilim Dalı	Elektrik-Elektronik Mühendisliği Anabilim Dalı
Program Türü	Proje ☐ Yüksek Lisans ☒ Doktora ☐
Tez Danışmanı (Ünvanı, Adı, Soyadı)	Prof.Dr. Mehmet Sıraç ÖZERDEM
(Varsa) II. Tez Danışmanı (Ünvanı, Adı, Soyadı)	Doç.Dr. Hasan POLAT
Tez Başlığı	Afet Sonrası Yapı Hasarlarının Uzaktan Algılama Görüntüleri İle Semantik Segmentasyon Tabanlı Değerlendirilmesi
RAPOR BİLGİLERİ	
Raporlama Aşaması	Tez Savunma Sınavı Sonrası
Sayfa Sayısı	113
Raporlama Tarihi	25/06/2025
Benzerlik Oranı (%)	% 3

Yukarıda bilgileri verilen tez çalışmamın toplam 113 sayfalık kısmına ilişkin, 25/06/2025 tarihinde şahsım/tez danışmanım tarafından Turnitin isimli intihal tespit programından aşağıda belirtilen filtrelemeler uygulanarak alınmış olan intihal raporuna göre, tezimin benzerlik oranı % 3 olarak tespit edilmiştir.

Uygulanan filtrelemeler:

- ☐Başlangıç Bölümleri (Kabul ve Onay sayfası, Teşekkür sayfası, Özet/Abstract) hariç
☒Kaynaklar hariç
☐Alıntılar hariç/dâhil
☐Diğer (Açıklayınız)

Tezimin benzerlik oranı, Dicle Üniversitesi Fen Bilimleri Enstitüsü İntihal Raporu Uygulama Esaslarında belirtilen üst sınır benzerlik oranını aşmamaktadır. Tez benzerlik oranı üst sınır benzerlik oranının altında olsa dahi aksinin tespit edilmesi durumunda her türlü yasal sorumluluğu kabul ettiğimi ve hukuki sonuçlarına razı olduğumu bildirir, gereğini arz ederim.

Öğrencinin Adı, Soyadı: Serhat ALPERGİN

Tarih:

İmza:

Danışman Adı, Soyadı: Prof. Dr. Mehmet Sıraç ÖZERDEM

İmza:

Tarih:

Ana Bilim Dalı Başkanı Adı, Soyadı: Prof.Dr.M.Bahaddin KURT

İmza:

Tarih: