T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

DERİN ÖĞRENME TABANLI BÖLÜTLEME YÖNTEMLERİYLE DEPREM SONRASI UYDU GÖRÜNTÜLERİNDEN HASARLI BÖLGELERİN TESPİTİ: 6 ŞUBAT 2023 TÜRKİYE DEPREMLERİ ÖRNEĞİ

Mehmet Can EKKAZAN

YÜKSEK LISANS TEZİ
Bilgisayar Mühendisliği Anabilim Dalı
Bilgisayar Mühendisliği Programı

Danışman
Prof. Dr. Mine Elif KARSLIGİL

Temmuz, 2024

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

DERİN ÖĞRENME TABANLI BÖLÜTLEME YÖNTEMLERİYLE DEPREM SONRASI UYDU GÖRÜNTÜLERİNDEN HASARLI BÖLGELERİN TESPİTİ: 6 ŞUBAT 2023 TÜRKİYE DEPREMLERİ ÖRNEĞİ

Mehmet Can EKKAZAN tarafından hazırlanan tez çalışması 24.07.2024 tarihinde aşağıdaki jüri tarafından Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı Bilgisayar Mühendisliği Programı **YÜKSEK LISANS TEZİ** olarak kabul edilmiştir.

Prof. Dr. Mine Elif KARSLIGİL
Yıldız Teknik Üniversitesi
Danışman

Jüri Üyeleri

Prof. Dr. Mine Elif KARSLIGİL, Danışman
Yıldız Teknik Üniversitesi _____

Prof. Dr. Songül VARLI, Üye
Yıldız Teknik Üniversitesi _____

Prof. Dr. Yusuf Sinan AKGÜL, Üye
Gebze Teknik Üniversitesi _____

Danışmanım Prof. Dr. Mine Elif KARSLIGİL sorumluluğunda tarafımca hazırlanan Derin Öğrenme Tabanlı Bölütleme Yöntemleriyle Deprem Sonrası Uydu Görüntülerinden Hasarlı Bölgelerin Tespiti: 6 Şubat 2023 Türkiye Depremleri Örneği başlıklı çalışmada veri toplama ve veri kullanımında gerekli yasal izinleri aldığımı, diğer kaynaklardan aldığım bilgileri ana metin ve referanslarda eksiksiz gösterdiğimi, araştırma verilerine ve sonuçlarına ilişkin çarpıtma ve/veya sahtecilik yapmadığımı, çalışmam süresince bilimsel araştırma ve etik ilkelerine uygun davrandığımı beyan ederim. Beyanımın aksinin ispatı halinde her türlü yasal sonucu kabul ederim.

Mehmet Can EKKAZAN

İmza

Bu çalışma, “Yıldız Teknik Üniversitesi Bilimsel Araştırma Proje Koordinatörlüğü’nün FBA-2024-6117” numaralı projesi ile desteklenmiştir.

Aileme, arkadaşlarıma ve
depremlerdeki tüm kayıplarımıza adanmıştır..

TEŞEKKÜR

Öncelikle, saygıdeğer danışmanım Prof. Dr. Mine Elif KARSLIGİL'e en derin teşekkürlerimi sunmak istiyorum. Engin rehberliği ve paha biçilemez geri bildirimleri tez yolculuğumun temel taşı oldu.

Planet Labs'a, uydu görüntülerine erişim sağlayarak çalışmama değerli bir katkı sundukları için içtenlikle teşekkür ederim. Sağladıkları yüksek kaliteli veriler, araştırmamın başarısında kritik bir rol oynadı ve elde edilen sonuçların doğruluğunu ve güvenilirliğini artırdı. Verdikleri destek için minnettarım.

Annem Nurgül EKKAZAN ve babam Muhammer EKKAZAN'a sarsılmaz sevgi ve destekleri için en içten teşekkürlerimi sunuyorum. Bana olan inancınız benim en büyük motivasyon ve güç kaynağım oldu.

Kardeşim Hüseyin Cem EKKAZAN'a her daim yanımda olduğu için sonsuz minnettarlığımı sunuyorum.

Sevgili ablam Tuğçe GENÇ SELİMOĞLU'na araştırma sürecim boyunca gösterdiği sürekli teşvik ve değerli tavsiyeler için yürekten teşekkür ederim. Yeğenim Ali SELİMOĞLU'na hayatıma getirdiği neşe için minnettarım; kendisiyle geçirdiğim zamanlar akademik çabalarımın arasındaki en büyük enerji kaynağım oldu.

Bu tez, bana her daim destek olan ve akademik yolculuğum boyunca yanımda duran herkese adanmıştır. Hepinize kalpten teşekkür ederim.

Mehmet Can EKKAZAN

İÇİNDEKİLER

SİMGE LİSTESİ viii

KISALTMA LİSTESİ ix

ŞEKİL LİSTESİ x

TABLO LİSTESİ xii

ÖZET xiii

ABSTRACT xv

1 GİRİŞ 1

2 LİTERATÜR TARAMASI 8
2.1 Veri Kümeleri 8
2.2 Uydu Görüntülerden Otomatik Hasar Tespiti 12

3 VERİ KÜMESİ 15
3.1 Veri Kaynağı 17
3.2 Etiketleme Stratejisi 19
3.2.1 $TE23D_A$ Veri Alt Kümesi için Etiketleme Stratejisi 20
3.2.2 $TE23D_{B1}$ Veri Alt Kümesi için Etiketleme Stratejisi 22
3.2.3 $TE23D_{B2}$ Veri Alt Kümesi için Etiketleme Stratejisi 22
3.3 Veri Kümesinin Son Haline Getirilmesi 23

4 METODOLOJİ 28
4.1 Örnek Segmentasyon ile Hasar Tespiti 29
4.1.1 Mask R-CNN Mimarisi 29
4.2 Anlamsal Segmentasyon ile Hasar Tespiti 31
4.2.1 U-Net Mimarisi 31
4.2.2 U-Net++ Mimarisi 32
4.2.3 BeiT Mimarisi 34
4.2.4 DPT Mimarisi 35

4.2.5 MobileViT Mimarisi 37
4.2.6 SegFormer Mimarisi 38
4.3 Performans Metrikleri 39

5 DENEYSEL SONUÇLAR **41**
5.1 Mimarilerin Deneysel Sonuçları 42
5.2 Hipotez Deneyi Sonuçları 44
5.3 $\text{SegFormer}_{\text{A}}$ Modelinin Eğitim Grafiği 51

6 SONUÇ **54**

KAYNAKÇA **57**

TEZDEN ÜRETİLMİŞ YAYINLAR **61**

SİMGE LİSTESİ

IoU_{BG}	Arka Plan için Birlik Üzerinden Kesişim
TP_{BG}	Arka Plan için Doğru Pozitif
FP_{BG}	Arka Plan için Yanlış Pozitif
IoU_B	Binalar için Birlik Üzerinden Kesişim
IoU	Birlik Üzerinden Kesişim
OPA	Genel Piksel Doğruluğu
IoU_D	Hasar için Birlik Üzerinden Kesişim
TP_D	Hasar için Doğru Pozitif
FP_D	Hasar için Yanlış Pozitif
$mIoU$	Ortalama Birlik Üzerinden Kesişim
mAP	Ortalama Hassasiyet

KISALTMA LİSTESİ

BeiT	Bidirectional Encoder Representation from Image Transformers
BERT	Bidirectional Encoder Representations from Transformers
CNN	Convolutional Neural Networks
DPT	Dense Prediction Transformer
DSÖ	Dünya Sağlık Örgütü
GeoTIFF	Coğrafi Etiketli Görüntü Dosya Biçimi
GPU	Grafik İşlem Birimi
İHA	İnsansız Hava Aracı
MEDIC	Media-based Disaster Image Classification
R-CNN	Region-based Convolutional Neural Networks
TE23D	6 Şubat 2023 Türkiye Depremleri Veri Kümesi
xBD	xView2 Bina Hasar Tespit Veri Kümesi

ŞEKİL LİSTESİ

Şekil 1.1 Hatay şehir merkezinin SkySat uydu ağı ile çekilmiş görüntüsü . . 2
Şekil 3.1 Veri kümesine ait ham görüntüler 16
Şekil 3.2 Sırasıyla görüntü sınıflandırma, nesne algılama ve segmentasyon yöntemlerinin hasar tespiti problemi üzerindeki gösterimleri . . . 19
Şekil 3.3 Soldan sağa sırayla; veri kümesinden bir yama üzerinde modeller kullanılarak tespit edilmiş binaların temsili, $TE23D_A$ veri kümesinde aynı yama üzerindeki hasarlı alanın temsili ve aynı yamanın $TE23D_{B1}$ veya $TE23D_{B2}$ veri kümesindeki temsili . 23
Şekil 3.4 Uydu görüntüleri (birinci ve beşinci sütunlar), Uydu görüntülerinin $TE23D_A$ veri kümesindeki temsili (ikinci ve altıncı sütunlar), Uydu görüntülerinin $TE23D_{B1}$ veri kümesindeki temsili (üçüncü ve yedinci sütunlar) ve Uydu görüntülerinin $TE23D_{B2}$ veri kümesindeki temsili (dördüncü ve sekizinci sütunlar). 24
Şekil 3.5 TE23D veri kümesinin genel şablonu. 24
Şekil 3.6 1024x1024 piksel boyutlarındaki görüntülerin, 256x256 piksellik yamalara bölünmesini ve hasarlı alan içeren yeşil yamalar veri kümesinde tutulup, hasar içermeyen kırmızı yamaların çıkarılmasını gösteren şekil. 26
Şekil 4.1 Mask R-CNN Mimarisi 30
Şekil 4.2 U-Net Mimarisi 31
Şekil 4.3 U-Net++ Mimarisi 33
Şekil 4.4 BeiT Mimarisi 34
Şekil 4.5 DPT Mimarisi 36
Şekil 4.6 MobileViT Mimarisi 38
Şekil 4.7 SegFormer Mimarisi 39
Şekil 5.1 Modellerin test veri kümesi üzerindeki nitel sonuçları 45
Şekil 5.2 $TE23D_A$ veri kümesi üzerinde eğitilmiş olan $SegFormer_A$, $TE23D_{B1}$ veri kümesi üzerinde eğitilmiş olan $SegFormer_{B1}$ ve $TE23D_{B2}$ veri kümesi üzerinde modeli $SegFormer_{B2}$ modellerinin ait olduğu veri kümelerinin test alt kümelerindeki nitel sonuçları . 48

Şekil 5.3 Uydu görüntüleri (birinci sütun), TE23D$_A$ veri kümesine ait gerçek segmentasyon maskeleri (ikinci sütun), SegFormer$_A$ modelinin segmentasyon tahminleri (üçüncü sütun). 49
Şekil 5.4 Uydu görüntüleri (birinci sütun), TE23D$_A$ veri kümesine ait gerçek segmentasyon maskeleri (ikinci sütun), SegFormer$_A$ modelinin segmentasyon tahminleri (üçüncü sütun). 50
Şekil 5.5 SegFormer$_A$ modelinin eğitim sürecindeki eğitim ve doğrulama *mIoU* değerlerini gösteren grafik. 52

TABLO LİSTESİ

Tablo 2.1 Çeşitli veri kümelerine ait özelliklerin çalışma kapsamında hazırlanan TE23D veri kümesi ile karşılaştırılmasını gösteren tablo. 10
Tablo 3.1 Veri kümesindeki görüntülerin alındığı şehirler, görüntü çözünürlükleri ve kapladıkları alanları gösteren tablo. 18
Tablo 3.2 TE23D alt kümelerinin eğitim-doğrulama-test parçalarının dağılımı 25
Tablo 5.1 Mimarilerin, performans metriklerine göre nicel başarı oranlarını gösteren tablo (%'lik olarak). 42
Tablo 5.2 SegFormer modelinin TE23D veri kümeleri üzerinde başarılarının nicel sonuçları (%'lik olarak) 46
Tablo 5.3 Seçilen görüntülerdeki bazı örnekler için gerçek etiketleri, yorumcuların tahminlerini ve model tahminlerini gösteren tablo. . 47

ÖZET

Derin Öğrenme Tabanlı Bölütleme Yöntemleriyle Deprem Sonrası Uydu Görüntülerinden Hasarlı Bölgelerin Tespiti: 6 Şubat 2023 Türkiye Depremleri Örneği

Mehmet Can EKKAZAN

Bilgisayar Mühendisliği Anabilim Dalı
Yüksek Lisans Tezi

Danışman: Prof. Dr. Mine Elif KARSLIGİL

Doğal afetlerden sonra, etkili müdahale ve iyileştirme stratejileri için hızlı ve doğru hasar tespiti oldukça önemlidir. Bu tez çalışmasında, 6 Şubat 2023 tarihinde Türkiye'de gerçekleşen ve 10 şehri etkileyen depreme ait $\sim$481,72km^2 alanı kapsayan uydu görüntüleri kullanılarak 1183 görüntüden ve 2080 hasarlı olarak etiketlenmiş poligondan oluşan TE23D (6 Şubat 2023 Türkiye Depremleri) Veri Kümesi geliştirilmiş ve bu veri kümesi kullanılarak hasarlı binaların tespitini yapan derin öğrenme tabanlı bir sistem tasarlanmış ve gerçeklenmiştir.

Bu tez çalışmasının hipotezi, binalarda depremlerden kaynaklanan hasarın bir anomali olarak kabul edilebileceği ve bu hasarın anomali tespiti yaklaşımı ile tespitinin gerçekleştirilebileceğidir. Anomali tespiti yaklaşımı ile hasarlı binaların tespitinin performansının yeterli olup olmadığını değerlendirmek için TE23D veri kümesinin TE23D$_{\mathrm{A}}$, TE23D$_{\mathrm{B1}}$ ve TE23D$_{\mathrm{B2}}$ olmak üzere üç farklı versiyonu oluşturulmuştur. TE23D$_{\mathrm{A}}$ veri kümesi sadece hasarlı alanların etiketlendiği veri kümesiyken, TE23D$_{\mathrm{B1}}$ ve TE23D$_{\mathrm{B2}}$ veri kümeleri hasarlı alan etiketleriyle birlikte hasarsız bina etiketlerini içermektedir. İstanbul Veri Kümesi üzerinde eğitilen U-Net++ modeli, TE23D$_{\mathrm{B1}}$ veri kümesi oluşturulurken ve Massachusetts Buildings Dataset üzerinde eğitilen U-Net modeli TE23D$_{\mathrm{B2}}$ veri kümesi oluşturulurken bina segmentasyonu için kullanılmıştır.

Anomali tespiti yapılarak hasarlı alanların saptanabileceği hipotezini doğrulamak

için önce sadece hasarlı binaların etiketlendiği veri kümesi ile derin öğrenme tabanlı segmentasyon modelleri eğitilerek performansları değerlendirilmiştir. Hasarlı alanların tespiti amacıyla anlamsal ve örnek segmentasyon yaklaşımlarına ait mimariler olan Mask R-CNN, U-Net, U-Net++, BEiT, DPT, MobileViT ve SegFormer dahil olmak üzere son yıllarda geliştirilen başarılı segmentasyon modelleri bu yaklaşımı doğrulamak için $TE23D_A$ veri kümesi üzerinde eğitilmiştir. Ardından bu veri kümesi üzerinde en başarılı sonuçları veren SegFormer modeli, hasarsız bina etiketlerine sahip veri kümeleri üzerinde eğitilmiş, ve karşılaştırmalı analiz, $TE23D_A$ veri kümesi üzerinde eğitilen modelin, diğer veri kümeleri üzerinde eğitilen modellerle benzer ve hatta daha iyi performans gösterdiğini ortaya koymuş ve sadece hasarlı alanların etiketlenmesinin başarılı hasar tespiti için yeterli olduğunu doğrulamıştır. $SegFormer_A$ modeli, $TE23D_A$ veri kümesi üzerinde %91.92 OPA ve %74.45 mIoU skorlarını elde etmiştir. Bu sonuçlara göre anomali tabanlı etiketleme yaklaşımı, SegFormer modelinin $TE23D_A$ veri kümesi üzerindeki üstün performansının da gösterdiği gibi segmentasyon sürecini basitleştirmekte ve model doğruluğunu artırmaktadır.

Bulgular, afet sonrası hasar tespitinde yüksek kaliteli, odaklanmış veri kümelerinin değerinin altını çizmekte ve gelişmiş makine öğrenimi modellerinin afet müdahale ve iyileştirme çabalarını geliştirme potansiyelini vurgulamaktadır. Bu araştırma ile geliştirilen metodolojiler ve içgörüler, çeşitli doğal afet senaryolarında hızlı hasar tespiti için ölçeklenebilir ve verimli çözümler sunarak afet yönetimi alanına önemli ölçüde katkıda bulunmaktadır.

Anahtar Kelimeler: Türkiye 2023 Deprem Veri Kümesi, Deprem Görüntü Segmentasyonu, Uzaktan Algılama, Hasar Tespiti

ABSTRACT

Detection Of Damaged Regions From Post-Earthquake Satellite Images With Deep Learning Based Segmentation Methods: The Case Of February 6, 2023 Türkiye Earthquakes

Mehmet Can EKKAZAN

Department of Computer Engineering
Master of Science Thesis

Supervisor: Prof. Dr. Mine Elif KARSLIGİL

Natural disasters, especially earthquakes, require rapid and accurate damage assessment for effective response and recovery strategies. In this thesis, TE23D (Turkey Earthquakes of 6 February 2023 Dataset) dataset consisting of 1183 images and 2080 polygons labelled as damaged was developed using the satellite images covering 10 cities and $\sim$481,72km^2 taken after the earthquake that occurred on 6 February 2023 in Turkey, and a deep learning based system that detects damaged buildings was designed and implemented using this dataset.

The hypothesis of this thesis is that damage caused by earthquakes can be considered as an anomaly and this damage can be detected by anomaly detection approach. Three different versions of the TE23D dataset, namely TE23D$_{\mathrm{A}}$, TE23D$_{\mathrm{B1}}$ and TE23D$_{\mathrm{B2}}$, were created to evaluate whether the performance of the anomaly detection approach is adequate. While the TE23D$_{\mathrm{A}}$ dataset contains labels of damaged areas only, TE23D$_{\mathrm{B1}}$ and TE23D$_{\mathrm{B2}}$ datasets contain building labels along with damaged area labels. The U-Net++ model trained on the Istanbul Dataset was used for building segmentation when creating the TE23D$_{\mathrm{B1}}$ dataset and the U-Net model trained on the Massachusetts Buildings Dataset was used for building segmentation when creating the TE23D$_{\mathrm{B2}}$ dataset.

In order to verify the hypothesis that damaged areas can be detected by anomaly detection, deep learning based segmentation models are trained with

the dataset in which only damaged buildings are labelled and their performances are evaluated. Recently developed segmentation models including Mask R-CNN, U-Net, U-Net++, BEiT, DPT, MobileViT and SegFormer, which are architectures of semantic and instance segmentation approaches for the detection of damaged areas, were trained on the $TE23D_A$ dataset to validate this approach. The SegFormer model, which gave the best results on this dataset, was then trained on datasets with undamaged building labels, and the comparative analysis revealed that the model trained on the $TE23D_A$ dataset performed similarly or even better than the models trained on the other datasets, confirming that only labelling damaged areas is sufficient for successful damage detection. The $SegFormer_A$ model achieved 91,92% OPA and 74,45% mIoU scores on the $TE23D_A$ dataset. According to these results, the anomaly-based labelling approach simplifies the segmentation process and improves model accuracy, as demonstrated by the superior performance of the SegFormer model on the $TE23D_A$ dataset.

The findings underline the value of high-quality, focused datasets in post-disaster damage assessment and highlight the potential of advanced machine learning models to enhance disaster response and recovery efforts. The methodologies and insights developed through this research contribute significantly to the field of disaster management by providing scalable and efficient solutions for rapid damage assessment in various natural disaster scenarios.

Keywords: Turkey 2023 Earthquakes Dataset, Earthquake Image Segmentation, Remote Sensing, Damage Assessment

1
GİRİŞ

Tarih boyunca depremler en yıkıcı doğal afetler arasında yer almış, toplumlara, ekonomilere ve çevreye büyük zararlar vermiştir. Bu ani ve öngörülemeyen doğa olayları bazen saniyeler içinde büyük yıkımlara yol açarak önemli ölçüde can ve mal kaybına neden olabilmektedir. DSÖ'ye göre, depremler 1998 ve 2017 yılları arasında yaklaşık 750.000 kişinin ölümüne neden olmuş ve 125 milyon kişiyi etkilemiştir; bu değerler doğal afetlerin neden olduğu tüm kayıpların yarısından fazlasını oluşturmaktadır[1]. Bazen tüm şehirlerin enkaza dönüştüğü ve hayatta kalanların acil yardıma ihtiyaç duyduğu bu felaketlerin insani bilançosu da oldukça ağırdır. Yıkımın büyüklüğü; kurtarma operasyonları, acil durum hizmetleri ve uzun vadeli iyileştirme çabalarını önemli ölçüde zorlaştırmaktadır. Son yılların en ölümcül depremlerinden ikisi 6 Şubat 2023 tarihinde Türkiye'nin güneydoğu bölgesinde meydana gelmiştir. Büyüklükleri 7,8 ve 7,5 olan bu depremler, Türkiye ve Suriye'de 55.000'den fazla can kaybına yol açarak büyük depremlerin yoğun nüfuslu bölgelerde yaratabileceği yıkıcı etkiye örnek teşkil etmiştir[2]. 6 Şubat 2023 Türkiye depreminin yıkıcı etkisi Şekil 1.1'den incelenebilir.

Bu tür güçlü sarsıntıların yol açtığı altyapı hasarları arasında çöken binalar, tahrip olan yollar ve bozulan kamu hizmeti sistemleri yer almakta, bu da kurtarma görevlerini ve yardım dağıtımını zorlaştırmaktadır. Fiziksel yıkımın ötesinde, depremlerin hayatta kalanlar arasında travma ve sıkıntıya neden olan derin psikolojik etkileri de vardır. Ticari mülklerin ve sanayi tesislerinin yıkımı yerel ekonomileri yıllarca sekteye uğratabileceğinden ekonomik yansımaları da aynı derecede ağırdır. Bu felaketler, gelecekteki sismik olayların yıkıcı etkilerini hafifletmek için hazırlıklı olmanın, hızlı müdahalenin ve kapsamlı kurtarma planlamasının önemini vurgulamaktadır. Depremlerin tekrar eden doğası ve öngörülemezliği, yaşamları korumak ve etkilenen bölgeler üzerindeki genel etkiyi azaltmak için afet yönetimi stratejilerinde sürekli ilerlemeler gerektirmektedir. Erken uyarı sistemlerine yapılan yatırımlar, sıkı bina yönetmelikleri ve halkın depreme hazırlık konusunda eğitilmesi, afet riskinin etkili bir şekilde azaltılmasının

önemli bileşenleridir. Türkiye ve Suriye'de yaşanan trajik olaylar, depremlerin yarattığı çok yönlü zorlukları yönetmek için sağlam sistemlere ve uluslararası işbirliğine duyulan ihtiyacı çarpıcı bir şekilde hatırlatmaktadır.



Şekil 1.1 Hatay şehir merkezinin SkySat uydu ağı ile çekilmiş görüntüsü

Afet sonrası hasarlı bina tespiti, bir depremin ardından hayati önem taşır. Bu süreç, afetin neden olduğu hasarın kapsamının ve niteliğinin değerlendirilmesini içerir ve çeşitli nedenlerden dolayı gereklidir:

Hasarın Büyüklüğünü Anlamak: Afet sonrası hasar tespiti, afetin yol açtığı yıkımın boyutunu ve ciddiyetini belirlemek açısından önemlidir. Bu süreç, altyapının, binaların ve kritik tesislerin durumu hakkında doğru bilgi toplamak için etkilenen alanların kapsamlı bir değerlendirmesini içerir. Yetkililer, hasarın boyutunu titizlikle belgeleyerek hangi bölgelere acil müdahale gerektiğini ve hangi altyapıların hala çalışır durumda olduğunu belirler. Bu kapsamlı tarama, kaynakların ve yardımların etkili bir şekilde tahsis edilmesinin planlanması ve önceliklendirilmesi için önemlidir. Örneğin, ağır hasarlı hastanelerin tespit edilmesi ve acil destek almalarının sağlanması, tıbbi müdahale çabalarının verimliliğini önemli ölçüde artırabilir. Ayrıca, yollar ve köprüler gibi ulaşım ağlarındaki hasarın boyutunu anlamak, en çok etkilenen bölgelere yardım ve malzeme ulaştırma lojistiğinin planlanmasına yardımcı olur. Ayrıntılı hasar değerlendirmeleri aynı

zamanda yetkililerin toplumun işleyişi ve iyileşme süreci için kritik olan su temini, elektrik ve telekomünikasyon gibi temel hizmetler üzerindeki genel etkiyi ölçmesine de olanak tanır. Ayrıca, bu bilgiler halkla ve uluslararası toplumla şeffaf iletişimi destekler, güveni artırır ve yardımın en çok ihtiyaç duyulan yere yönlendirilmesini sağlar. Doğru değerlendirmeler, arama ve kurtarma ekiplerinin efektif bir şekilde organize edilmesine, geçici barınakların kurulmasına ve ihtiyaç sahiplerine hizmet verilmesine olanak tanır; bunların tümü, etkilenen toplulukların istikrara kavuşması ve iyileşme sürecini başlatmanın anahtarıdır.

İnsani İhtiyaçların Tespiti: Hasar tespiti, afet sonrasında etkilenen nüfusun acil insani ihtiyaçlarının belirlenmesinde kritik bir adımdır. Bu süreç, barınma, yiyecek, su, tıbbi yardım ve diğer temel hizmetlere ilişkin özel gereksinimlerin belirlenmesi amacıyla topluluklar üzerindeki etkinin ayrıntılı bir analizini içerir. Yardım kuruluşları ve devlet kurumları, hasarın boyutunu ve bunun farklı alanlar üzerindeki etkilerini kapsamlı bir şekilde anlayarak müdahale çabalarına daha etkili bir şekilde öncelik verebilir.

Örneğin, hasar değerlendirmeleri hangi yerleşim alanlarının ne derece etkilendiğinin belirlenmesi sayesinde geçici barınakların ve barınma çözümlerinin hızlı bir şekilde sunulabilmesine olanak sağlayabilir. Ayrıca, yollar, köprüler ve kamu hizmetleri gibi altyapılara verilen hasarın değerlendirilmesi, gıda ve su kaynaklarının dağıtımının planlanması için gereklidir. Kritik tedarik yollarının hasar gördüğü tespit edilirse, temel malların ihtiyaç sahiplerine gecikmeden ulaşmasını sağlamak için alternatif lojistik planları hızla uygulanabilir.

Fiziksel ihtiyaçların yanı sıra hasar tespitleri etkilenen nüfusun sağlık bakım ihtiyaçlarının belirlenmesinde de önemlidir. Buna hastanelerin ve kliniklerin durumunun değerlendirilmesi, tıbbi malzemelerin mevcudiyetinin belirlenmesi ve yerel sağlık hizmetleri için hasta kapasitesinin tespiti de dahildir. Yardım kuruluşları, tıbbi tesislerin hasar gördüğü veya aşırı yüklendiği bölgeleri tespit ederek, tıbbi ekiplerin, malzemelerin ve ekipmanların bu yüksek ihtiyaç duyulan bölgelere ulaştırılmasına öncelik verebilir, böylece daha fazla can kaybını önleyebilir ve acıları azaltabilirler.

Hasar değerlendirmeleri, acil fiziksel ve tıbbi ihtiyaçların ötesinde, bir felaketin ardından hastalık salgınlarını önlemek için hayati önem taşıyan sanitasyon ve atık yönetimi gibi kesintiye uğrayabilecek diğer temel hizmetlerin belirlenmesine de yardımcı olur. Ek olarak, eğitim tesislerine ve toplum merkezlerine verilen hasarın boyutunun anlaşılması, etkilenen nüfusun sosyal ve psikolojik iyileşmesi için önemli olan eğitim ve toplumsal destek hizmetlerinin devamına yönelik planlama

yapılmasına yardımcı olur.

Genel olarak, hasar değerlendirmeleri, afetin etkisinin net ve ayrıntılı bir resmini sunarak, daha koordineli ve etkili bir müdahaleye olanak tanıyarak en acil insani ihtiyaçların hızlı ve etkili bir şekilde karşılanmasını sağlar. Bu hedefe yönelik yaklaşım, yalnızca yardım çabalarının etkisini en üst düzeye çıkarmakla kalmıyor, aynı zamanda etkilenen topluluklarda uzun vadeli iyileşme ve dayanıklılık için bir temel oluşturulmasına da yardımcı oluyor.

Acil Durum Müdahalesine Yönelik Yönlendirme: Hızlı ve doğru hasar değerlendirmesi, iyi koordine edilmiş bir acil durum müdahalesi için çok önemlidir. Bu veriler, acil durum yönetimi ekiplerinin ve ilk müdahale ekiplerinin kaynakları verimli bir şekilde dağıtmasına, yüksek öncelikli alanları hedeflemesine ve hayat kurtarmasına yardımcı olur.

Doğru değerlendirmeler, müdahale ekiplerinin en çok etkilenen bölgeleri anlamalarına olanak tanıyarak, hedefe yönelik arama ve kurtarma operasyonlarına olanak tanır. Çok sayıda mahsur kalan veya yaralı kişinin bulunduğu alanların belirlenmesi kurtarma başarısını artırır. Hasar değerlendirme verileri aynı zamanda iletişim ağlarının hızlı bir şekilde onarılmasına yardımcı olarak, etkilenen topluluklara etkili koordinasyon ve zamanında güncelleme sağlanmasına yardımcı olur.

Genel olarak hızlı hasar tespiti; verimli kaynak dağıtımına, iletişim ağları kurulmasına, barınakların kurulmasına ve hızlı tıbbi yardım sağlayarak koordineli bir müdahaleye olanak sağlar ve iyileşme için zemin hazırlar.

Sigorta Taleplerinin Karşılanması ve Mali Yardım: Hasar tespit raporları, sigorta taleplerinin karşılanması ve afetlerden etkilenen bireyler, işletmeler ve topluluklar için mali yardımın güvence altına alınmasında önemli bir rol oynamaktadır. Bu raporlar, sigortacılara ve devlet kurumlarına talepleri işleme koymak ve mali yardım tahsis etmek için gerekli bilgileri sağlayarak, meydana gelen hasar ve kayıpların boyutunu göstererek önemli kanıtlar olarak hizmet vermektedir. Afetin ardından adil ve zamanında tazminat sağlanması ve etkilenen tarafların toparlanıp hayatlarını yeniden inşa etmelerine olanak sağlamak için doğru değerlendirmeler şarttır.

Ayrıca, hasar tespit raporları devlet kurumlarından ve yardım kuruluşlarından mali yardım alınmasını kolaylaştırmada etkilidir. Doğru değerlendirmeler, politika yapıcılara afetin etkisinin ölçeği ve ciddiyeti konusunda değerli bilgiler sağlar ve afet yardım fonlarının ve kaynaklarının tahsisine rehberlik eder. Hasar değerlendirme raporları, kamu altyapısına, özel mülkiyete ve topluluk varlıklarına

verilen hasarın boyutunu belgeleyerek, mali yardımın adil bir şekilde dağıtılmasına ve en fazla ihtiyacı olan alanlara yönlendirilmesine yardımcı olur, böylece etkilenen topluluklar için iyileşme ve yeniden inşa sürecini kolaylaştırır.

Altyapı Rehabilitasyonu ve Yeniden İnşa: Hasar değerlendirme verileri, bir afet sonrasında binaların, köprülerin, yolların ve diğer kritik altyapı bileşenlerinin yapısal bütünlüğünün değerlendirilmesinde bir temel taşı görevi görür. Bu kapsamlı değerlendirme, hasarın boyutunun değerlendirilmesini, zayıf noktaların belirlenmesini, rehabilitasyon ve yeniden inşa çalışmaları için gerekli eylem planının hazırlanmasını içerir. Altyapı varlıklarının durumunu titizlikle belgeleyen hasar değerlendirme raporları, karar vericilere hasarın boyutu ve acil müdahale gerektiren belirli alanlar hakkında paha biçilmez bilgiler sağlar.

Ayrıca hasar tespit verileri, hasarlı altyapının onarımı, değiştirilmesi veya değiştirilmesine ilişkin karar verme sürecine rehberlik etmede önemli bir rol oynamaktadır. Paydaşların, hasarın ciddiyetine, etkilenen yapıların stratejik önemine ve topluluğun işlevselliği ve dayanıklılığı üzerinde beklenen etkiye göre çabalarını önceliklendirmesine olanak tanır. Örneğin, binaların kapsamlı yapısal hasara maruz kaldığı durumlarda, hasar değerlendirme verileri, onarımların mümkün olup olmadığının veya kamu güvenliği ve yapısal bütünlüğün sağlanması için yıkım ve yeniden inşanın gerekli olup olmadığının belirlenmesine yardımcı olur.

Gelecekteki Afetlere Hazırlık: Afet sonrası hasar değerlendirmesi, çok önemli bir öğrenme fırsatı sunarak bir afet sırasında ortaya çıkan güvenlik açıkları ve zayıf noktalar hakkında değerli bilgiler sağlar. Bu kapsamlı değerlendirme, hasarın boyutuna katkıda bulunan belirli faktörlere ışık tutarak yetkililerin ve paydaşların afet hazırlığı ve etki azaltma önlemlerinde iyileştirilecek alanları belirlemesine olanak tanır. Karar vericiler, hasar değerlendirme verilerinde gözlemlenen modelleri ve eğilimleri analiz ederek, gelecekteki felaketlerin etkisini daha da artırabilecek altta yatan risk faktörleri ve sistemik güvenlik açıkları hakkında daha derin bir anlayış kazanır.

Ayrıca, hasar değerlendirme raporlarından elde edilen bulgular, afetlere karşı dayanıklılığı artırmayı amaçlayan politika geliştirme ve düzenleyici çerçevelere bilgi sağlamada önemli bir rol oynamaktadır. Yetkililer, mevcut bina mevzuatındaki, arazi kullanım planlama düzenlemelerindeki ve altyapı standartlarındaki eksiklikleri tespit ederek gelecekteki felaketlere karşı dayanıklılığı güçlendirecek hedefli reformları hayata geçirebilir. Esasen, afet sonrası hasar değerlendirmesi, politikayı bilgilendiren, altyapı dayanıklılığını artıran ve

toplulukları riski azaltma ve yeniden daha güçlü bir şekilde yeniden inşa etme konusunda güçlendiren eyleme dönüştürülebilir bilgiler sağlayarak gelecekteki afetlere hazırlıklılığın sağlanmasında önemli bir rol oynar.

Özetle, afet sonrası hasar tespiti, hasarın boyutunun anlaşılması, müdahale çabalarının önceliklendirilmesi, iyileşme ve yeniden yapılanmanın kolaylaştırılması ve gelecekteki afetlere hazırlığın artırılması için gereklidir. Bu süreç kaynakların etkin bir şekilde tahsis edilmesini sağlar, hayat kurtarmaya yardımcı olur ve gelecekteki afetler karşısında toplumların dayanıklılığını artırır. Doğru hasar tespitleri, en çok etkilenen bölgelerin belirlenmesinde temel teşkil eder ve acil durum müdahale ekiplerinin çabalarını önceliklendirmelerine ve en çok ihtiyacı olanlara zamanında yardım sağlamalarına olanak tanır. Hasar tespitleri, yardım ve kaynakların etkin bir şekilde dağıtılmasını sağlayarak, etkilenen toplulukların istikrara kavuşturulmasında ve toparlanma sürecinin başlatılmasında önemli bir rol oynar.

Ancak, büyük depremlerden sonra, geniş alanlar etkilenmişse yardım ulaştırmak için zaman faktörü çok önemli olmasına rağmen hasarın boyutunun hızlı anlaşılması zordur. Geniş bölgelerin gözlemlenmesine olanak tanıdığı için deprem sonrası hasar tespitinde hava görüntüleri kullanılarak felaketin etkisine dair kısa sürede genel bir fikir elde edilebilir. Fakat uydulardan veya İHA'lardan alınan görüntüler gibi büyük alanlara ait hava görüntülerinin insan gücüyle değerlendirilmesi zaman alıcı ve yoğun emek gerektiren bir süreçtir.

Bilgisayarla görme alanındaki son gelişmeler sayesinde, depremlerden sonra çekilen uydu görüntülerinden hasarlı alanları yüksek doğrulukla otomatik olarak tespit etmek mümkün olmaktadır. Fakat bu tip çalışmalarda kullanılabilecek deprem sonrası alınmış hava görüntülerine ait ortak kullanıma açılmış veri kümeleri çok kısıtlıdır. Bu ihtiyaca yanıt olarak, bu tez çalışmasında deprem sonrası hasar tespiti için geliştirilebilecek sistemlerde kullanılması amacıyla 6 Şubat 2023 Türkiye Depremi'nden sonra alınan uydu görüntülerinden kapsamlı bir veri kümesi oluşturulmuştur. Oluşturulan bu veri kümesi kullanılarak örnek ve anlamsal segmantasyon için geliştirilen çeşiti mimariler değerlendirilerek deprem sonrası otomatik hasar tespitinin başarısı değerlendirilmiştir. Yapılan çalışmanın literatüre olan katkısı iki ana başlıkla açıklanabilir.

- 6 Şubat 2023 tarihinde Türkiye'de gerçekleşen ve 10 şehri etkileyen depreme ait 481,72 kilometrekarelik uydu görüntüleri kullanılarak 1183 görüntüden ve 2080 poligondan oluşan; çeşitli hasar ve yıkım türlerine dair örnekler bulunduran ilk uydu veri kümesi tez çalışması kapsamında tanıtılmıştır.

- Veri kümesinde üç farklı etiketleme yöntemi kullanılarak üç alt küme oluşturulmuştur. İlk alt küme, sadece hasarlı alanların etiketli olduğu ve yıkımın bir anomali olarak değerlendirilebileceği yani hasarın tespit edilebilmesi için binaların etiketlenmesine gerek olmadığı hipotezine dayandırılan kümedir. Diğer iki alt küme ise binaların otomatikleştirilmiş etiketleme yöntemleri kullanılarak etiketlendiği alt kümelerdir. Çalışma kapsamında yıkımın bir anomali olarak değerlendirilebileceği hipotezi, veri alt kümeleri üzerinde eğitilen modellerin sonuçlarına dayandırılarak kanıtlanmıştır.

2
LİTERATÜR TARAMASI

Son yıllarda, doğal afetlerin neden olduğu hasarlı alanların tespiti üzerine literatürde önemli gelişmeler olmuştur [3–5]. Gelişmekte olan bu araştırma alanı, depremler, kasırgalar, seller ve orman yangınları da dahil olmak üzere çok çeşitli doğal afet türünü kapsamaktadır. Sofistike algoritmaların geliştirilmesi ve yüksek çözünürlüklü görüntülerin yaygınlaşması, bu alandaki ilerlemeleri teşvik etmiştir. Araştırmacılar, hasarlı alanları doğru bir şekilde tespit edebilen otomatik sistemler geliştirmek için uydu görüntüleri, hava fotoğrafları ve drone görüntüleri gibi çeşitli veri kaynaklarından yararlanmaktadır [6–9].

2.1 Veri Kümeleri

Uydu görüntüleri büyük ölçekli afetlere kapsamlı bir genel bakış sağlayarak yer ekipleri için erişilemez veya tehlikeli olabilecek geniş alanların analiz edilmesine olanak tanır. Öte yandan, drone görüntüleri daha yüksek çözünürlüklü görüntüler ve belirli alanları yakalamada daha fazla esneklik sunarak spesifik bölgelerde ayrıntılı değerlendirmeler için idealdir. Böylece çeşitli veri kaynakları, hasar tespit algoritmalarının doğruluğunu ve verimliliğini artırmada etkili olmaktadır.

Kamuya açık veri kümeleri bu araştırma alanında çok önemli bir rol oynamıştır [10–12]. Bunun yanısıra algoritmaların geliştirilmesi ve kıyaslanması için değerli bir temel sağlamış, araştırmacılar için işbirliğini ve yeniliği teşvik etmiştir. Bu veri kümelerini kullanan çalışmalar, otomatik hasar tespit sistemlerinin afet sonrası müdahalenin hızını ve doğruluğunu önemli ölçüde artırma potansiyelini ortaya koymuştur. Örneğin, araştırmacılar makine öğrenimi modellerini afet öncesi ve sonrası görüntülerden oluşan büyük veri kümeleri üzerinde eğiterek, hasarın boyutunu hızla belirleyip ölçebilen ve acil durum müdahale ekipleri ile karar vericilere kritik bilgiler sağlayan araçlar geliştirebilmiştir.

Gupta ve arkadaşları tarafından oluşturulan xBD veri kümesi, çeşitli doğal afet türlerinde hasar değerlendirmesi görevi için tasarlanmış en kapsamlı veri

kümelerinden biridir [13]. Bu veri kümesi depremler, tsunamiler, rüzgar olayları ve yangınlar dahil olmak üzere çok çeşitli felaket senaryolarını kapsamaktadır. Aynı bölgelerin afet öncesi ve afet sonrası uydu görüntülerini sağlayan xBD veri kümesi, otomatik hasar değerlendirme modelleri geliştirmeyi ve doğrulamayı amaçlayan araştırmacılar için önemli kaynaklardan biridir. xBD veri kümesinin dikkat çekici özelliklerinden biri geniş ölçeğidir. Toplam 22.068 görüntü ve 850.736 poligondan oluşan veri kümesi, bu araştırma alanındaki mevcut en büyük veri kümelerinden biridir. Bu büyük miktardaki veri, farklı felaket senaryolarında hasarı doğru bir şekilde tespit edip değerlendirebilen güçlü makine öğrenimi modellerinin eğitilmesine olanak tanır. Çeşitli afet türlerinin dahil edilmesi, xBD veri kümesi kullanılarak geliştirilen modellerin çok yönlülüğünü artırarak bunların çeşitli doğal afet türlerine daha iyi genelleme yapmalarını sağlar.

Alam ve arkadaşları tarafından yayınlanan MEDIC veri kümesi afet görüntüsü sınıflandırma görevleri için bir diğer önemli veri kümesidir [14]. xBD veri kümesinden farklı olarak MEDIC veri kümesi diğer afet türlerine göre daha yüksek oranda deprem görüntüsü içermektedir. Veri kümesinde yer alan 71.198 görüntünün 15.095'i deprem sonrası görüntülerdir. MEDIC veri kümesinin ayırt edici bir özelliği, deprem görüntülerinin uydu görüntülerinden alınmaması, bunun yerine sosyal medya platformu X'ten (makalenin yayınlandığı sırada Twitter olarak biliniyordu) toplanmasıdır. Veri kümesindeki deprem görüntüleri arasında 2015 Nepal depremi, 2015 Şili Illapel depremi, 2016 Ekvador depremi, 2017 Irak-İran depremi ve 2017 Meksika depremi gibi depremler yer almaktadır. Çeşitli yerlerden çekilen bu görüntüler, depremlerin yıkımına ve sonrasına dair kapsamlı bir görsel kaynak sunmaktadır. Sosyal medyayı bir kaynak olarak kullanan MEDIC veri kümesi, zamanında ve erken afet müdahalesi için oldukça önemli bir perspektif sunmaktadır. Ancak bu aynı zamanda veri kümesinde değişen görüntü kalitesi, açılar ve önyargılar gibi zorlukları da beraberinde getirmektedir. Bu zorluklara rağmen MEDIC veri kümesi, afet müdahalesi üzerine çalışan araştırmacılar için değerli bir kaynak olmaya devam etmekte, uydu tabanlı veri kümelerini tamamlayan içgörüler sunmakta ve çeşitli görsel veriler aracılığıyla afet etkilerinin anlaşılmasını geliştirmektedir.

Weber ve arkadaşları tarafından yayınlanan Incidents veri kümesi, çeşitli olay türlerini içeren bir veri kümesidir. Bu veri kümesinde deprem sonrası görüntüleri içeren örnekler de bulunmaktadır [15]. Veri kümesi, her bir olay sınıfı için pozitif ve negatif görüntülerden oluşan bir yapı ile tasarlanmıştır. Bir sınıf için pozitif bir görüntü, belirli bir olay sınıfını örneklediğini gösterirken, bir sınıf için negatif bir görüntü, diğer olay türlerini tasvir etmesine rağmen, belirli bir sınıfı temsil etmediğini gösterir. Bu kategorizasyon, farklı olay türlerini doğru bir şekilde ayırt

etmek için modellerin eğitilmesine yardımcı olur. Veri kümesinde çok sayıda görüntü olmasına rağmen, deprem olaylarının veri kümesindeki temsili diğer olay türlerine kıyasla sınırlıdır. Bunun nedeni, orman yangınları veya trafik kazaları gibi diğer olaylara kıyasla önemli depremlerin nispeten daha az sıklıkta meydana gelmesi olabilir. Bununla birlikte, görüntü kaynakları ve bağlamlarındaki çeşitlilik, bu veri kümesini afet müdahale modellerinin eğitimi ve değerlendirilmesi için değerli bir varlık haline getirmektedir, çünkü görsel verilerde model sağlamlığını ve genelleştirmeyi artırabilecek değişkenlik sunmaktadır.

Incidents veri kümesine ek olarak Weber ve arkadaşları aynı 43 olay kategorisinden 977.088 pozitif görüntü içeren genişletilmiş bir versiyon olan Incidents-1M veri kümesini tanıtmıştır [16]. Orijinal Incidents veri kümesine benzer şekilde Incidents-1M'deki görüntüler de Google Görseller'den indirilmiştir. Bu daha büyük veri kümesi, afet ve olay tespiti ve sınıflandırması için makine öğrenimi modellerinin geliştirilmesine ve iyileştirilmesine daha fazla yardımcı olabilecek daha geniş bir görsel veri yelpazesi sunmaktadır. Depremlerle ilgili olanlar da dahil olmak üzere Incidents-1M'deki çok sayıda görüntü, gelişmiş görüntü analizi teknikleriyle afete hazırlık ve müdahaleyi iyileştirmeyi amaçlayan araştırmacılar ve uygulayıcılar için zengin bir kaynak sağlamaktadır.

Taşçı ve arkadaşları tarafından yayınlanan çalışmada, 6 Şubat 2023 Türkiye depremlerinde ait tanıtılan veri kümesinde ise Türkiye Cumhuriyeti Milli Savunma Bakanlığına bağlı Harita Genel Müdürlüğü tarafından yayınlanan ve İHA'lar tarafından kaydedilen görüntüler depreme ait bir veri kümesi olarak yayınlanmıştır [17]. Hasar görmüş binalara ait görüntüler ilgili kaynağın internet sitesi üzerinden alınan ekran görüntülerinden, hasar görmemiş binalara ait görüntüler ise Google Haritalar üzerinden alınan ekran görüntülerinden oluşmaktadır. Ancak, 1237 yıkılmış bina görüntüsü ve 1498 sağlam bina görüntüsü içeren veri kümesindeki görüntülerin ayrı ayrı kaydedilmiş olması yani bir görüntü sınıflandırma problemi için tasarlanmış olması en büyük eksikliğidir.

Tablo 2.1'de literatürdeki bazı veri kümeleri ile çalışma kapsamında hazırlanan veri kümesinin karşılaştırılması incelenebilir.

Tablo 2.1 Çeşitli veri kümelerine ait özelliklerin çalışma kapsamında hazırlanan TE23D veri kümesi ile karşılaştırılmasını gösteren tablo.

Veri Kümesi	Yıl	Veri Kaynağı	Deprem Öncesi Görüntü Sayısı	Deprem Sonrası Görüntü Sayısı	Çözünürlük (piksel)	Uzaysal Çözünürlük (metre/piksel)
xBD	2019	Uydu	192	192	1024 × 1024	∼0.5
Incidents	2020	Kişisel Kamera	-	∼20,000	Değişken	-
Incidents-1M	2022	Kişisel Kamera	-	∼70,000	Değişken	-
[17]	2023	İHA	-	2735	Değişken	-
TE23D	**2023**	**Uydu**	**-**	**1183**	**256 × 256**	**∼0.5**

Mevcut hasar tespit veri kümeleri, çoklu görev modelleri eğitmek amacıyla genellikle kasırgalar, seller, orman yangınları ve depremler gibi çok çeşitli afet türlerini kapsamaktadır. Bu kapsamlı yaklaşım, çeşitli afet senaryolarını ele alabilen çok yönlü modeller oluşturmayı amaçlasa da, depreme özgü uygulamalar için uygun olmayabilir. Depremlerle ilişkili hasar modelleri, benzersiz yapısal arızalar, zemin kırılmaları ve toprak kayması ve sıvılaşma gibi ikincil tehlikeler gibi diğer afetlerden önemli ölçüde farklıdır. Sonuç olarak, birden fazla afet türünden elde edilen veriler birleştirildiğinde, deprem hasarının belirli özelliklerinin ve nüanslarının yeterince yakalanamaması veya vurgulanamaması gibi bir risk ortaya çıkmaktadır. Bu durum, depreme özgü hasar tespiti için daha zayıf modellere yol açabilir ve etkili afet müdahalesini potansiyel olarak engelleyebilir.

Ayrıca, deprem sonrası uydu görüntüsü veri kümelerinin azlığı da göz ardı edilemez. Büyük depremler diğer afetlere kıyasla nispeten seyrek meydana gelmekte, bu da ilgili verilerin kullanılabilirliğini sınırlamaktadır. Ayrıca, uydu görüntülerinin kapsamı genellikle uydu geçişlerinin zamanlaması ve bulut örtüsü ile kısıtlanmakta, bu da yüksek kaliteli, deprem sonrası görüntülerin yakalanma şansını daha da azaltmaktadır. Deprem sonrası özel veri kümelerinin bu eksikliği, deprem hasar tespitinin özel ihtiyaçlarına göre hassas bir şekilde ayarlanmış modeller geliştirme ve eğitme becerisini engellemektedir. Bu tür veri kümelerinin azlığı, deprem sonrası uydu görüntülerinin toplanmasına yönelik odaklanmış çabalara duyulan kritik ihtiyacın altını çizmektedir. Bu özel yaklaşım, depreme özgü daha doğru ve güvenilir hasar tespit modellerinin oluşturulmasını kolaylaştırır. Geliştirilmiş modeller ise, etkilenen alanların daha hızlı ve daha kesin bir şekilde değerlendirilmesini sağlayarak, kurtarma ve yardım operasyonlarını bilgilendirerek ve iyileştirme çabalarının planlanması ve yürütülmesine yardımcı olacak şekilde afet müdahalesini önemli ölçüde geliştirebilir.

Bunlarla birlikte, depreme özgü kapsamlı veri kümelerinin olması, deprem hasarının benzersiz özelliklerini tanımak ve analiz etmek için özel olarak tasarlanmış gelişmiş algoritmaların geliştirilmesini destekleyebilir. Bu, bina çökmelerinin, altyapı arızalarının ve peyzaj değişikliklerinin kapsamını anlamayı içerir. Deprem senaryolarının özel ihtiyaçlarına ve özelliklerine odaklanarak, bu özel modeller daha fazla doğruluk ve etkinlik sunabilir ve sonuçta daha dirençli topluluklara ve daha iyi hazırlanmış afet müdahale sistemlerine katkıda bulunabilir.

2.2 Uydu Görüntülerden Otomatik Hasar Tespiti

Hasar tespitinde veri kümelerinin öneminin yanında, bu veri kümelerini analiz etmek için uygun metodolojileri değerlendirmek de aynı derecede önemlidir. Uydu görüntülerinden hasar tespitine, her biri benzersiz faydalar ve yetenekler sunan çeşitli görüntü analiz teknikleri kullanılarak yaklaşılabilir. Görüntü sınıflandırma, nesne tespiti ve segmentasyon bu amaç için dikkate alınabilecek üç temel yöntemdir. Doğru yaklaşımın seçilmesi, değerlendirme sürecinin doğruluğunu ve verimliliğini önemli ölçüde etkileyebilir. Her teknik farklı avantajlar sunar ve bunların anlaşılması projenin hedefleri ve kısıtlamalarıyla uyumlu bilinçli kararlar alınmasına yardımcı olabilir. Bu nedenle, mevcut veriler ve istenen sonuçlar bağlamında her bir yöntemin uygunluğunu araştırmak, uydu görüntülerinden hasar değerlendirmesini optimize etmek için oldukça önemlidir.

Görüntü sınıflandırma, tüm görüntülerin hasarın varlığı veya seviyesine göre kategorize edildiği en basit değerlendirme biçimidir. Çalışmalarda görüntüler yalnızca "hasarlı" veya "hasarsız" gibi kategorilere ayrılarak sınıflandırılır. 2018 yılında Duarte ve arkadaşları tarafından yapılan çalışmada kullanılan CNN tabanlı yaklaşım ile uydu görüntüleri içeren veri kümesinde, hasar içeren görüntülerin sınıflandırılmasında 89.7±0.9 doğruluk skoru elde edilmiştir [18]. Taşçı ve arkadaşları tarafından 2023 yılında gerçekleştirilen çalışmada ise başlangıç(inception) ve birleştirme(concatenation) tabanlı residüel bloklar kullanılan CNN yaklaşımında yaklaşık %98'lik bir doğruluk skoru elde edilmiştir. [17]. Bu tür görüntü sınıflandırma tabanlı yaklaşımlar nispeten basit ve hesaplama açısından verimlidir, ancak ayrıntıdan yoksundur ve hasarın belirli konumlarını tam olarak belirlemeden yalnızca genel bir değerlendirme sağlar.

Nesne tespiti, yalnızca hasarın varlığını tespit etmekle kalmaz, aynı zamanda görüntü içinde yerini de belirleyerek sınıflandırmanın ötesine geçer. Bu yöntem, hasarlı alanların veya nesnelerin etrafına sınırlayıcı kutular(bounding boxes) çizerek daha ayrıntılı bir değerlendirme yapılmasını sağlar. Nesne tespiti, tek bir görüntüdeki birden fazla hasar örneğini ayırt edebilir ve afet müdahalesi için daha uygulanabilir bilgiler sağlar. Ancak nesne tespiti, bazı kısıtlamaları nedeniyle hasar tespiti için ideal değildir. Nesne tespitinde kullanılan sınırlayıcı kutular, hasarlı alanların konumu hakkında yalnızca kabaca bir tahmin sağlar. Kesin değerlendirme için kritik olan hasarın şeklini ve kapsamını doğru bir şekilde tanımlamazlar. Bu durum, etkilenen alanların olduğundan fazla veya olduğundan az tahmin edilmesine yol açabilir. Ayrıca, afet senaryolarında hasarlar genellikle karmaşıktır ve üst üste biner. Sınırlayıcı kutular üst üste gelebilir, bu da karışıklığa ve hasarın doğru bir şekilde ölçülmesinde yanlışlıklara neden olabilir. Bu alanda Wang ve

arkadaşları tarafından yapılan çalışmada, hasarın tespit edilmesi bir nesne tespiti problemi olarak değerlendirilmiştir [19]. Kullanılan veri kümesi Çin'den alınan 3738 İHA görüntüsü içermektedir. YOLOv5, modelinin kullanıldığı çalışmada %95,34 F1-skorunda başarı oranına ulaşılmıştır.

Segmentasyon ise görüntüdeki her bir pikseli sınıflandırarak en detaylı ve hassas analizi sağlar. Bu yöntem, hasarlı alanların tam şeklini ve kapsamını ana hatlarıyla belirleyerek hasara ilişkin kapsamlı ve ayrıntılı bir anlayış sunar [20, 21]. Segmentasyon, hasarın ciddiyetini ve mekansal dağılımını doğru bir şekilde değerlendirmek için özellikle değerlidir, bu da onu ayrıntılı ve uygulanabilir hasar değerlendirmesi için daha tercih edilebilir bir yöntem haline getirir.

Zhan ve arkadaşları 2016 Kumamoto depreminden sonra hasarlı binaları segmente için Mask R-CNN modelinin bir versiyonunu kullanmıştır [22]. Yöntemle, 10cm/piksel ve 500 x 500 çözünürlüğe sahip 667 görüntüden oluşan veri kümesini kullanarak sınırlayıcı kutular için 0,365 ve segmentasyon için 0,373 mAP skoru elde etmiştir.

Xie ve arkadaşları, 2010 Haiti depremiden sonrasında alınan 3094 uydu görüntüsünü hasarlı binaları segmente etmek için kullanmışlardır. Çalışma, büyük spektrum farkı, düzensiz doku özellikleri ve olağandışı morfolojik özellikler gösterdikleri için deprem sonrası hasarlı binaların heterojenlik özelliklerine odaklanmaktadır. Görüntü transformatörleri(vision transformers) kullanılarak yapılan çalışmada model %62,43 IOU başarımı elde etmiştir [21].

Görüntü transformatörleri tabanlı bir başka çalışmada is Li ve arkadaşları, uydudan alınmış yapay açıklıklı radar görüntülerini kullanarak hasarlı binaların tespiti için DDFormer adı verilen segmentasyon modeli geliştirmişlerdir. Sonuç olarak, DDformer %81,81 mIOU elde etmiştir [23].

Afet hasar tespiti alanında, hasarın boyutunu belirlemek ve analiz etmek için modellerde, afet sonrası görüntülerin kullanılmasının yanında, afet öncesi ve sonrası görüntülerin birlikte kullanılması da oldukça yaygındır [24–26]. Bu eşleştirilmiş görüntüler, bir afetin etkisini doğru şekilde değerlendirmek için çok değerli olan bir öncesi ve sonrası perspektifi sağlar. Ancak bu tür veri kümeleri, afet öncesi ve sonrası görüntüler arasında zaman içinde meydana gelen değişiklikler nedeniyle genellikle önemli zorluklarla karşılaşmakta ve bu da veri kümesinin kalitesini ve güvenilirliğini olumsuz yönde etkileyebilmektedir.

Kalantar ve arkadaşları tarafından yapılan çalışmada 2016 Kumamoto depremi ardından toplanan uydu görüntüleriyle birlikte deprem öncesi görüntüler birlikte

kullanılmıştır. Bu ikili görüntülerin CNN tabanlı bir mimariyle özelliklerinin çıkarılıp birleştirildiği yöntemde hasarlı bina tespitinde %76.86 doğruluk ve %76.1 F1-skoru elde edilmiştir [24].

Wu ve arkadaşları tarafından yapılan çalışmada ise dikkat mekanizması(attention mechanism) kullanılan U-Net mimarisi, xBD veri kümesi üzerinde eğitilmiştir. Ardından 2020 Beyrut Patlaması ve 2020 Laure Kasırgası'nda hasar gören binaların tespit edilmesi için kullanılmıştır. Model %79.2 F1-skoru elde etmiştir [25].

Sonuç olarak, literatürde, doğal afetlerin neden olduğu hasarlı alanların tespitine yönelik önemli ilerlemeler kaydedilmiştir. Geliştirilen başarılı algoritmalar ve çeşitli veri kaynaklarından yararlanma, araştırmacıların daha doğru ve etkili hasar tespit sistemleri oluşturmasına olanak sağlamıştır. Ayrıca, kamuya açık veri kümeleri ve bu veri kümeleri üzerinde yapılan çalışmalar, afet sonrası müdahalelerin hızını ve doğruluğunu artırma potansiyeline sahip otomatik sistemlerin geliştirilmesine önemli katkılar sunmuştur. xBD, MEDIC ve Incidents gibi veri kümeleri, bu alandaki çalışmalar için önemli kaynaklar sağlarken, özellikle depremler gibi belirli afet türlerine odaklanan veri kümelerinin eksikliği, bu alanın daha fazla araştırma ve geliştirme gerektirdiğini göstermektedir. Hasar tespitinde doğru veri kümelerinin seçilmesi ve analiz edilmesi için uygun metodolojilerin kullanılması, afet müdahale sistemlerinin etkinliğini ve doğruluğunu artırmak için kritik öneme sahiptir. Bu nedenle, mevcut veriler ve istenen sonuçlar bağlamında her bir yöntemin uygunluğunu araştırmak, uydu görüntülerinden hasar değerlendirmesini optimize etmek için oldukça önemlidir.

3
VERİ KÜMESİ

Bu tez çalışmasında hazırlanan TE23D veri kümesi, Türkiye'de 6 Şubat 2023 tarihinde meydana gelen depremlerin ardından toplanan yüksek çözünürlüklü uydu görüntülerinden oluşan kapsamlı bir veri kümesidir. Bu yıkıcı depremler Türkiye'de 10 farklı şehirde binalarda ve altyapıda büyük hasara yol açmış, çok geniş bir alanı kapsaması nedeniyle, hasarlı binalarda mahsur kalan kişileri kurtarma, sağlık, yeme, içme, barınma hizmetlerini kısa sürede etkin bir şekilde organize etmekte güçlükler yaşanmıştır.

TE23D veri kümesinin temel amacı, deprem sonrası hasar tespiti için yapılacak makine öğrenmesi tabanllı çalışmalarda kullanılabilecek kapsamlı bir kaynak sağlamaktır. Bu kapsamda yapılacak çalışmalar sayesinde, ciddi şekilde etkilenen alanların hızlı bir şekilde belirlenmesine, acil yardım ve yeniden yapılanma çabaları için önceliklendirilmesine olanak tanındığından, hızlı ve etkili afet müdahalesine önemli bir katkı sağlanmış olacaktır.

TE23D, depremlerden etkilenen çeşitli bölgeleri kapsayan ve farklı kentsel ve kırsal manzaralardaki hasar çeşitliliğini yakalayan çok çeşitli uydu görüntüleri içerir. Bu çeşitlilik, farklı bağlamlar ve bina hasarı türleri arasında iyi genelleme yapabilen sağlam makine öğrenimi modelleri geliştirmek için gereklidir. Veri kümesi yalnızca tamamen çökmüş binaların görüntülerini değil, aynı zamanda kısmi hasar, yapısal tehlikeler ve diğer bozulma biçimlerini de içermektedir. Bu kapsamlı yaklaşım, TE23D üzerinde eğitilen modellerin, etkili yeniden inşa ve kurtarma stratejilerinin planlanması için kritik olan deprem hasarının ayrıntılı ve incelikli değerlendirmelerini sağlayabilmesi için önemlidir.

TE23D'nin geliştirilmesinde, afet sonrası hasar tespitlerinin hızını ve doğruluğunu artırmaya yönelik acil ihtiyaç etkili olmuştur. Geleneksel hasar tespit yöntemleri, özellikle büyük bir depremin ardından yaşanan kaos ortamında zaman alıcı ve emek yoğun olabilen manuel incelemeleri ve sahada yapılan araştırmaları içerir. TE23D, uydu görüntülerinin ve makine öğreniminin gücünden yararlanarak bu

süreçte devrim yaratmayı ve afet müdahale ve kurtarma çalışmalarını önemli ölçüde hızlandırabilecek gerçek zamanlı değerlendirmelere olanak sağlamayı amaçlamaktadır.

Ayrıca TE23D, literatürün gelişimi için kritik bir kaynak olarak hizmet vermekte ve afetlere dayanıklılık ve zarar azaltma konusunda giderek artan araştırmalara katkıda bulunmaktadır. TE23D veri kümesi kamuya açık hale getirilerek; araştırmacılar, uygulayıcılar ve politikacılar arasındaki işbirliğini teşvik ederek gelecekteki depremlerin ve diğer doğal afetlerin etkilerini azaltabilecek yenilikçi çözümlerin geliştirilmesini teşvik etmektedir. Veri kümesine ait ham görüntüler Şekil 3.1'de görülebilir. Ham görüntüler, veri kümesinin farklı jeolojik koşullara ve şehir manzaralarına sahip bölgelerden alındığını ve farklı düzeylerde hasar örnekleri içerdiğini göstermektedir.



Şekil 3.1 Veri kümesine ait ham görüntüler

Literatür taramasında belirtildiği üzere, 6 Şubat 2023 Türkiye Depremleri için afet öncesi görüntülerin mevcudiyeti ve güncelliği en büyük problemlerden biriydi. Mevcut afet öncesi görüntüler genellikle birkaç yıl öncesine aitti veya bazı durumlarda belirli bölgeler için hiç afet öncesi görüntü mevcut değildi. Bu güncel

afet öncesi görüntü eksikliği, hasar tespiti ve segmentasyon için etkili modeller oluşturmada önemli bir zorluk teşkil etmiştir. Deprem tarihinden yıllar öncesine dayanan afet öncesi görüntüler ile deprem sonrası kaydedilen görüntüler arasındaki zaman farkı, şehir manzaralarının önemli ölçüde değiştiği anlamına geliyor ve deprem hasarıyla ilgisi olmayan çok sayıda değişkenin devreye girmesi nedeniyle potansiyel olarak modelleri daha az etkili hale getirmektedir.

Bu zorluklar göz önüne alındığında, çalışma, afet öncesi görüntülerdeki zamansal değişiklikler ve tutarsızlıklarla ilgili sorunları aşmak için yalnızca deprem sonrası görüntülere odaklanmıştır. Bu yaklaşım, tüm görüntülerin aynı zaman dilimini ve çevresel koşulları yansıtmasını sağlayarak modellerin eğitilmesi ve doğrulanması için daha doğru bir temel sağlar. Yalnızca deprem sonrası görüntülere odaklanılması kararı, hasar tespitinde hassasiyet ve güvenilirlik ihtiyacından kaynaklanmıştır. Bu yöntem, güncelliğini yitirmiş veya mevcut olmayan afet öncesi görüntülerin yol açtığı karmaşıklıkları ortadan kaldırarak veri kümesinin güncel olmasını ve afet sonrası koşulları yansıtmasını sağlar. Ayrıca, afet öncesi ve sonrası birleşik veri kümelerini etkileyen zamansal tutarsızlıklar ve çevresel varyasyonlardan kaçınarak, hasarlı binaları tanımlama ve segmentasyonda daha etkili ve doğru modeller geliştirilebilir.

3.1 Veri Kaynağı

6 Şubat 2023 Türkiye Depremlerinden etkilenen bölgelerden çekilen uydu görüntülerinden oluşan veri kümesindeki görüntüler, yüksek çözünürlüklü görüntüleme kabiliyetine sahip gelişmiş SkySat Uydu ağı kullanılarak elde edilmiştir. SkySat uyduları, piksel başına yaklaşık 0,5 metre gibi etkileyici bir çözünürlükte görüntü sağlayarak yeryüzünün ayrıntılı bir şekilde gözlemlenmesine olanak tanır ve binalarda ve altyapıda meydana gelen hasarın doğru bir şekilde tespit edilip değerlendirilmesini mümkün kılar.

Veri toplama çalışmalarında toplam 15 adet yüksek çözünürlüklü GeoTIFF görüntüsü toplanmıştır. Bu görüntüler, depremden etkilenen bölgedeki dört büyük şehri ve on bir ilçeyi kapsamakta ve etkilenen alanların kapsamlı bir şekilde temsil edilmesini sağlamaktadır. Bu görüntülerin yüksek çözünürlüğü, makine öğrenimi modellerinin yapılı çevredeki ince ayrıntıları ayırt etmesine olanak tanıdığından, hassas hasar tespiti ve segmentasyonu sağlamak için çok önemlidir.

Tablo 3.1, bu görüntülerin çekildiği şehirlerin yanı sıra ilgili çözünürlükler ve görüntülerin kapladığı alanın yüzölçümünü göstermektedir. Bu tablo, veri kümesinin kapsamını ve ölçeğini vurgulamakta, genişliğini ve içerdiği kentsel

ve kırsal ortamların çeşitliliğini göstermektedir. Birden fazla şehir ve ilçeyi kapsayan veri kümesi, sağlam ve çok yönlü hasar tespit modellerinin eğitilmesi için gerekli olan farklı arazi ve altyapı türlerinde depremlerin yarattığı çeşitli etkileri yansıtmaktadır.

Tablo 3.1 Veri kümesindeki görüntülerin alındığı şehirler, görüntü çözünürlükleri ve kapladıkları alanları gösteren tablo.

Şehir	**Çözünürlük(piksel)**	**Yüzölçümü($\sim$km^2)**
Adıyaman	11256 × 14271	40,15
Adıyaman	6611 × 10164	16,79
Gaziantep	5393 × 9841	13,26
Gaziantep	6825 × 4048	6,9
Hatay	10892 × 17204	46,84
Hatay	10019 ×19564	49
Hatay	10223 × 18766	47,96
Hatay	11503 × 23615	67,91
Hatay	11126 × 5912	16,44
Hatay	8351 × 8186	17,09
Hatay	10752 ×18776	50,46
Hatay	4248 × 9985	10,60
Hatay	9656 × 14662	35,39
Kahramanmaraş	10475 × 7664	20,07
Kahramanmaraş	12199 × 14054	42,86

Veri kümesine dahil edilen şehirler, depremin etkisinin ciddiyetine ve net, yüksek kaliteli uydu görüntülerinin mevcudiyetine göre stratejik olarak seçilmiştir. Bu bölgeler önemli yapısal hasara maruz kalmıştır ve bu da onları hasar tespit modelleri geliştirmeyi amaçlayan bir veri kümesine dahil etmek için uygun yerler haline getirmiştir. Toplanan görüntüler, afet sonrası manzaranın değerli bir anlık görüntüsünü sunarak hasarın boyutu ve en çok etkilenen belirli alanlar hakkında fikir vermektedir.

Ayrıca, SkySat uydu ağının kullanılması, görüntülerin yalnızca yüksek çözünürlükte değil, aynı zamanda kalite açısından da tutarlı olmasını sağlar. Bu tutarlılık, makine öğrenimi algoritmalarını potansiyel olarak karıştırabilecek değişkenliği azalttığı için veri kümesinin güvenilirliğini ve doğruluğunu korumak açısından büyük önem taşımaktadır. Farklı bölgelerdeki görüntü çözünürlüğü ve kalitesindeki tutarlılık, veri kümesinin güvenilirliğini ve doğruluğunu korumak açısından temel unsurlardan biridir.

3.2 Etiketleme Stratejisi

Veri kümesini etiketleme süreci, 15 yüksek çözünürlüklü (Tablo 3.1) GeoTIFF görüntüsünün 1024x1024 piksellik daha küçük, yönetilebilir yamalar halinde kırpılmasıyla başlamıştır. Daha küçük yamalarla çalışmak daha hassas etiketleme ve model eğitimini kolaylaştırdığından, bu adım görüntülerin verimli bir şekilde kullanılması ve işlenmesi için önemli bir fayda sağlamıştır.

Veri kümesi etiketlenirken, hasarın tespit edilebilmesi için problemin görüntü sınıflandırma, nesne tespiti veya segmentasyon problemi olarak ele alınması değerlendirilmiştir. Literatür taramasında da görüldüğü üzere, hasar tespitinde problemin segmentasyon işlemi ile değerlendirilmesi görüntüdeki her pikseli sınıflandırarak hasarlı alanların tam şeklini ve kapsamının belirlenmesini sağlar. Bu durum, hasarın ciddiyetini ve mekansal dağılımını doğru bir şekilde değerlendirmek için kritik öneme sahiptir. Şekil 3.2'de problemin sınıflandırma, nesne tespiti ve segmentasyon problemi olarak değerlendirilmesi arasındaki fark gözlemlenebilir. Şekilde görüldüğü üzere problemin segmentasyon görevi olarak değerlendirilmesi hasarın konumunun ve biçiminin anlaşılması için çok daha hassas bilgi vermektedir. Bundan dolayı hasar tespiti probleminin segmentasyon problemi olarak değerlendirilmesine karar verilmiştir.



Şekil 3.2 Sırasıyla görüntü sınıflandırma, nesne algılama ve segmentasyon yöntemlerinin hasar tespiti problemi üzerindeki gösterimleri

Görüntülerin etiketlenmesi sırasında, makine öğrenimi alanında yaygın olarak kullanılan başarılı ve çok yönlü bir etiketleme platformu olan Label Studio aracı kullanılmıştır [27]. Etiketleme için poligon etiket türünün seçilmesi, hasar tespitiyle ilgili segmentasyon görevlerinde yaygın olarak kullanılması nedeniyle bilinçli olarak yapılmıştır [10, 13]. Poligon etiketleme yöntemi, etiketleyicilerin düzensiz şekilleri ve sınırları doğru bir şekilde çizmesine olanak tanıdığından, afet sonrası görüntülerdeki hasarlı yapıların genellikle karmaşık ve kaotik modellerini işaretlemek için idealdir. Poligon etiketleri kullanmanın önemli avantajlarından biri de esnekliklerdir. Poligonlar gerektiğinde diğer etiket türlerine kolaylıkla

dönüştürülebilir böylece farklı analiz türleri ve model eğitimleri için çok yönlülük sağlar. Bu uyarlanabilirlik, veri kümesini nesne tespiti ve sınıflandırma gibi segmentasyonun ötesinde çeşitli uygulamalar için kullanışlı hale getirir.

Etiketleme sürecinde dikkat edilmesi gereken önemli bir husus da uydu görüntülerinde görülebilen ayrıntı düzeyidir. Bazı görüntüler, uydunun ayakucu (off-nadir) açısı nedeniyle binaların yan görünümlerini yakalamış ve bu da binaların yapısal durumları hakkında ek bilgi sağlamıştır. Ancak bu durum tüm görüntülerde tutarlı bir şekilde geçerli olmamıştır. Çoğu durumda, uydu görüntüleri yeterli yan görünüm detayından yoksundur, bu durum yapısal hasarın boyutunu doğru bir şekilde belirlemeyi zorlaştırmaktadır. Bu sınırlamalar göz önüne alınarak, hasarı derecelendirmek(az-orta-çok hasar gibi) yerine yalnızca hasarın varlığının belirtildiği bir etiketleme sistemi tercih edilmiştir. Bu karar, eksik görsel bilgilere dayanarak potansiyel olarak yanıltıcı varsayımlarda bulunmaktan kaçınmak ve böylece etiketlemelerin güvenilirliğini ve doğruluğunu sağlamak için alınmıştır.

Deprem sonucu binaların çökmesi genellikle yapıların birbirinden ayırt edilemeyen moloz yığınları halinde parçalanmasına neden olur ve bu da hangi moloz yığınının hangi binaya ait olduğunun tek tek ayırt edilmesini zorlaştırır. Başka bir deyişle Şekil 3.4'te görüldüğü gibi deprem, binaların birden fazla yapıdan gelen enkazı tek bir kütle halinde birleştirecek şekilde çökmesine neden olur. Bu birleşme, münferit binaların sınırlarını belirsizleştirerek geniş ve kesintisiz yıkım alanlarının oluşmasına neden olur. Bu olgu, veri kümesinde poligonların etiketlenmesine de yansımıştır. Hasarlı sınıfın bir parçası olarak etiketlenen bir poligon mutlaka tek bir hasarlı binaya karşılık gelmez. Bunun yerine, deprem hasarının doğası gereği, birleşmiş moloz yığınlarının kapladığı tüm alanlar hasarlı olarak etiketlenir. Bu yaklaşım, veri kümesi üzerinde eğitilen modellerin hasarın tam kapsamını doğru bir şekilde tanımlayabilmesini ve bu hasarlı alanları hasarsız kentsel dokudan ayırt edebilmesini sağlar.

TE23D veri kümesi için üç farklı alt küme oluşturulmuştur: $TE23D_A$, $TE23D_{B1}$ ve $TE23D_{B2}$. Bu alt kümeler, çeşitli etiketleme stratejilerinin model performansı üzerindeki etkisini araştırmak için farklı etiketleme metodolojileri kullanılarak türetilmiştir.

3.2.1 $TE23D_A$ Veri Alt Kümesi için Etiketleme Stratejisi

$TE23D_A$ alt kümesi, hasarlı binaların kentsel çevre içinde anomaliler olduğu hipotezine dayanan ikili bir etiketleme stratejisi izlenerek görüntülerde yalnızca hasarlı alanların etiketlenmesiyle oluşturulmuştur. Bu hipotez, afetlerden

zarar gören binaların, sağlam binalar, parklar, köprüler ve diğer yapıları içeren kentsel peyzajın geri kalanına kıyasla aykırı değerler olduğunu ileri sürmektedir. Bu hipoteze bağlı kalınarak etiketleme işlemi yalnızca hasarlı binalara odaklanırken diğer tüm yapılar arka plan olarak ele alınır. Bu ikili yaklaşım, kategorizasyonun karmaşıklığını azaltarak ve etiketleyicilerin yalnızca hasarı belirlemeye odaklanmasını sağlayarak etiketleme sürecini önemli ölçüde basitleştirir.

Bu strateji, farklı bölgelerdeki sağlam yapıların görünümündeki değişkenliğe rağmen, hasarlı ve yıkılmış binaların küresel olarak benzer görsel özellikler sergileme eğiliminde olduğu gözlemiyle uyumludur. Hasar görünümündeki bu tutarlılık, deprem sonrası hasar tespiti için evrensel olarak uygulanabilir bir veri setinin oluşturulmasını desteklemektedir. Modelleri böylesine tutarlı bir veri kümesi üzerinde eğiterek, dünyanın dört bir yanındaki çeşitli kentsel ortamlarda deprem hasarını tanıyabilen ve değerlendirebilen algoritmalar geliştirmek mümkün hale gelir.

Görüntülerdeki tüm binaları etiketlemek sadece yoğun emek gerektirmekle kalmaz, aynı zamanda önemli miktarda gereksiz veri ortaya çıkarır ve potansiyel olarak hasar tespit modellerinin etkinliğini azaltır. Önerilen hipoteze göre, hasarlı alanlara odaklanan bir etiketleme süreci, hasar tespit sürecini geliştirerek daha verimli ve hedefe yönelik hale getirir. Bu odaklanmış etiketleme yaklaşımı, modelin hasarlı ve hasarsız alanları doğru bir şekilde belirleme ve ayırt etme yeteneğini geliştirir, böylece modellerin, genelleştirilmiş bir veri kümesinde gözden kaçırılabileceği daha lokal özelliklerin tespit edilmesi sağlanır.

Veri kümesi bu hipoteze dayalı olarak titizlikle oluşturulmuş ve yalnızca depremden etkilenen gözle görülür hasarlı alanlar etiketlenmiştir. Bu yaklaşım, vurgunun tüm kentsel peyzajdan ziyade anomaliler üzerinde kalmasını sağlar. Süreç, hasarın meydana geldiği belirli alanları belirlemek için uydu görüntülerinin ayrıntılı bir şekilde incelenmesini içermektedir. Bu etiketleme yöntemi birkaç farklı avantaj sunmaktadır. İlk olarak, işlenmesi gereken veri hacmini azaltarak hesaplama verimliliğini artırır. İkinci olarak, özellikle hasar tespit göreviyle ilgili veriler üzerinde eğitildikleri için daha sofistike ve doğru modellerin geliştirilmesine olanak tanır. Üçüncü olarak, modeller anomalilere odaklanarak daha genelleştirilmiş bir veri kümesinde gözden kaçabilecek ince hasar belirtilerini tespit etmeyi öğrenebilir.

Özetle, hasarın bir anomali olarak kabul edilebileceği hipotezi, $TE23D_A$ Veri Alt Kümesinin oluşturma yaklaşımının temelini oluşturmaktadır. Veri kümesi, yalnızca hasarlı alanlara odaklanarak depremin etkisinin daha net ve kesin bir temsilini

sağlamaktadır. Bu hedefli yaklaşımı ile segmentasyon sürecini kolaylaştırmanın, aynı zamanda hasar tespit modellerinin doğruluğunu ve etkinliğini de arttırmak amaçlanmıştır. Bu hipotezi test etmek ve doğrulamak için, veri kümesi üzerinde binaların etiketlenmesi ihtiyacı doğmuştur. Binaların etiketlenmesinin manuel olarak yapılması büyük miktarda iş yükü gerektireceğinden dolayı bina etiketlemesinin otomatize edilmesine karar verilmiştir. Binaların etiketlenebilmesi için iki farklı yöntem benimsenmiş ve binaların etiketli olduğu $TE23D_{B1}$ ve $TE23D_{B2}$ veri kümeleri oluşturulmuştur.

3.2.2 $TE23D_{B1}$ Veri Alt Kümesi için Etiketleme Stratejisi

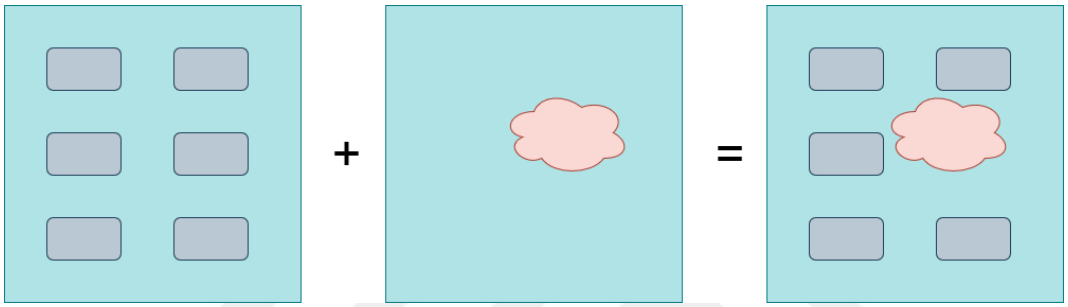
Daha önce bahsedildiği üzere binalar ve şehir peyzajı farklı lokasyonlarda çok farklı özellikler sergileyebilmektedir. Bundan dolayı ülkemizdeki binaları içeren ve benzer uzaysal çözünürlüklerde görüntülerden oluşan veri kümeleri üzerinde eğitilmiş bir segmentasyon modeline ihtiyaç duyulmuştur. Bakırman ve arkadaşları tarafından yapılan çalışmada detaylandırıldığı üzere, mevcut veri kümesindekine benzer çözünürlüklere sahip yüksek çözünürlüklü uydu görüntülerinden oluşan İstanbul Veri Kümesi üzerinde eğitilmiş U-Net++ modeli aynı veri kümesi üzerinde %93.8 IoU skoru elde ederek en başarılı sonuçlara ulaşmıştır [28]. Her iki veri kümesinin de Türkiye'den binalar içerdiği ve benzer uzaysal çözünürlüklere sahip uydu görüntülerinden oluştuğu göz önüne alındığında, mimari stiller ve yapısal özellikler yeterince benzerdir, dolayısıyla modelin bu bağlamda uygulanabilirliği ve güvenilirliği sağlanmıştır. Ardından bu model kullanılarak $TE23D_A$ veri alt kümesi üzerindeki binalar tespit edilmiştir.

3.2.3 $TE23D_{B2}$ Veri Alt Kümesi için Etiketleme Stratejisi

$TE23D_{B2}$ veri kümesi, hipotezin daha güvenilir şartlar altında test edilebilmesi amacıyla oluşturulmuştur. Böylece $TE23D_{B1}$ veri kümesi üzerindeki yanlış etiketlenmelere dayanabilecek kuşkuların azaltılması hedeflenmiştir. Volodymyr Mnih tarafından 2013 yılında tanıtılan Massachusetts Buildings Dataset bina tespiti alanında önde gelen veri kümelerindendir [29]. Veri kümesi üzerinde U-Net modeli eğitilmiştir. Veri kümesinin, test kümesi üzerinde %79.26 IoU skorları elde edilmiştir. Ardından bu model kullanılarak $TE23D_A$ veri alt kümesi üzerindeki binalar tespit edilmiştir.

$TE23D_{B1}$ veri kümesi ve $TE23D_{B2}$ veri kümesi oluşturulurken; bina segmentasyon modelleri $TE23D_A$ veri kümesi üzerinde, hasarlı olarak etiketlenen bölgeler içinde bir alanı bina olarak tanımlarsa, orijinal hasar etiketleri korunmuştur. Bu karar, bu veri kümesi hazırlanırken manuel olarak gerçekleştirilen etiketlemelerin,

modellerin genelleştirilmiş tahminlerinden daha doğru ve güvenilir olacağı varsayımına dayanmaktadır. Böylece, yalnızca model tahminlerinden kaynaklanan ve hasarlı bölgelerin bina olarak etiketlenmesinde neden olabilecek potansiyel yanlış sınıflandırmalardan kaçınılmıştır. Şekil 3.3'te mavi alanlar arkaplanı, kırmızı alanlar hasarlı alanları ve gri alanlar binaları göstermektedir. Soldaki ilk görüntüde herhangi bir yama üzerinde, bina segmentasyon modeli kullanılarak binaların segmente edilmesi gösterilmiştir. Ardından ortadaki görüntüde aynı yamanın $TE23D_A$ veri kümesindeki karşılığı betimlenmiştir. Sağdaki görüntüde ise; bu iki görüntünün üst üste bindirilerek bina ve hasarlı alanın kesişmesi durumunda, kesişen bölgenin hasarlı olarak etiketlenmesi ve bina etiketinin kaldırılması anlatılmıştır.



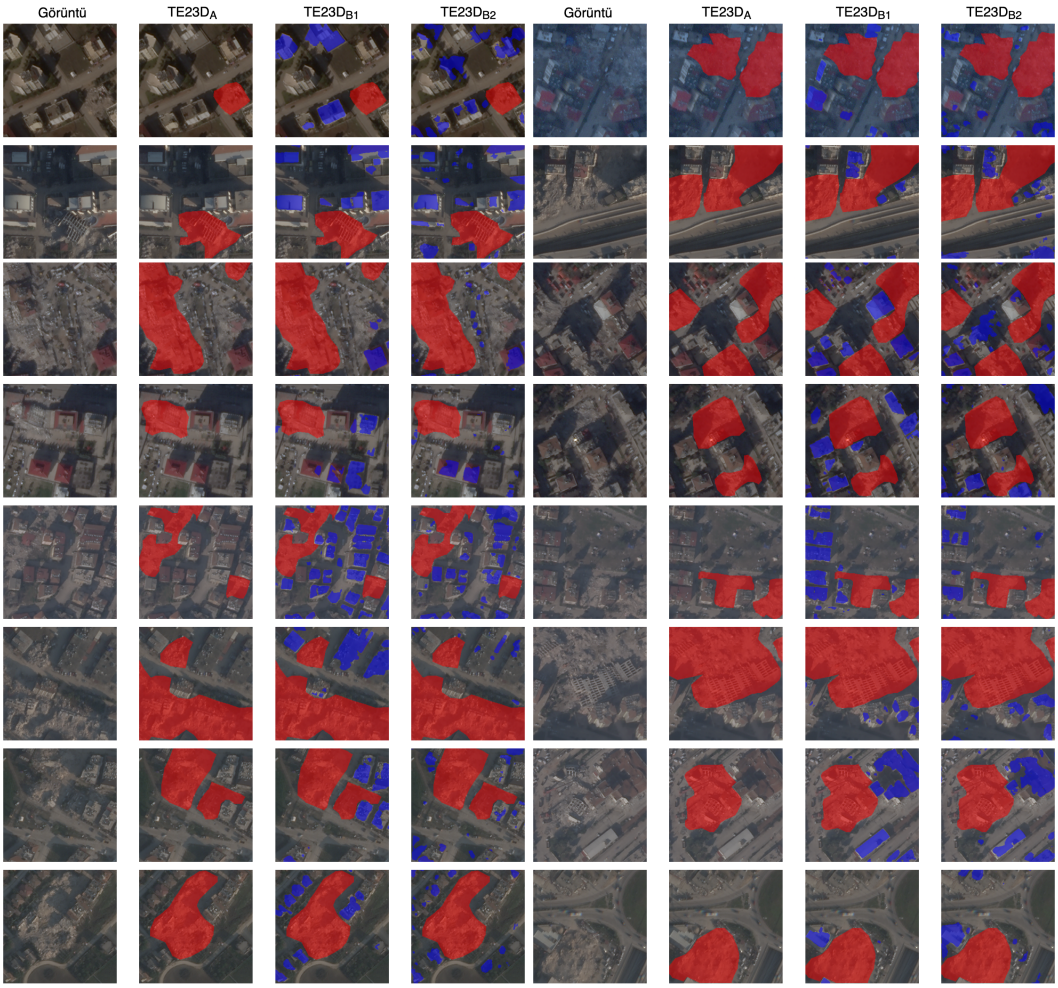
Şekil 3.3 Soldan sağa sırayla; veri kümesinden bir yama üzerinde modeller kullanılarak tespit edilmiş binaların temsili, $TE23D_A$ veri kümesinde aynı yama üzerindeki hasarlı alanın temsili ve aynı yamanın $TE23D_{B1}$ veya $TE23D_{B2}$ veri kümesindeki temsili

Uydu görüntülerini ve görüntülerin üç veri kümesi üzerindeki temsillerini gösteren Şekil 3.4'te kırmızıyla boyanmış alanlar hasarlı alanları, maviyle boyanmış alanlar ise binaları göstermektedir.

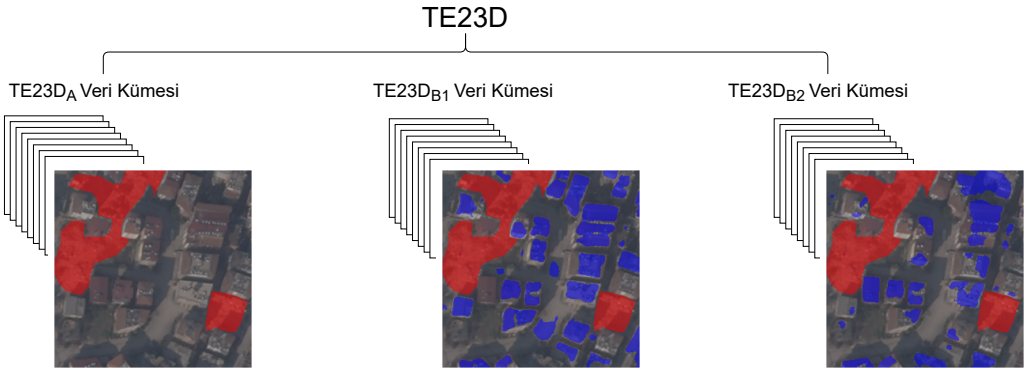
Şekil 3.5'te TE23D veri kümesi tüm alt kümeleriyle birlikte görülebilir. Şekilde, TE23D alt kümeleri olan yalnızca hasarlı alanların etiketli olduğu $TE23D_A$ veri kümesi, binaların İstanbul Veri Kümesi üzerinde eğitilen U-Net++ modeli kullanılarak etiketlendiği $TE23D_{B1}$ veri kümesi ve Massachusetts Buildings Dataset üzerinde eğitilen U-Net modeli kullanılarak etiketlendiği $TE23D_{B2}$ veri kümesi görülebilir.

3.3 Veri Kümesinin Son Haline Getirilmesi

Etiketleme işlemleri tamamlandıktan sonra, veri kümesinin ayrıntılı bir şekilde değerlendirilmesiyle hasarlı alanlar ile arka plan alanları arasında önemli bir dengesizlik olduğu ortaya çıkmıştır. Hasarlı alanlar tüm veri kümesinin sadece küçük bir kısmını oluştururken, çoğunluğu hasarsız, arka plandaki alanların



Şekil 3.4 Uydu görüntüleri (birinci ve beşinci sütunlar), Uydu görüntülerinin TE23D$_A$ veri kümesindeki temsili (ikinci ve altıncı sütunlar), Uydu görüntülerinin TE23D$_{B1}$ veri kümesindeki temsili (üçüncü ve yedinci sütunlar) ve Uydu görüntülerinin TE23D$_{B2}$ veri kümesindeki temsili (dördüncü ve sekizinci sütunlar).



Şekil 3.5 TE23D veri kümesinin genel şablonu.

oluşturduğu görülmüştür. Kentsel ortamlarda moloz ve sağlam binalar arasında doğru ayrım yapabilen makine öğrenimi modelleri geliştirme hedefimiz göz önüne alındığında, büyük hacimli arka plan verilerini korumanın verimsiz ve gereksiz olduğu düşünülmüştür. Böyle bir dengesizlik yalnızca hesaplama kaynaklarını boşa harcamakla kalmayacak, aynı zamanda eğitim sürecini potansiyel olarak çarpıtarak daha az etkili model performansına yol açacaktı.

Hasarlı ve arka plan alanları arasındaki dengesizliği gidermek için her üç veri kümesindeki orijinal 1024x1024 piksel görüntüler 256x256 piksellik daha küçük yamalar halinde kırpılmıştır. Kırpma işleminin ardından, hasarlı alan içermeyen tüm yamalar veri kümesinden çıkarılmıştır. Uygulanan strateji Şekil 3.6'da gösterilmiştir. Mavi alan hasarlı alan olarak düşünüldüğünde; 1024x1024 piksel boyutlarındaki görüntüler 256x256 piksellik yamalara bölünmüş ve hasarlı alan içeren yeşil yamalar veri kümesinde tutulmuş, içermeyen kırmızı yamalar ise çıkarılmıştır. Şekildeki kırmızı ve yeşil yamaların içerisinde $TE23D_{B1}$ veya $TE23D_{B2}$ alt kümelerinde bina etiketlerinin bulunduğu ayrıca not düşülmelidir.

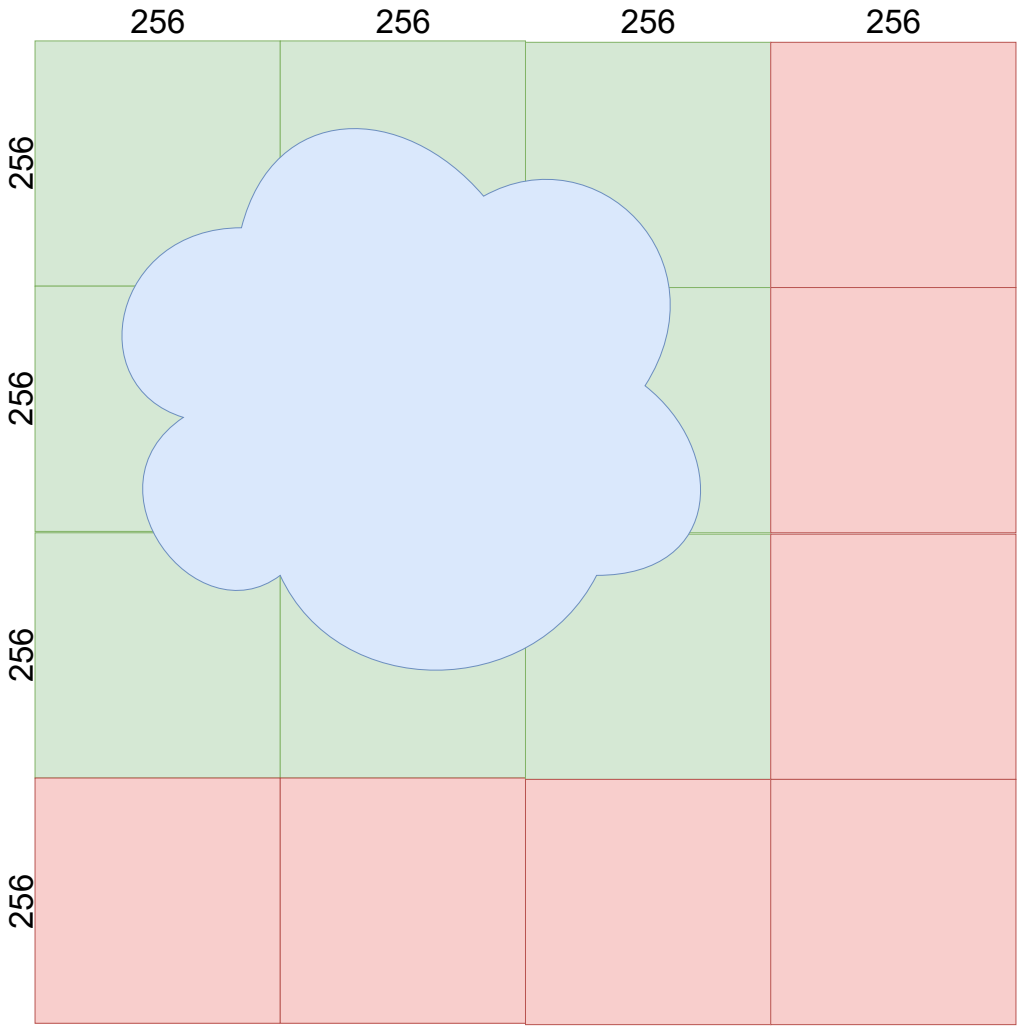
Bu seçici dahil etme başka bir deyişle hasar içermeyen yamaların çıkarılması işlemi iki amaca hizmet eder. Bilgilendirici olmayan verilerin hacmini azaltarak hesaplama verimliliği için veri kümesini optimize eder, böylece model eğitimi için gereken işlem süresini ve kaynakları azaltır. Ayrıca, veri kümesinin hasarlı ve hasarsız alanların dengeli bir temsilini sürdürmesini sağlar, bu da ikisi arasında doğru bir şekilde ayrım yapabilen modeller geliştirmek için kritik öneme sahiptir. Bu yaklaşım, modellerin görevle doğrudan ilgili veriler üzerinde eğitilmesini sağlayarak afet sonrası senaryolarda hasarlı binaların belirlenmesi ve segmente edilmesinde daha iyi performans ve doğruluk sağlar.

En son halinde, TE23D veri kümesinin her bir alt kümesi, 1183 görüntü ve hasarlı olarak etiketlenmiş 2080 poligon içermektedir. Veri kümeleri daha sonra model geliştirme ve değerlendirmeyi kolaylaştırmak için eğitim, doğrulama ve olmak üzere test üç farklı parçaya ayrılmıştır. Tablo 3.2, görüntülerin ve etiketlerin farklı parçalar arasındaki dağılımını göstererek ayrıntılı bir analizini sağlamaktadır.

Tablo 3.2 TE23D alt kümelerinin eğitim-doğrulama-test parçalarının dağılımı

Parça	Görüntü Sayısı	Hasar Etiketli Poligon Sayısı
Eğitim	947	1669
Doğrulama	118	197
Test	118	214

Özet olarak, veri kümesi, 6 Şubat 2023 Türkiye depremleri sonrasında ortaya çıkan yıkımın detaylı bir görünümünü yakalayan yüksek çözünürlüklü uydu



Şekil 3.6 1024x1024 piksel boyutlarındaki görüntülerin, 256x256 piksellik yamalara bölünmesini ve hasarlı alan içeren yeşil yamalar veri kümesinde tutulup, hasar içermeyen kırmızı yamaların çıkarılmasını gösteren şekil.

görüntüleri sayesinde çeşitli hasar türlerinin ayrıntılı ve kapsamlı bir tasvirini sunar. Çeşitli hasar türlerinin dahil edilmesi, depremlerin neden olduğu yıkım türlerini genelleyerek; hasarı doğru bir şekilde tanımlayabilen makine öğrenimi modellerinin geliştirilmesi için önemlidir. Bu çeşitlilik, modellerin tam çökmelerden küçük yapısal bozukluklara kadar farklı hasar senaryoları altında eğitlmesini sağlayarak, çeşitli gerçek dünya koşullarında genelleme ve iyi performans gösterme yeteneklerini artırır. Araştırmacılar bu veri kümesi üzerinde modeller eğiterek, hasar değerlendirmesi yapabilen daha sofistike modeller geliştirebilirler. Bu modeller sonrasında daha kapsamlı afet müdahale stratejilerini oluşturmak için kullanılabilir.

Genel olarak, veri kümesi yalnızca afet sonrası acil değerlendirme için hayati bir araç olarak hizmet etmekle kalmaz, aynı zamanda depremin etkilerinin daha derinlemesine anlaşılmasına da katkıda bulunur. Afete hazırlık, müdahale ve zarar azaltma stratejilerini iyileştirebilecek ileri analitik yöntemlerin geliştirilmesini desteklemektedir. Deprem hasarına ilişkin ayrıntılı ve çeşitli bir bakış açısı sunan veri kümesi, nihayetinde toplumun direncini artırmayı ve gelecekteki sismik olayların olumsuz etkilerini azaltmayı amaçlayan daha etkili ve bilinçli karar alma süreçlerine olanak sağlamaktadır.

4
METODOLOJİ

Metodoloji bölümü, deprem hasar tespitine yönelik makine öğrenimi modellerinin geliştirilmesi ve değerlendirilmesi için kullanılan kapsamlı metodolojiyi özetlemektedir. Hasar tespiti probleminin bir segmentasyon problemi olarak ele alınmasına karar verilmesinin ardından, alt segmentasyon yöntemleri arasında karar verilmesi gerekliliği doğmuştur. Hasar tespiti bağlamında, segmentasyon yönteminin seçimi doğru ve verimli sonuçlar elde etmek için oldukça önemlidir.

Segmentasyon yöntemleri, anlamsal (semantic) segmentasyon, örnek (instance) segmentasyon ve panoptik segmentasyon olmak üzere üçe ayrılmaktadır. Segmentasyon yöntemleri hasar tespiti için değerlendirildiğinde, anlamsal segmentasyon en uygun yaklaşımdır çünkü görüntüdeki her bir pikseli hasarlı veya hasarsız alanlar gibi belirli bir kategoride sınıflandırır. Bu yöntem, birincil hedefin aynı görüntüdeki farklı hasar örneklerini ayırt etmeye gerek kalmadan hasarı temsil eden tüm pikselleri tanımlamak ve etiketlemek olduğu hasar tespit hedefiyle iyi uyum sağlar. Bu basitleştirme avantajlıdır çünkü hesaplama karmaşıklığını azaltır ve daha akıcı bir analiz sağlar, bu da hızlı ve doğru hasar değerlendirmesinin gerekli olduğu büyük ölçekli afet müdahale senaryoları için idealdir.

Anlamsal segmentasyon tercih edilirken, örnek segmentasyon da bir seçenek olarak düşünülebilir. Örnek segmentasyon sadece her bir pikseli sınıflandırmakla kalmaz, aynı zamanda aynı kategorideki nesneleri veya örnekleri birbirinden ayırarak bir adım daha ileri gider. Bu, ayrı hasarlı yapılar veya alanlar arasında ayrım yapmanın gerekli olduğu durumlarda faydalı olabilir ve hasarın kapsamı ve dağılımı hakkında daha ayrıntılı bilgi sağlar. Ancak bu ilave karmaşıklık, hasarlı bölgeleri belirleme görevi için her zaman gerekli olmayabilir ve hesaplama karmaşıklığını artırabilir.

Öte yandan, sahnenin kapsamlı bir şekilde anlaşılmasını sağlamak için hem anlamsal hem de örnek segmentasyonunu birleştiren panoptik segmentasyon, genellikle hasar tespiti için gerekli değildir. Panoptik segmentasyon, her bir pikseli belirli bir nesne örneğine veya bir arka plan kategorisine ait olarak

etiketleyerek sahnenin eksiksiz bir yorumunu sunmayı amaçlar. Bu yöntem en ayrıntılı segmentasyonu sunarken, tek tek hasarlı örnekler arasındaki ayrımın o kadar kritik olmadığı hasar tespit görevleri için gereksiz karmaşıklık getirir. Bu nedenle, anlamsal segmentasyon, afetten etkilenen ortamlarda hasarlı alanların verimli bir şekilde tanımlanması ve etiketlenmesi için en uygun seçim olmaya devam etmekte ve sürecin hem etkili hem de hesaplama açısından yönetilebilir olmasını sağlamaktadır.

Bu koşullar değerlendirildiğinde anlamsal segmentasyonun hasar tespiti için ideal yöntem olduğu düşünülmüştür. Ancak örnek segmentasyon yönteminin de değerlendirilmesi gerektiği fikriyle hareket edilerek temel olarak yedi model seçilmiştir. Bu modeller anlamsal segmentasyon için, BeiT, DPT, MobileViT, SegFormer, U-Net ve U-Net++ ve örnek segmentasyon için Mask R-CNN modeli olmak belirlenerek segmentasyon görevlerine yönelik farklı yaklaşımların kapsamlı bir değerlendirmesinin sağlanması amaçlanmıştır. Bu modeller, görüntü segmentasyonundaki benzersiz yetenekleri ve başarıları nedeniyle seçilmiştir. Modeller son yıllarda geliştirilmiş çeşitli yöntemlerin geniş bir yelpazesini sunmaktadır.

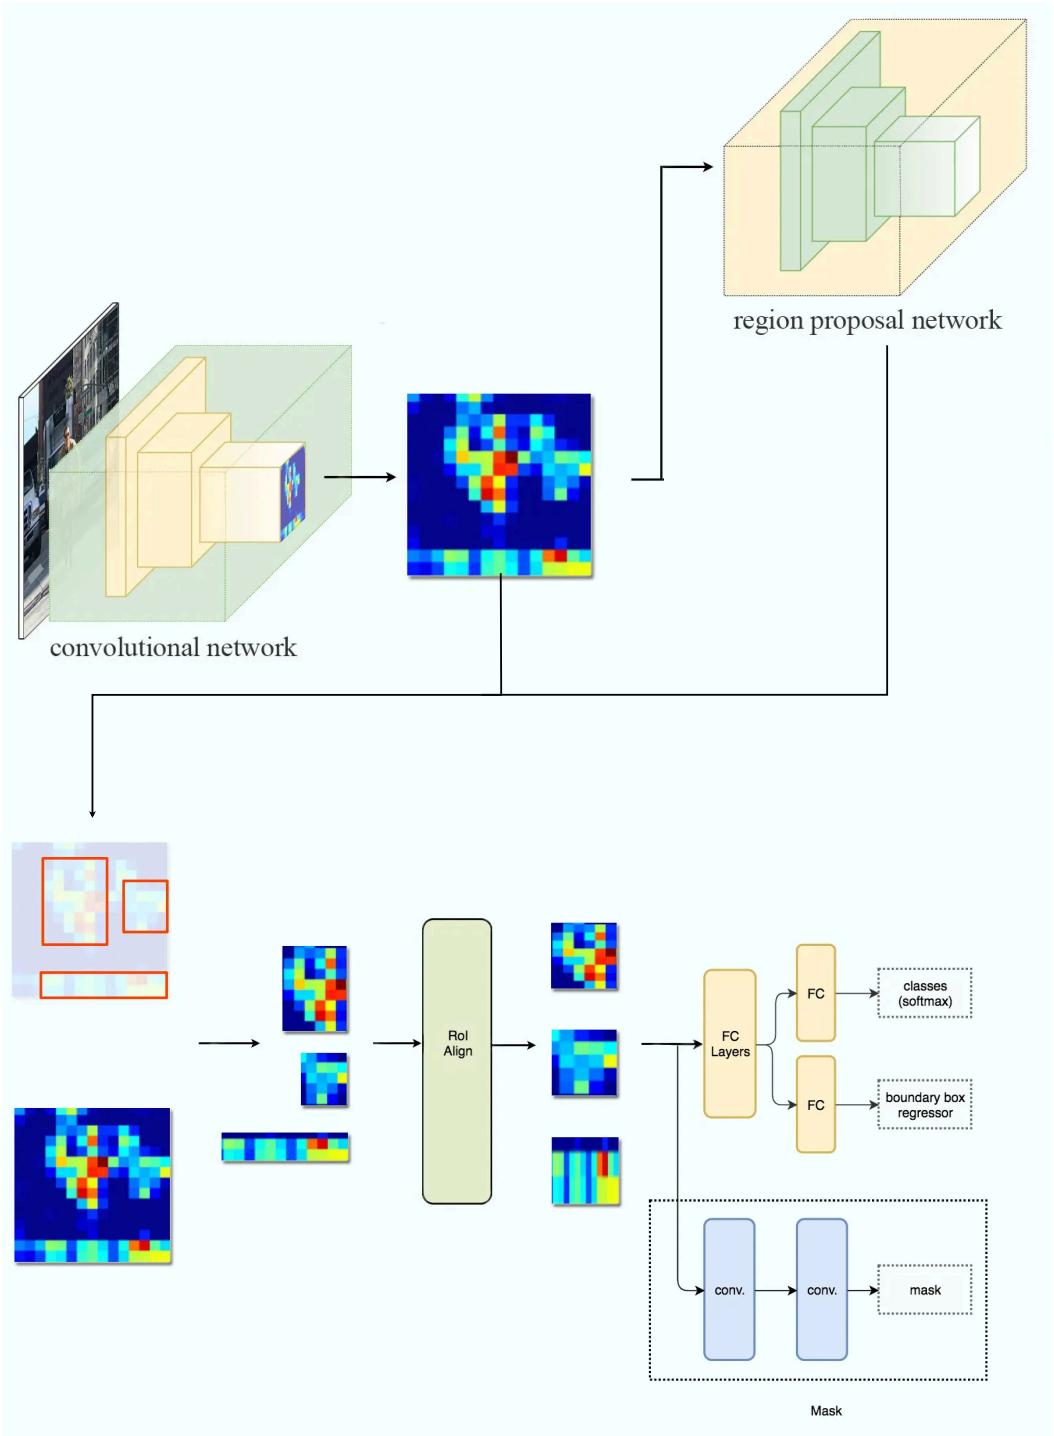
4.1 Örnek Segmentasyon ile Hasar Tespiti

4.1.1 Mask R-CNN Mimarisi

Mask R-CNN, Faster R-CNN çerçevesi üzerine inşa edilmiş bir segmentasyon mimarisidir [30, 31]. Nesne sınıflandırması ve sınırlayıcı kutuları belirlemenin yanında, tespit edilen her nesne için segmentasyon maskelerini tahmin eder. Şekil 4.1, Mask R-CNN mimarisini göstermektedir [32]. Süreç, bir giriş görüntüsünü alan ve özellik haritalarını çıkaran bir CNN ile başlar. Çıkarılan özellik haritaları daha sonra bunları tarayan ve nesne içermesi muhtemel bölgeler (sınırlayıcı kutular) öneren Bölge Öneri Ağına (RPN) beslenir. Önerilen her bölge, bir nesne içerme olasılığını gösteren bir puanla birlikte gelir. Bu öneriler daha sonra İlgi Bölgesi (RoI) Hizalama kullanılarak iyileştirilir, bu da özelliklerin iyi hizalanmasını ve uzamsal olarak kesin olmasını sağlar.

Hizalanan özellikler daha sonra üç çıkışa ayrılan kafa ağı tarafından işlenerek sınıflandırma yapılır, sınırlayıcı kutu belirlenir ve segmentasyon maskesi oluşturulur. Sınıflandırma dalı, önerilen her bölgedeki nesneyi sınıflandırmak için tam bağlı (fully connected) katmanlar ve ardından bir Softmax katmanı kullanır. Sınırlayıcı kutu regresörü, tespit edilen nesnelere daha iyi uyması için sınırlayıcı kutuların koordinatlarını daha da iyileştirir. Son olarak, küçük CNN olan maske

dalı, her sınıf için sınırlayıcı kutu içindeki nesneye ait tam pikselleri gösteren ikili bir maske üretir. Bu maske çıktısı örnek segmentasyonu için kullanılır. Genel olarak, Mask R-CNN, piksel düzeyinde segmentasyon için maske dalı ekleyerek Faster R-CNN'yi genişletir ve yalnızca nesneleri tespit etmekle kalmaz, aynı zamanda görüntüdeki her örnek için kesin maskeler sağlar.



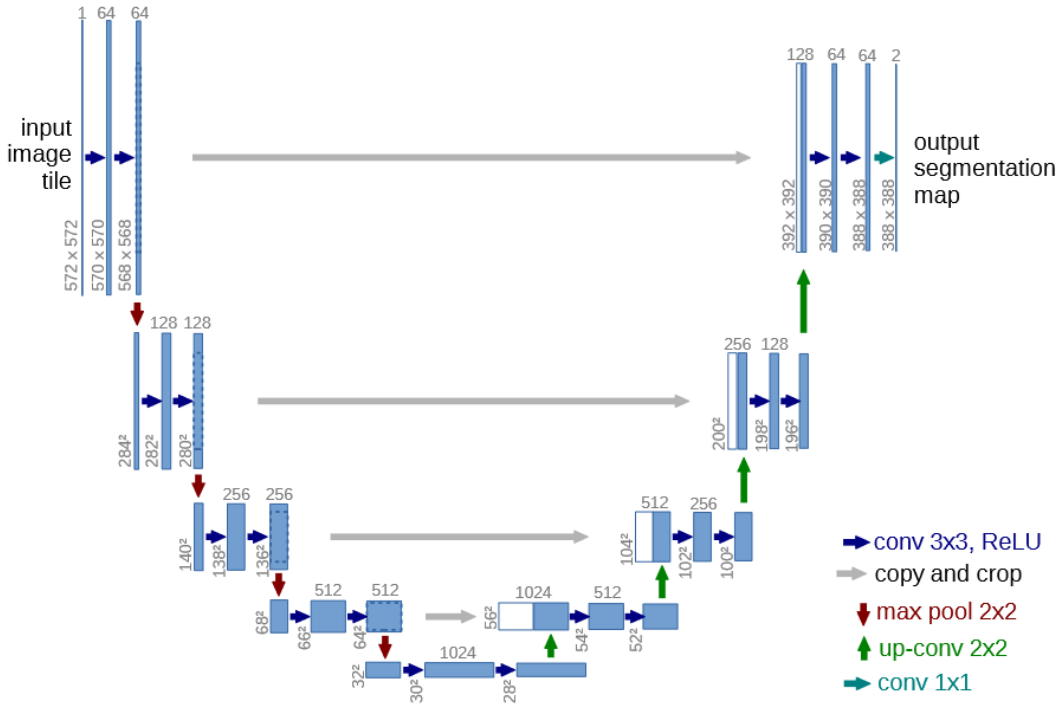
Şekil 4.1 Mask R-CNN Mimarisi

4.2 Anlamsal Segmentasyon ile Hasar Tespiti

4.2.1 U-Net Mimarisi

Ronneberger ve arkadaşları tarafından 2015 yılında tanıtılan CNN mimarisi olan U-Net mimarisi, ilk olarak tıbbi görüntülemede görüntü segmentasyonu üzerinde kullanılsa da segmentasyon görevlerinde çığır açan bir modeldir [33]. Simetrik U şeklindeki yapısıyla karakterize edilen ağ, yüksek çözünürlüklü uzamsal özelliklerin bağlamsal bilgilerle birleştirilmesini sağlayan atlama bağlantılarıyla(skip connections) birbirine bağlanan kodlayıcı (encoder), ve kod çözücü (decoder) yapısından oluşur. Kodlayıcı ve kod çözücü kısım arası da darboğaz (bottleneck) olarak adlandırılır.

Kodlama her biri iki adet 3x3 CNN ardından ReLU aktivasyonları ve 2 adımlı 2x2 maksimum havuzlama (max pool) işleminden oluşan bir dizi katman aracılığıyla gerçekleştirilir. Bu yol, özellikleri birden fazla ölçekte çıkararak bağlamı etkili bir şekilde yakalar; özellik kanallarının sayısı, başlangıçtaki küçük bir sayıdan (Şekil 4.2'de 64) başlayarak ve ağ derinleştikçe artarak her aşağı örnekleme adımından sonra iki katına çıkar.



Şekil 4.2 U-Net Mimarisi

Ağın en derin noktasında darboğaz, kodlayıcıyı kod çözücüye bağlar. Giriş görüntüsünün en soyut özelliklerini yakalayan ReLU aktivasyonları tarafından takip edilen iki adet 3x3 CNN'den oluşur. Ağın bu merkezi kısmı, kodlayıcıdan gelen ayrıntılı yerelleştirme ile doğru segmentasyon için gereken üst düzey özellikler

arasında bir denge sağlayarak köprü görevi görür.

Kod çözücü, özellik kanallarının sayısını azaltırken özellik haritalarının uzamsal boyutlarını kademeli olarak artırarak segmentasyon haritasını yeniden yapılandırır. Bu yoldaki her katman, özellik kanallarının sayısını yarıya indiren, tipik olarak 2x2 transpoze konvolüsyon olan bir yukarı örnekleme (upsampling) işlemi içerir. Yukarı örneklenmiş özellik haritaları daha sonra atlama bağlantıları aracılığıyla kodlayıcıdan gelen ilgili özellik haritalarıyla birleştirilir. Bu bağlantılar, ağın kodlayıcıdan gelen ince taneli özellikleri yeniden kullanmasını sağlayarak doğruluğu artırır. Birleştirmenin ardından, ReLU aktivasyonlarına sahip iki adet 3x3 konvolüsyonel katman uygulanır.

Son çıktı katmanı, işlenmiş özellik haritalarını istenen sayıda sınıfa eşleyen 1x1 konvolüsyonel katmandan ve ardından çok sınıflı segmentasyon için bir softmax aktivasyon fonksiyonundan veya ikili segmentasyon için bir sigmoid aktivasyon fonksiyonundan oluşur. Bu katman, giriş görüntüsüyle aynı uzamsal boyutlara sahip olan ancak farklı sınıfları temsil eden belirli sayıda çıkış kanalına sahip nihai segmentasyon haritasını üretir.

Bu iki taraflı mekanizma, U-Net'in karmaşık yapıları segmentlere ayırmada yüksek doğruluk elde etmesini ayrıca düşük ve yüksek seviyeli özellikleri etkili bir şekilde entegre etmesini sağlar. Yüksek performansı ve uyarlanabilirliği, uygulamasını tıbbi görüntülemenin ötesinde uydu görüntüleri, tarım ve genel nesne segmentasyonu gibi alanlara genişletmiştir. Model mimarisi Şekil 4.2'de incelenebilir.

4.2.2 U-Net++ Mimarisi

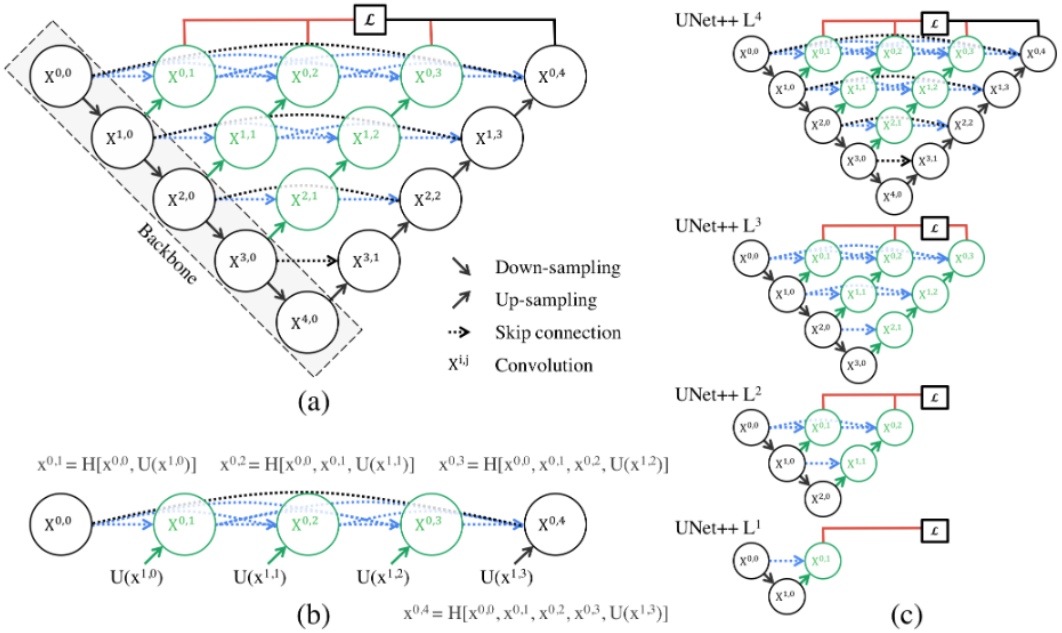
Orijinal U-Net mimarisinin gelişmiş bir varyantı olan U-Net++, iç içe ve yoğun atlama bağlantılarını dahil ederek segmentasyon görevlerindeki sınırlamaları ele almak için Zhou ve arkadaşları tarafından geliştirilmiştir [34]. U-Net++, özünde U-Net ile aynı kodlayıcı-kod çözücü yapısını korur, ancak yeniden tasarlanmış atlama bağlantıları ile iç içe geçmiş ve yoğun bir mimari sunar. Kodlayıcı yolu, giriş görüntüsünü aşamalı olarak aşağı örnekleyerek çoklu evrişim katmanları ve havuzlama işlemleri yoluyla özellikleri çıkarır. Tersine, kod çözücü yolu segmentasyon haritasını oluşturmak için özellik haritalarını aşamalı olarak yukarı örneklemektedir. U-Net++'da kodlayıcı ve kod çözücü arasındaki atlama bağlantıları doğrudan değildir. Bunun yerine, kodlayıcının her aşamasını kod çözücünün ilgili aşamasına bağlayan bir dizi ara katman olarak yeniden tasarlanırlar. Bu bağlantılar bir dizi evrişimsel katmandan geçerek ara özellik

haritasıyla sonuçlanır. Bu yoğun bağlantı, farklı soyutlama seviyelerindeki özelliklerin daha rafine bir şekilde bir araya getirilmesine olanak tanıyarak modelin segmentasyon görevindeki karmaşık ayrıntıları yakalama becerisini geliştirir.

U-Net++'daki bir diğer önemli gelişme de derin denetimdir. Sadece nihai çıktının denetlendiği orijinal U-Net'in aksine, U-Net++ ara katmanların çıktılarına da denetim uygular. Bu, segmentasyon haritalarının sadece son katmanda değil, aynı zamanda ağ içindeki çeşitli ara katmanlarda da oluşturulduğu anlamına gelir. Bu sayede ağ, her seviyede daha anlamlı özellikler öğrenmeye zorlanır, bu da eğitim sırasında gradyan akışını geliştirir ve daha iyi yakınsama ve performansla sonuçlanır.

Ayrıca, U-Net++'daki dikkat mekanizmaları tarafından gerçektirilen özellik yeniden kalibrasyonu(feature recalibration), önemli özelliklerin seçici olarak vurgulanmasına ve daha az kullanışlı olanların bastırılmasına yardımcı olur.

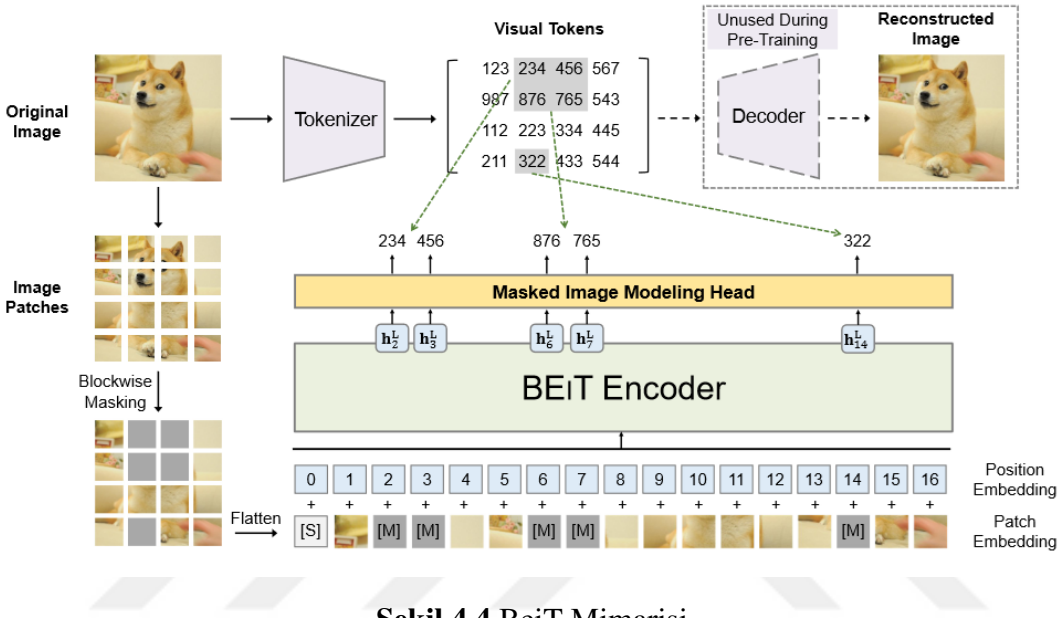
Deneysel sonuçlar, U-Net++'ın çeşitli biyomedikal ve doğal görüntü segmentasyon kriterlerinde öncülü olan U-Net'ten sürekli olarak daha iyi performans gösterdiğini ve bu sayede hassas ve sağlam segmentasyon görevleri için oldukça etkili bir model olduğunu göstermiştir. Ayrıca bu projede kullanılan U-Net++ yapısının kodlayıcı kısmı ImageNet üzerinde ön eğitimi yapılmış SE-ResNeXt101-32x4d mimarisinden oluşmaktadır [35, 36]. Model mimarisi Şekil 4.3'te incelenebilir.



Şekil 4.3 U-Net++ Mimarisi

4.2.3 BeiT Mimarisi

Bao ve arkadaşları tarafından tanıtılan BEiT, doğal dil işlemede kullanılan BERT'ten adapte edilmiş, gözetimli temsili öğrenme (self-supervised vision representation) modelidir [37]. Model, görüntü transformatörlerinin (vision transformers) ön eğitime tabi tutulması için bir görüntünün rastgele yamalarının maskelendiği ve modelin bu eksik yamaları tahmin etmeyi öğrendiği maskeli bir görüntü modelleme yöntemini kullanır.



Şekil 4.4 BeiT Mimarisi

BeiT özünde, görüntüleri sabit boyutlu yamalara bölerek işleyen, bu yamaları düzleştiren ve ardından bunları bir dizi transformatör katmanına besleyen bir görüntü transformatörleri omurgasından yararlanır. BeiT modelinde görüntü transformatörleri yama tabanlı bir yaklaşımla çalışır. Görüntünün tamamını bir kerede işlemek yerine, görüntü ilk olarak örtüşmeyen yamalardan oluşan bir ızgaraya bölünür. Daha sonra her yama bir vektöre gömülür ve bu vektörler transformatörleri kodlayıcısından geçirilir. Kodlayıcı, yamalar arasındaki bağlamsal ilişkileri yakalamak için kendi kendine dikkat mekanizmalarını kullanır ve modelin görüntüden karmaşık desenleri ve temsilleri öğrenmesine olanak tanır.

Segmentasyon görevleri için BeiT, transformatör kodlayıcının çıktısının üzerinde çalışan bir segmentasyon kafası sunar. Bu kafa tipik olarak, kodlayıcı tarafından üretilen kaba özellik haritalarını ayrıntılı segmentasyon haritalarına dönüştürmek için tasarlanmış bir dizi yukarı örnekleme ve evrişim katmanından oluşur. Segmentasyon kafası, görüntüdeki her piksel için sınıf etiketlerini tahmin etmek üzere eğitilir ve öğrenilen temsilleri etkin bir şekilde piksel bazında sınıflandırmaya dönüştürür.

Çalışmada kullanılan BeiT modeli önce ImageNet-21K veri kümesi üzerinde ön eğitimden ardından ADE20k veri kümesi üzerinde ince ayardan geçirilmiştir [38, 39]. Model mimarisi Şekil 4.4'te incelenebilir.

4.2.4 DPT Mimarisi

Ranftl, Bochkovskiy ve Koltun tarafından geliştirilen DPT, görüntü transformatörlerinin farklı bölümlerinden gelen tokerleri birleştirir ve segmentasyon gibi yoğun tahmin görevleri için özel olarak tasarlanmıştır [40]. DPT, özünde, segmentasyon için optimize edilmiş hibrit bir mimari oluşturmak için transformatör modelini CNN'ler ile entegre eder.

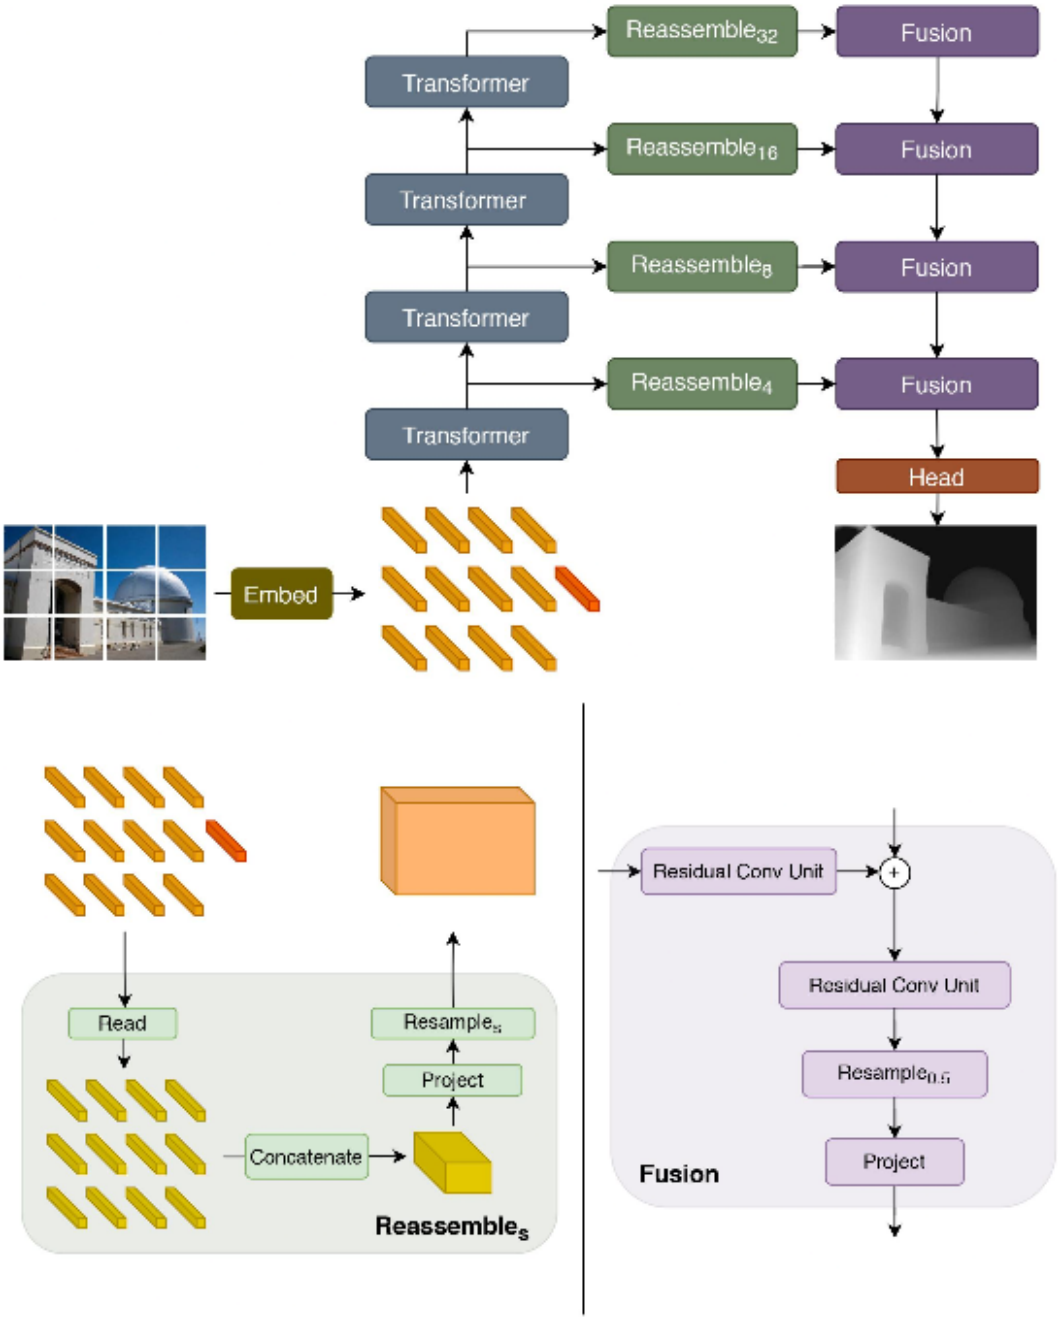
İlk olarak, giriş görüntüsü küçük, örtüşmeyen yamalara bölünür. Bu yamalar daha sonra düzleştirilir ve esasen görüntü hakkında küçük bilgi parçaları olan tokenlara dönüştürülür. Bu dönüşüm ya basit bir doğrusal projeksiyonla ya da görüntüden özellikler çıkarmak için bir ResNet-50 modeli kullanılarak gerçekleştirilebilir. Konumsal bilgilerle zenginleştirilen belirteçler daha sonra bir tranformatör katmanlarına beslenir.

Transformatör katmanlarında, tokenlardan çok başlı dikkat mekanizmaları (multi-head self-attention) kullanılarak yapılan analiz, CNN'lerin yaptığı gibi sırayla küçük parçalara odaklanmak yerine tüm görüntünün aynı anda analiz edilmesini sağlar. İşlem boyunca token sayıları korunarak görüntünün uzamsal detayı muhafaza edilir.

Transformatör katmanlardan geçtikten sonra, tokenlar orijinal görüntüden farklı çözünürlüklerde yeniden birleştirilir. Bu işlem sırasında tokenlar birleştirildikten sonra konvolüsyon kullanılarak istenen çözünürlüğe yeniden örneklenir. Bu aşama tokenlar tarafından yakalanan görüntü ayrıntılarının korunmasına ve geliştirilmesine yardımcı olur.

Transformatörlerin çeşitli aşamalarından gelen yeniden birleştirilmiş özellik haritaları daha sonra birleştirilir. Bu işlem, özellikleri aşamalı olarak harmanlayan özel füzyon blokları kullanılarak yapılır ve daha doğru ve ayrıntılı bir nihai görüntü tahmini elde edilir.

Özetle, DPT mimarisi, yüksek kaliteli görüntü segmentasyonu elde etmek için CNN'lerin ve transformatörlerin tamamlayıcı güçlerinden yararlanır. Projede modelin DPT-Large versiyonu kullanılmıştır. Mimari ADE20k veri kümesi üzerinde ön eğitimden geçirilmiştir [39]. Model mimarisi Şekil 4.5'te incelenebilir.



Şekil 4.5 DPT Mimarisi

4.2.5 MobileViT Mimarisi

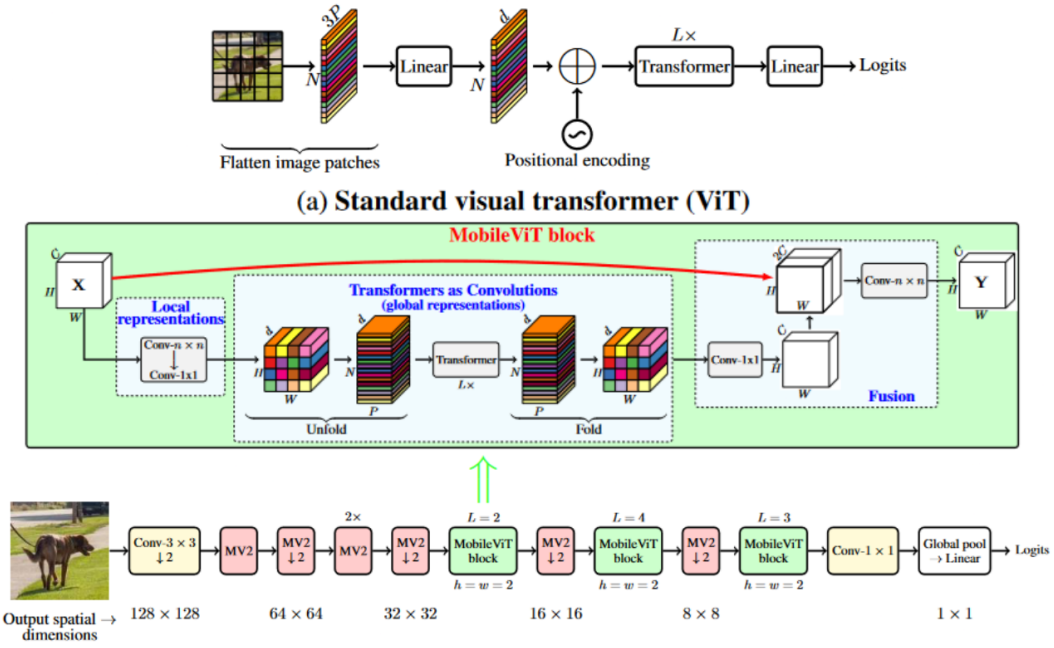
MobileViTi mobil uygulamalar için optimize edilmiş, genel amaçlı kullanım için tasarlanmış hafif bir görüntü transformatör mimarisidir. Yerel özellikleri yakalamak için evrişimsel katmanları ve küresel bağlamı yakalamak için dönüştürücü katmanları kullanarak transformatörlerin ve CNN'lerin güçlü yönlerini birleştirir [41]. Bu hibrit yaklaşım, MobileViT'in hesaplama verimliliği ile model performansı arasında bir denge kurmasını sağlayarak onu mobil cihazlardaki gerçek zamanlı uygulamalar için uygun hale getirir.

MobileViT mimarisi, mobil cihazlar için optimize edilmiş verimli konvolüsyonel katmanlar olan bir dizi MobileNetv2 bloğu ile başlar. Bu bloklar, hesaplama verimliliği sağlarken giriş görüntüsünden düşük seviyeli özelliklerin çıkarılmasından sorumludur. MobileNet'in derinlemesine ayrılabilir konvolüsyonları, parametre ve işlem sayısında azalma sağlayarak modeli kaynak kısıtlı ortamlar için uygun hale getirir.

MobileNetv2 omurgasını takiben MobileViT, hafif ve hesaplama açısından verimli olacak şekilde özel olarak tasarlanmış transformatör bloklarını entegre eder. Bu transformatör blokları, MobileNetv2 katmanları tarafından üretilen özellik haritalarını işler ve görüntü içindeki uzun menzilli bağımlılıkları ve bağlamsal ilişkileri yakalar. Önemli hesaplama kaynakları gerektiren geleneksel transformatörlerin aksine, MobileViT'in transformatör blokları mobil cihazların kısıtlamalarına uyacak şekilde düzenlenirken, aynı zamanda sağlam bir küresel bağlam anlayışı sağlar.

MobileViT mimarisinin son bileşeni, transformatör bloklarından gelen özellikleri piksel bazında tahminlere dönüştüren segmentasyon kafasıdır. Çalışmada kullanılan DeepLabV3 segmentaston kafası, kaba özellik haritalarını ayrıntılı segmentasyon haritalarına dönüştüren yukarı örnekleme ve konvolüsyonel katmanları içerir [42]. MobileNet'in yerel özellik çıkarma yeteneklerini transformatör bloklarının küresel bağlamsal anlayışıyla birleştiren MobileViT, verimlilikten ödün vermeden yüksek kaliteli segmentasyon sonuçları elde eder.

Özünde MobileViT, konvolüsyonel ve transformatör modellerinin en iyi yönlerini harmanlayan hibrit bir yaklaşımı temsil eder. Performans ve hesaplama verimliliğini dengeleyerek mobil cihazlarda etkili görüntü segmentasyonu sağlamak için tasarlanmıştır, bu da onu kısıtlı ortamlarda gerçek zamanlı uygulamalar için değerli bir araç haline getirir. Model PASCAL VOC veri kümesi üzerinde ön eğitimden geçirilmiştir [43]. Model mimarisi Şekil 4.6'da incelenebilir.



Şekil 4.6 MobileViT Mimarisi

4.2.6 SegFormer Mimarisi

SegFormer mimarisi, anlamsal segmentasyon görevleri için tasarlanmış, transformatörlerin güçlü yönlerini segmentasyon için verimli ve etkili bir çerçeve ile birleştiren bir state-of-the-art modeldir [44]. Mimari, konumsal kodlama(positional encoding) olmadan görüntü transformatörlerini kullanan bir semantik segmentasyon yöntemidir. Konumsal kodlamanın olmaması, model mimarisini basitleştirir ve hesaplama gereksinimlerini azaltırken en son teknolojiye sahip performansa ulaşmaya devam eder. SegFormer'ın tasarımı basitlik ve verimliliğe odaklanır, bu da modelin hem doğruluğun hem de hesaplama verimliliğinin çok önemli olduğu semantik segmentasyon görevlerinde başarılı olmasını sağlar.

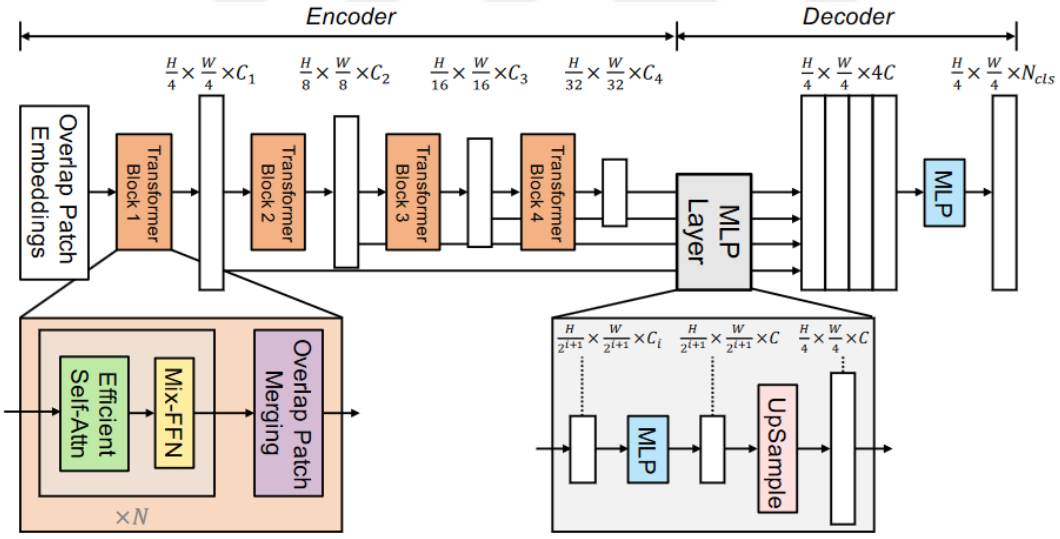
SegFormer'ın merkezinde, giriş görüntülerini bir dizi kendi kendine dikkat katmanı aracılığıyla işleyen hafif bir transformatör kodlayıcı bulunmaktadır. Büyük miktarda veri ve hesaplama kaynağı gerektiren geleneksel görüntü transformatörlerinin aksine SegFormer, transformatör kodlayıcı için karmaşıklığı azaltılmış bir tasarım kullanır. Bu tasarım, hesaplama verimliliğini korurken görüntü içindeki zengin küresel bağlamı ve uzun menzilli bağımlılıkları yakalamaya yardımcı olur. Kodlayıcı, giriş görüntüsünü, görüntünün çeşitli bölgelerini bağlamsal bilgilerle temsil eden bir dizi özellik simgesine dönüştürür.

SegFormer'ın son aşaması, özellikleri piksel bazında sınıf tahminlerine dönüştürmek için tasarlanmış bir segmentasyon kafasını içerir. Bu kafa,

transformatör kodlayıcıdan gelen çıktıyı ayrıntılı segmentasyon haritalarına dönüştürür. Modelde önerilen MLP-Kod Çözücü (multilayer perceptron) dört ana aşamadan oluşmaktadır. İlk olarak, kodlayıcı tarafından çıkarılan çok seviyeli özellikleri, kanal boyutlarını standartlaştırmak için bir MLP katmanından geçer. İkinci adımda, özellikler orijinal boyutlarının 1/4'üne kadar örneklenir ve birleştirilir. Son olarak, birleştirilmiş özellik segmentasyon maskesini tahmin etmek için başka bir MLP katmanı tarafından işlenir.

Genel olarak, SegFormer'ın mimarisi, Transformatörlerin küresel bağlamsal anlayışını verimli çok ölçekli özellik çıkarma ile birleştirerek anlamsal segmentasyonda önemli bir ilerlemeyi temsil etmektedir. Bu entegrasyon, SegFormer'ın yüksek kaliteli segmentasyon sonuçları elde ederken hesaplama açısından verimli olmasını sağlayarak onu çok çeşitli görüntü analizi görevleri için güçlü bir araç haline getirir.

Ayrıca bu projede kullanılan SegFormer yapısının kodlayıcı kısmı ImageNet-1K üzerinde ön eğitimi yapılmış MiT-B5 mimarisinden oluşmaktadır [36]. Model mimarisi Şekil 4.7'de incelenebilir.



Şekil 4.7 SegFormer Mimarisi

4.3 Performans Metrikleri

Modeller TE23D veri kümesi üzerindeki performanslarını uygun ölçütleri kullanarak değerlendirmek amacıyla *OPA*, IoU_{BG}, IoU_D ve *mIoU* metrikleri seçilmiştir. Bu ölçütler, modellerin afet sonrası senaryolarda hasarlı alanları doğru bir şekilde segmente etme başarısının kapsamlı bir değerlendirmesini sağlar [45, 46].

Bu metrikler hesaplanırken aşağıdaki kısaltmalar kullanılır: TP_{BG} arka plan sınıfı için doğru pozitifleri TP_D hasarlı sınıf için doğru pozitifler, FP_{BG} arka plan olarak tahmin edilen hasarlı sınıf için yanlış pozitifler ve FP_D hasarlı olarak tahmin edilen arka plan sınıfı için yanlış pozitiflerdir.

OPA, toplam pikseller içinde doğru sınıflandırılan piksellerin oranını ölçer (Eşitlik 4.1. Metrik, modelin piksel doğruluğu hakkında genel bir fikir verir. Fakat veri kümesinde hasarlı alanlar dışında kalan alanlar arkaplan olarak işaretlendiğinden ve görüntülerde hasarlı alanların kısıtlı olmasından dolayı bu ölçütün yüksekliği hasarlı alanların başarıyla tespit edilebildiğini göstermeyebilir.

IoU, tahmin edilen ve gerçek pikseller arasındaki örtüşmeyi belirlemek amacıyla her sınıf için hesaplanır (Eşitlik 4.2).

IoU_{BG} arka plan sınıfı için *IoU*'yu ve IoU_D hasarlı sınıf için IoU'yu temsil eder (Eşitlik 4.3, 4.4). Veri kümesi üzerinde esas amaç hasarlı bölgelerin tespiti olduğundan dolayı IoU_D ölçütünün yüksekliği gerçek anlamda başarıyı ifade eder.

mIoU, tüm sınıflar için *IoU*'dur ve modelin görüntülerdeki farklı bölge türlerini ayırt etme performansının dengeli bir değerlendirmesini sunar (Eşitlik 4.5).

$$OPA = \frac{TP_{BG} + TP_D}{TP_{BG} + FP_{BG} + TP_D + FP_D} \tag{4.1}$$

$$IoU = \frac{TP}{TP + FP + FN} \tag{4.2}$$

$$IoU_{BG} = \frac{TP_{BG}}{TP_{BG} + FP_{BG} + FP_D} \tag{4.3}$$

$$IoU_D = \frac{TP_D}{TP_D + FP_D + FP_{BG}} \tag{4.4}$$

$$mIoU = \frac{IoU_{BG} + IoU_D}{2} \tag{4.5}$$

Bu değerler, modelin her bir sınıfa ait pikselleri doğru tanımlama performansını ve sınıflandırmadaki hatalarını yansıtmaktadır. Bu metriklerin ayrıntılı tanımları ve hesaplamaları, segmentasyon modellerinin etkinliğinin kapsamlı ve titiz bir şekilde değerlendirilmesini sağlar.

5
DENEYSEL SONUÇLAR

TE23D veri kümesinde hasar segmentasyonu için etkili bir sistem tasarlamak amacıyla, çeşitli modeller eğitilmiş ve bir dizi başarı metriği değerlendirilmiştir. Tüm eğitim süreçlerinde, büyük veri kümelerini ve karmaşık sinir ağlarını işlemedeki verimliliği nedeniyle seçilen AdamW optimizasyon fonksiyonu kullanılmıştır [41]. Eğitimler esnasında eğer kullanılan mimarinin içinde gömülü olarak bir hata fonksiyonu var ise o fonksiyon, yok ise Binary Cross Entropy Loss fonksiyonu kullanılmıştır. Her model, 1×10^{-4} öğrenme oranı ve 4 yığın(batch) boyutu ile 100 iterasyon(epoch) eğitilmiştir. Eğitim süresince modellerin doğrulama *mIoU* skorları takip edilmiş ve en başarılı olan modeller kullanılarak deneyler gerçekleştirilmiştir. Eğitim, yüksek hesaplama yeteneklerinden yararlanmak için tek bir NVIDIA A100 GPU üzerinde gerçekleştirilmiştir.

Bölüm 5.1'de bu çalışmada incelenen farklı mimarilerin TE23D_A veri kümesi üzerindeki deneysel sonuçları sunulacaktır. Bu, performans ölçümlerinin ayrıntılı bir karşılaştırmasını, çeşitli bağlamlardaki güçlü ve zayıf yönlerin vurgulanmasını içerir. Sonuçlar incelenerek hipotezi test etmek için en uygun mimari belirlenecek ve titiz bir değerlendirmenin temeli oluşturulacaktır.

Bölüm 5.2'de hipotez odaklı deneyin sonuçları sunulacaktır. Bu bölümde bir önceki bölümde belirlenen modelin TE23D_A, TE23D_{B1} ve TE23D_{B2} veri kümeleri üzerindeki performansının ayrıntılı bir analizi yapılacak ve yalnızca hasarlı alanlara odaklanmanın hasar tespit doğruluğunda ve genel model etkinliğinde önemli bir iyileşmeye yol açıp açmadığı tartışılacaktır. Bulgular, hipotezin geçerliliği, gelecekteki araştırmalar ve deprem hasar tespitindeki pratik uygulamalar için çıkarımları hakkında somut sonuçlar sunacaktır.

Son olarak, Bölüm 5.3'te hipotez testinde başarılı olarak değerlendirilen modelin eğitim sürecindeki grafiği analiz edilecektir.

5.1 Mimarilerin Deneysel Sonuçları

Bu bölümde, hasarlı alanların segmentasyonu için seçilen Mask R-CNN, U-Net, U-Net++, BeiT, DPT, MobileViT ve SegFormer mimarilerinin $TE23D_A$ veri kümesi üzerindeki değerlendirilmesi sunulmaktadır. Her model, kendine özgü yetenekleri ve görüntü segmentasyonu ve anormallik tespitindeki başarıları nedeniyle seçilmiş olup, depremden kaynaklanan hasarın etkin bir şekilde anormallikler olarak tanımlanabileceği hipotezinin test edilmesi için uygun adaylar haline getirilmiştir.

Deneysel değerlendirme, bu mimarilerin veri kümesi üzerinde eğitilmesini ve test edilmesini içerir. Amaç, her modelin performansını, hasarlı alanların belirlenmesinde başarısı açısından değerlendirmektir. Değerlendirme süreci, *OPA*, IoU_{BG}, IoU_D ve *mIoU* performans ölçümlerinin ayrıntılı bir analizini içerir.

Bu kapsamlı değerlendirme aracılığıyla çalışma, hangi mimarinin en başarılı hasar segmentasyonunu sağladığını belirlemeyi; ve ardından hipotezin test edilebilmesi sağlam bir temel sağlamayı amaçlamaktadır. Bu analiz, doğal afetlerden etkilenen kentsel ortamlarda anomaliye dayalı hasar tespiti için en etkili yaklaşımların anlaşılmasını anlaşılması açısından oldukça önemlidir.

Değerlendirme sonuçları Tablo 5.1'de sunulmuştur. Her bir modelin performansı dört ölçütün tamamında değerlendirilerek etkinliklerinin ayrıntılı bir şekilde karşılaştırılmasına olanak sağlanmıştır.

Tablo 5.1 Mimarilerin, performans metriklerine göre nicel başarı oranlarını gösteren tablo (%'lik olarak).

Method	***OPA***	$\boldsymbol{IoU_{BG}}$	$\boldsymbol{IoU_D}$	***mIoU***
Mask R-CNN	90,6	89,9	48,03	68,97
U-Net	90,61	89,97	43,64	66,8
U-Net++	91,76	91,18	50,48	70,83
BeiT	90,81	90,21	43,45	66,83
DPT	91,29	90,67	49,82	70,24
MobileViT	91,81	91,19	51,79	71,49
SegFormer-B5	**92,49**	**91,92**	**56,98**	**74,45**

Çalışma kapsamında değerlendirilen tek örnek segmentasyon yöntemi olan Mask R-CNN modeli, %90,6 *OPA*, %89,9 IoU_{BG} ve %48,03 IoU_D ve *mIoU* %68,97 değerlerini elde etmiştir.

U-Net modeli %90,61 *OPA*, %89,97 IoU_{BG} ve %43,64 IoU_D ve *mIoU* %66,8 değerlerini elde ederken, U-Net++ modeli ise, %91,76 *OPA*, %91,18 IoU_{BG} ve %50,48 IoU_D ve *mIoU* %70,83 değerlerini elde etmiştir.

BEiT, %90,81 *OPA*, %90,21 IoU_{BG} ve %43,45 IoU_D ile %66,83 *mIoU* elde etmiştir. Bu, BEiT'in arka plan alanlarını belirlemede iyi performans gösterirken, hasarlı alanları doğru bir şekilde belirlemede daha az etkili olduğunu göstermektedir.

DPT, %91,29 *OPA*, %90,67 IoU_{BG} ve %49,82 IoU_D ile hafif bir iyileşme göstermiş ve *mIoU* %70,24 olmuştur. Bu model, BEiT'e kıyasla hasarlı alanların daha iyi segmentasyonunu göstermiştir.

MobileViT, %91,81 *OPA*, %91,19 IoU_{BG} ve %51,79 IoU_D ile %71,49 *mIoU* elde etmiştir. Bu, önceki modellere kıyasla hem arka plan hem de hasarlı alan segmentasyonunda daha yüksek bir doğruluğa işaret etmektedir.

SegFormer %92,49 *OPA*, %91,92 IoU_{BG} ve %56,98 IoU_D ile diğer tüm modellerden daha iyi performans göstermiş ve *mIoU* %74,45 olmuştur.

Tablo 5.1'deki sonuçlara göre, SegFormer mimarisi tüm değerlendirme metriklerinde diğer tüm yöntemlerden daha iyi performans göstermektedir. SegFormer modeli; *OPA*, IoU_{BG}, IoU_D ve *mIoU* alanlarında sürekli olarak en yüksek puanları elde etmiş. Bu sonuçlar, SegFormer modelinin afet sonrası senaryolarda hasarlı alanları doğru bir şekilde segmente etmedeki etkinliğinin altını çizmektedir.

Bir sonraki en iyi performans gösteren mimari, özellikle *mIoU* açısından güçlü performans gösteren MobileViT'tir. MobileViT için *OPA*, SegFormer'inkinden sadece biraz daha düşük olsa da SegFormer, IoU_D ve *mIoU* açısından MobileViT'ten önemli ölçüde daha iyi performans göstermektedir. Bu da SegFormer'in afet sonrası hasar tespitinin kritik bir yönü olan hasarlı binaların belirlenmesi ve sınıflandırılmasında daha etkili olduğunu göstermektedir.

Öte yandan, BeiT ve U-Net, iyi *OPA* ve IoU_{BG} değerleriyle orta düzeyde performans sunar, ancak nispeten düşük IoU_D ve *mIoU* değerleri, arka plan segmentasyonu yapabilmelerine rağmen, hedef sınıfları tespit etme ve segmente etme performanslarının diğer modellere kıyasla daha başarısız olduğunu gösterir.

Ayrıca U-Net++ mimarisi, öncülü olan U-Net mimarisine kıyasla *OPA* ve IoU_{BG} metriklerinde yakın performanslar gösterirken, hasarlı alanları tespit etmede çok daha iyi sonuçlar elde etmiştir. Bu sonuçlar, mimarinin öncülünden daha başarılı olduğunu göstermektedir.

Çalışma kapsamında değerlendirilen Mask R-CNN örnek segmentasyon mimarisi ise, IoU_D ve *mIoU* metriklerinde U-Net'in önünde yer almasına rağmen, *OPA* ve IoU_{BG} metriklerinde en başarısız değerleri elde etmiştir. Bu

durum değerlendirildiğinde anlamsal segmentasyonun hasar tespiti için örnek segmentasyona kıyasla daha isabetli bir seçim olduğu fikri doğrulanabilir.

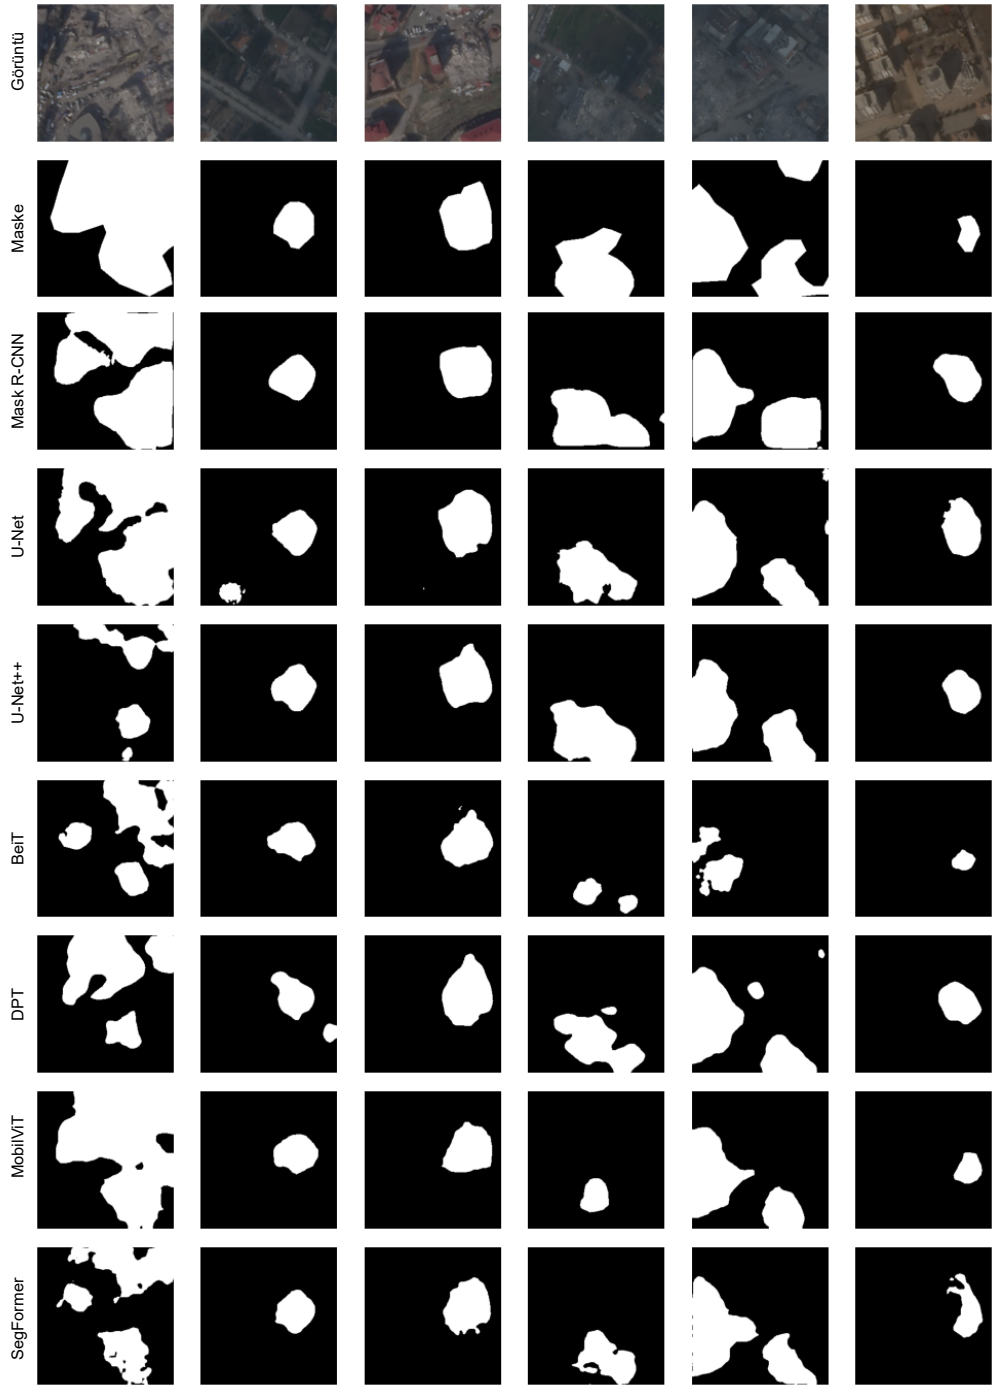
Ayrıca nitel sonuçları destekleyen segmentasyon örnekleri Şekil 5.1'de gösterilmiştir. Şekilde tüm mimarilerin, $TE23D_A$ veri kümesinin test parçasından seçilen altı örnek üzerindeki nitel sonuçları görülebilir. Şekilde orijinal görüntü, gerçek etiketler ve modeller tarafından tahmin edilen etiketler sırasıyla verilmiştir. Şekilde siyah alanlar arka planı ve beyaz alanlar hasarlı alanları temsil etmektedir.

Özetle, SegFormer ve MobileViT gibi transformatör tabanlı mimariler afet sonrası hasar tespitinde kayda değer bir başarı göstermektedir. Bu kapsamlı değerlendirmeye dayanarak, SegFormer, hasarlı alanların segmentasyonu görevi için en etkili mimari olarak öne çıkmaktadır. Tüm ölçütlerdeki üstün performansı, hipotezin test edilmesi ve doğrulanması için uygunluğunu teyit etmektedir. Bu nedenle, SegFormer bu çalışmanın sonraki bölümlerinde ayrıntılı olarak açıklanacak olan hipotez deneyi için tercih edilen mimari olmuştur. Bir sonraki bölümde, SegFormer modelinin sağlam yeteneklerinden yararlanarak deprem kaynaklı hasarın anomali olarak tanımlanabileceği hipotezini titizlikle test etmek için tasarlanan deneysel kurulum ayrıntılı olarak açıklanacaktır.

5.2 Hipotez Deneyi Sonuçları

TE23D veri kümelerinin oluşturulmasının ardından, modellerin başarısını $TE23D_A$ hem de $TE23D_{B1}$ ve $TE23D_{B2}$ veri kümeleri üzerinde karşılaştırılması gerekliliği doğmuştur. Bu karşılaştırma, yalnızca hasarlı alanların etiketlenmesinin, yani hasarlı alan tespitinin bir anomali olarak görülmesinin; binaların etiketlenmesine gerek duyulmadan hasar segmentasyon modellerinin performansını artırabileceği hipotezini doğrulamak için gereklidir. Başka bir deyişle bu karşılaştırma, bina etiketlemelerinin daha doğru ve sağlam segmentasyon sonuçları sağlayıp sağlamayacağını değerlendirme ihtiyacından kaynaklanmıştır. Bu amaçla, ilk kıyaslamada üstün performans gösteren SegFormer modeli, $TE23D_{B1}$ ve $TE23D_{B2}$ veri kümeleri üzerinde eğitim ve değerlendirme için seçilmiştir.

SegFormer modelinin veri kümeleri üzerinde eğitilmesi birkaç adımdan oluşmuştur. Her iki veri kümesi üzerindeki eğitimlerde de; başlangıçta model, değerlendirmede tutarlılığı sağlamak için önceki deneylerde kullanılan hiperparametrelerle yapılandırılmıştır. Modelin performansı daha sonra önceki kıyaslamalarda uygulanan aynı ölçütlere ek olarak IoU_B yani binalar için birlik üzerinden kesişim kullanılarak değerlendirilmiştir. Ancak $TE23D_A$ veri kümesinde binalar etiketli olmadığından dolayı bu metrik hasarlı alanların segmentasyonu üzerine herhangi bir



Şekil 5.1 Modellerin test veri kümesi üzerindeki nitel sonuçları

anlam ifade etmemektedir. Böylelikle kullanılan metrikler şu şekilde sıralanabilir: *OPA*, IoU_{BG}, IoU_B, IoU_D ve *mIoU*.

Böylece TE23D_A veri kümesi üzerinde eğitilmiş olan model $\text{SegFormer}_\text{A}$, TE23D_B1 veri kümesi üzerinde eğitilmiş olan model $\text{SegFormer}_\text{B1}$ ve TE23D_B2 veri kümesi üzerinde eğitilmiş olan model $\text{SegFormer}_\text{B2}$ olarak isimlendirilmiştir. Modellerin, eğitildikleri veri kümelerinin test parçaları üzerindeki başarıları Tablo 5.2'de sunulmuştur.

Tablo 5.2 SegFormer modelinin TE23D veri kümeleri üzerinde başarılarının nicel sonuçları (%'lik olarak)

Model	**Veri Kümesi**	***OPA***	$\boldsymbol{IoU_{BG}}$	$\boldsymbol{IoU_B}$	$\boldsymbol{IoU_D}$	***mIoU***
$\text{SegFormer}_\text{A}$	TE23D_A	**92.49**	**91.92**	**-**	56.98	**74.45**
$\text{SegFormer}_\text{B1}$	TE23D_B1	88.15	86.47	**61.3**	**57.03**	68.27
$\text{SegFormer}_\text{B2}$	TE23D_B2	85.14	83.64	36.53	55	58.39

SegFormer modellerinin veri kümeleri üzerinde eğitilmesinden elde edilen sonuçlar, karmaşık etiketleme yaklaşımının model performansı üzerindeki etkisi hakkında önemli bilgiler sağlamaktadır. TE23D_A veri kümesi üzerindeki *OPA*, hem TE23D_B1 hem de TE23D_B2 veri kümesine kıyasla daha yüksektir. Bu durum, modelin hem binaların hem de hasarlı alanların etiketlenmesinin aksine, yalnızca hasarlı alanlar etiketlendiğinde genel piksel düzeyinde doğruluk açısından daha iyi performans gösterdiğini ortaya koymaktadır. Ek bina etiketlerinin getirdiği daha yüksek karmaşıklık muhtemelen *OPA*'daki azalmaya katkıda bulunmuştur.

IoU_{BG} metriği, TE23D_B1 ve TE23D_B2 veri kümelerinde TE23D'ye kıyasla biraz daha düşüktür. Bu, bina etiketlerinin dahil edilmesinin arka plan sınıfını doğru bir şekilde segmente etmede bir dereceye kadar karışıklık yarattığını göstermektedir. Fakat TE23D_B1 ve TE23D_B2 veri kümelerindeki arka plan görüntüsünü binalar ve hasarlı alanlar harici alanların oluşturduğu; TE23D_A veri kümesindeki arka plan görüntüsünü ise hasarlı alanlar harici alanların oluşturduğu ve bu alanın binaları içerdiği göz önünde bulundurulduğunda TE23D_B1 ve TE23D_B2 veri kümelerindeki arka plan karmaşıklığının, TE23D karmaşıklığından daha fazla olduğu göz önünde bulundurulmalıdır.

TE23D_B1 ve TE23D_B2'deki IoU_B, bina etiketlerinin olmaması nedeniyle TE23D_A için mevcut olmayan yeni bir metriktir. TE23D_B2 için bu metrik başarısız olarak nitelendirilebilecek bir sonuç verirken TE23D_B1 için orta düzeyde bir puan göstermektedir.

IoU_D, TE23D_B1'de TE23D_A'ya göre %0.05 kadar yüksek olmasına rağmen TE23D_B2'de daha düşüktür. Hasarlı alanların segmentasyonu için IoU_D

skorunda %0.05'lik bir yüksekliğin anlamlı olmadığı açıktır. Bu yüksekliğin rassallıktan kaynaklanma olasılığı gözardı edilemeyeceği gibi hasarlı alanların segmentasyonunda, binaların etiketlenmesinin fayda sağlamadığı belirtilebilir. Bu durum, bina etiketlerinin dahil edilmesinin daha fazla bilgi sağlarken, aynı zamanda karmaşıklık da eklediğini ve modelin hasarlı alanları ayırt etmesini potansiyel olarak zorlaştırdığını göstermektedir.

mIoU, TE23D_{B1} ve TE23D_{B2}'de için TE23D_{A}'ye kıyasla daha düşüktür. Bu azalma, birden fazla sınıfı ele almanın zorluğunu ve veri kümesinin ek etiketlerle geliştirilmesi sonucunda başarıdan ödün verildiğini daha da vurgulamaktadır.

Hasarlı binaların tespit başarısını olumsuz etkileyen en önemli faktörlerden biri uydu görüntülerinin kalitesinin bazen gözle bakıldığında bile anlaşılması zor kalitede olmasıdır. Bu nedenle, modelin otomatik hasar tespit başarısı ile gözle bakılarak yapılan hasar tespiti ile karşılaştırılmıştır. Test kümesinde bulunan 30 hasarlı alan örneği ve 30 sağlam bina örneği üç kişiye gösterilerek örnekleri hasarlı alan veya bina olarak işaretlemeleri istenmiştir. Her örnek için en fazla tercih edilen işaretleme, o örnek için yorumcu seçimi olarak belirlenmiştir. Tablo 5.3'te seçilen görüntülerdeki bazı örnekler için gerçek etiketleri, yorumcuların tahminleri ve model tahminleri görülebilir.

Tablo 5.3 Seçilen görüntülerdeki bazı örnekler için gerçek etiketleri, yorumcuların tahminlerini ve model tahminlerini gösteren tablo.

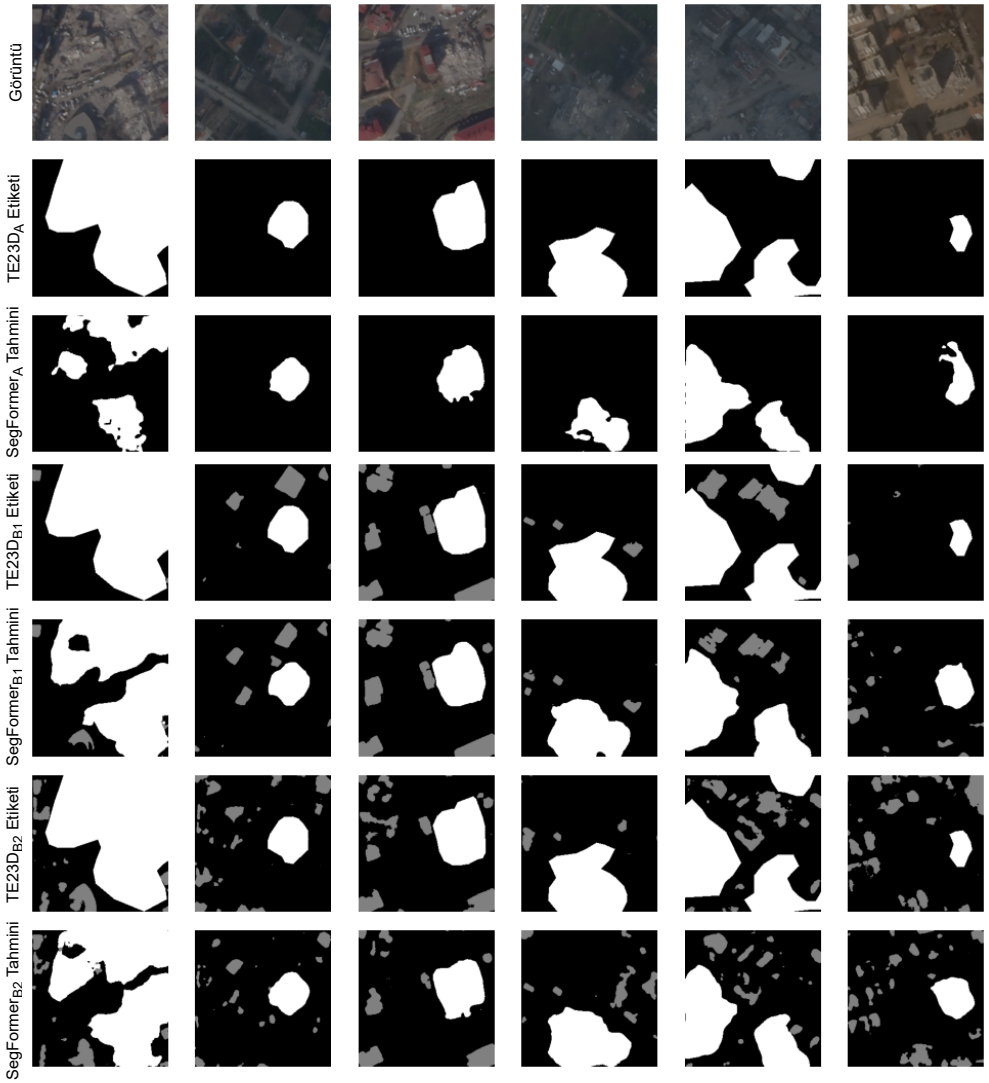
Görüntü	Gerçek Etiket	Yorumcu 1	Yorumcu 2	Yorumcu 3	Yorumcu Çoğunluğu	Model Tahmini
Görüntü 1	Bina	Hasarlı Alan	Hasarlı Alan	Bina	Hasarlı Alan	Bina
Görüntü 2	Hasarlı Alan	Hasarlı Alan	Hasarlı Alan	Bina	Hasarlı Alan	Bina
Görüntü 3	Bina	Bina	Bina	Bina	Bina	Bina
Görüntü 4	Hasarlı Alan	Bina	Bina	Bina	Bina	Hasarlı Alan
Görüntü 5	Hasarlı Alan	Hasarlı Alan	Hasarlı Alan	Hasarlı Alan	Hasarlı Alan	Hasarlı Alan

Yorumcuların tahminleri orijinal etiketlerle karşılaştırıldığında %88,3'lük bir doğruluk elde edilmiştir. $\text{SegFormer}_{\text{B1}}$ modelinin tahminleri gerçek etiketlerle karşılaştırıldığında %90'lık bir doğruluk elde edilmiştir.

Bu sonuçlar, insan yorumlayıcılar tarafından seçilen etiketler ile gerçek etiketler arasında güçlü bir uyum olduğunu göstermektedir. Ayrıca, modelin tespit performansının insan performansıyla karşılaştırılabilir olduğu görülmüştür. Dahası, modelin insan doğruluğundan daha iyi performans gösterdiği göz önüne alındığında, modelin performansının sağlam olduğu ve daha fazla iyileştirme elde etmenin zor olabileceği sonucuna varılabilir.

Şekil 5.2'de $\text{SegFormer}_{\text{A}}$ modelinin TE23D_{A} veri kümesi üzerinde $\text{SegFormer}_{\text{B1}}$ modelinin TE23D_{B1} veri kümesi üzerinde ve $\text{SegFormer}_{\text{B2}}$ modelinin TE23D_{B2} veri

kümesi üzerinde nitel sonuçları gözlemlenebilir. Şekilde siyah alanlar arka planı, gri alanlar binaları ve beyaz alanlar hasarlı alanları temsil etmektedir.



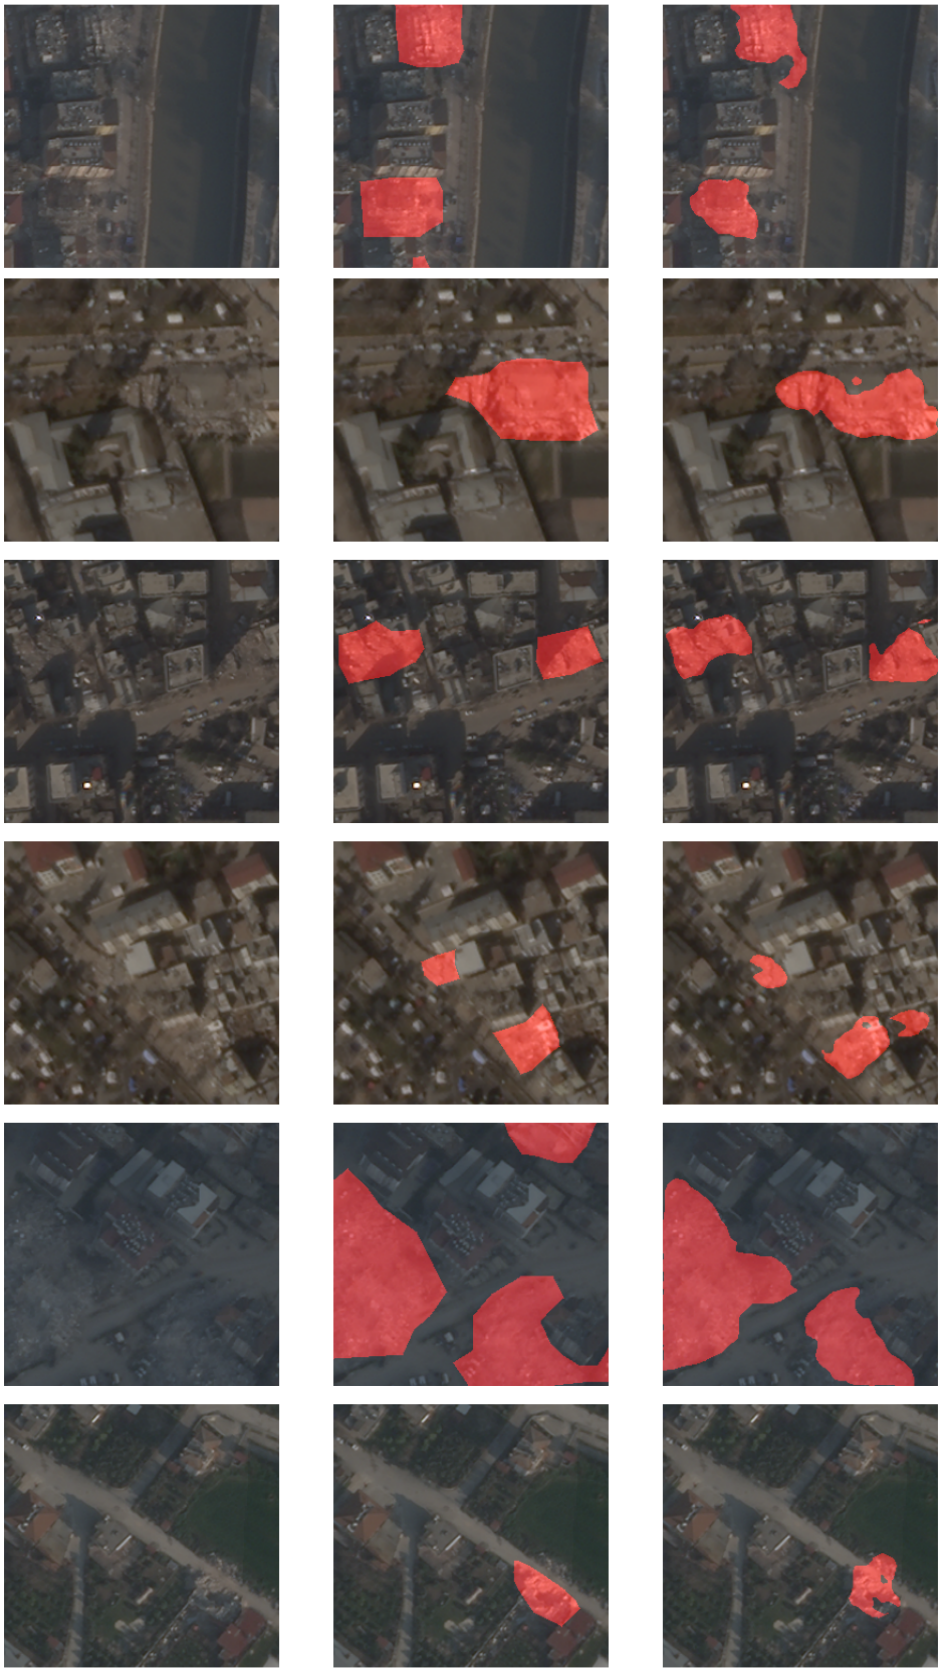
Şekil 5.2 TE23D$_A$ veri kümesi üzerinde eğitilmiş olan SegFormer$_A$, TE23D$_{B1}$ veri kümesi üzerinde eğitilmiş olan SegFormer$_{B1}$ ve TE23D$_{B2}$ veri kümesi üzerinde modeli SegFormer$_{B2}$ modellerinin ait olduğu veri kümelerinin test alt kümelerindeki nitel sonuçları

En başarılı model olarak değerlendirilen ve hasarı bir anomali tespiti olarak gerçekleştiren SegFormer$_A$ modelinin, TE23D$_A$ test alt kümesi üzerindeki segmentasyon örnekleri Şekil 5.3 ve Şekil 5.4'te görülebilir.

Genel olarak hipotez deneyi sonuçları, yalnızca hasarlı alanları anomali olarak etiketleme hipotezinin daha yüksek genel doğruluk sağladığını gösterirken, bina etiketlerinin dahil edilmesinin model performansını etkileyen ek karmaşıklık getirdiğini göstermektedir. Bu karmaşıklık, modelin her kategoriyi doğru bir şekilde



Şekil 5.3 Uydu görüntüleri (birinci sütun), TE23D$_A$ veri kümesine ait gerçek segmentasyon maskeleri (ikinci sütun), SegFormer$_A$ modelinin segmentasyon tahminleri (üçüncü sütun).



Şekil 5.4 Uydu görüntüleri (birinci sütun), TE23D$_{A}$ veri kümesine ait gerçek segmentasyon maskeleri (ikinci sütun), SegFormer$_{A}$ modelinin segmentasyon tahminleri (üçüncü sütun).

segmente etme kapasitesini zorlayabilecek birden fazla nesne türü arasında ayrım yapmanın artan zorluğundan kaynaklanmaktadır. Bu nedenle, hasarın bir anomali olarak ele alınabileceği hipotezi, segmentasyon sürecini basitleştirmede değerli bir bakış açısı sunmaktadır. Yalnızca hasarlı alanlara odaklanan yaklaşım, $TE23D_A$ veri kümesindeki yüksek performans metriklerinin de gösterdiği gibi, modelin bu anomalileri doğru bir şekilde tespit etme becerisini üst düzeye çıkarmıştır. Bununla birlikte, $TE23D_{B1}$ ve $TE23D_{B2}$'deki bina etiketlerinin eklenmesi, genel doğruluğu azaltırken, kentsel peyzaj hakkında daha kapsamlı bilgi sağlayarak veri kümesini zenginleştirir, bu da acil hasar değerlendirmesinin ötesinde daha geniş uygulamalar için çok önemli olabilir.

5.3 $SegFormer_A$ Modelinin Eğitim Grafiği

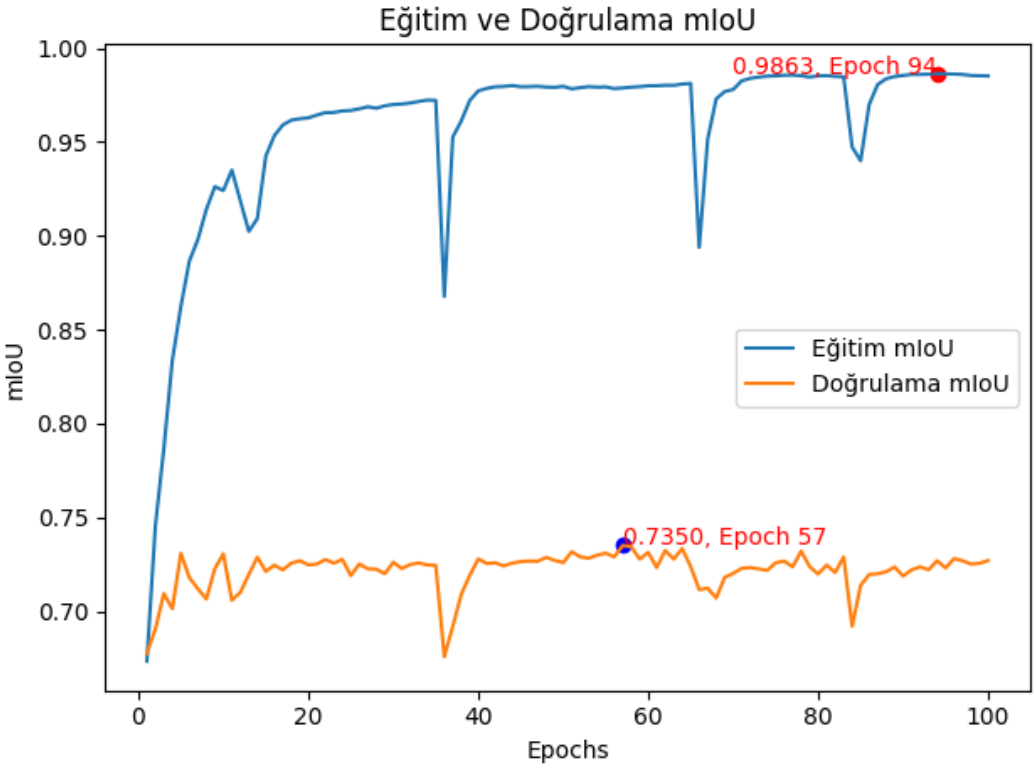
Deneysel değerlendirmelerde üstün performans gösteren $SegFormer_A$ modeli, deprem kaynaklı hasarın anomali olarak etkili bir şekilde tanımlanabileceği hipotezine önemli bir destek sağlamaktadır. Bu modelin *OPA*, IoU_{BG}, IoU_D ve *mIoU* metrikleri üzerindeki başarısı, bu bağlamdaki etkinliğinin altını çizmektedir.

Bu bölümde $SegFormer_A$ modelinin eğitim ve doğrulama süreçlerinin grafiksel gösterimi incelenecektir. Bu ayrıntılı analiz, modelin öğrenme dinamikleri, kararlılığı ve hasarlı alanları hasarsız olanlardan ayırt etmedeki genel etkinliği hakkında fikir verecektir. Bu analiz, $SegFormer_A$'nin odaklanmış etiketleme stratejisinin ve sofistike mimarisinin anomali tabanlı hasar tespitindeki başarısına nasıl katkıda bulunduğunu göstermeyi amaçlamaktadır.

Şekil 5.5'teki grafik $SegFormer_A$ modelinin 100 iterasyon süren eğitim sürecindeki her iterasyonda kaydedilen $TE23D_A$ veri kümesinin eğitim ve doğrulama parçaları üzerindeki *mIoU* değerlerini göstermektedir. Grafikte eğitim *mIoU*'su mavi çizgi ile gösterilirken, doğrulama *mIoU*'su turuncu çizgi ile gösterilmektedir.

Eğitim *mIoU*'su ilk iterasyonlar sırasında hızlı bir artış göstererek modelin hasarlı ve hasarsız alanları ayırt etmeyi hızlı bir şekilde öğrendiğini gösterir. 20. iterasyonda, eğitim *mIoU* değeri yüksek bir değer etrafında sabitlenir ve 94. iterasyonda 0,9863 ile zirveye ulaşır. İterasyonların çoğu boyunca bu tutarlı yüksek *mIoU* değeri, modelin eğitim verileriyle ilgili özellikleri etkili bir şekilde öğrendiğini gösterir. Eğitim *mIoU* değerinde zaman zaman görülen düşüşler, derin öğrenme eğitim süreçlerinde tipik olan model parametrelerindeki önemli güncelleme veya ayarlama anlarına işaret etmektedir.

Öte yandan, doğrulama *mIoU*'su farklı bir eğilim göstermektedir. Başlangıçta, 10.



Şekil 5.5 SegFormer$_{\text{A}}$ modelinin eğitim sürecindeki eğitim ve doğrulama *mIoU* değerlerini gösteren grafik.

iterasyon civarına kadar artar ve stabilize olur, ancak eğitim *mIoU*'suna kıyasla daha düşük bir değerdedir. Doğrulama *mIoU*'su 0,73 civarında dalgalanmakta ve 57. iterasyonda 0,7350 değerinde zirve yapmaktadır. Önemli bir yükseliş eğilimi göstermeyen bu dalgalanma, modelin eğitim verilerinde iyi performans göstermesine rağmen, doğrulama verilerinde genelleme yapmakta zorluklarla karşılaştığını göstermektedir.

İlk iterasyonlardan sonra eğitim ve doğrulama *mIoU*'ları arasındaki fark, modelin gürültü ve belirli örüntüler dahil olmak üzere eğitim verilerini çok iyi öğrendiğine, ancak yeni, görülmeyen verilere genelleme yapamadığına işaret etmektedir. Yüksek eğitim *mIoU*'suna rağmen, daha düşük ve dalgalı doğrulama *mIoU*'sunun muhtemel sebebi eğitim ve doğrulama verileri arasındaki evrensel özelliklerin örtüşmesine rağmen, modelin eğitim verisinde öğrendiği lokal özelliklerin doğrulama verisinde sınırlı olmasıdır. Modelin aşırı öğrenme problemini çözebilmek için katman dondurma, veri artırma ve regularizasyon teknikleri de dahil olmak üzere çeşitli stratejiler araştırılmıştır. Katman dondurma yaklaşımı, başlangıç, ara ve son katmanların hem toplu hem de ayrı ayrı dondurulmasının yanı sıra rastgele katmanların dondurulması gibi çoklu konfigürasyonların denenmesini içermektedir. Katman dondurma yönteminin uygulanmasının ardından; kodlayıcının ilk

katmanları dondurulduğunda model başarısı IoU_D için %56.55 ve *mIoU* için %74.26 olarak elde edilmiştir fakat aşırı öğrenme problemi çözülememiştir. Modelin kod çözücü kısmı hariç tüm katmanları dondurulduğunda ise IoU_D skoru %44.01 ve *mIoU* skoru %66.82 olarak elde edilmiştir.

Katman dondurmaya ek olarak, veri artırımı da potansiyel bir çözüm olarak incelenmiştir. Yatay ve dikey çevirme, döndürme ve yağmur, sis ve kar gibi sentetik unsurların eklenmesinin yanı sıra görüntü parlaklığında ayarlamalar da dahil olmak üzere değişen parametrelerle bir dizi veri artırma tekniği uygulanmıştır. Bu teknikler uygulandığında aşırı öğrenme problemi kısmen çözülmüş olsa da IoU_D için %56.49 ve *mIoU* için %74.15 skorları elde edilmiştir.

Bu yaklaşımlar aşırı öğrenme sorununu bir dereceye kadar hafifletmiş olsa da, *mIoU* ve IoU_D performans metriklerinde önemli bir düşüşe yol açmış olması ve aşırı öğrenmiş modelden çok daha kötü test sonuçların elde edilmesine neden olmuş olmasından dolayı çalışma üzerinde aşırı öğrenme probleminin çözülebilmesi için başarısız olarak değerlendirilebilir. Ancak yine de yaklaşımların farklı parametreler ile denenmesi faydalı olacaktır.

6
SONUÇ

Çalışmanın ilk amacı, özellikle 6 Şubat 2023 Türkiye depremlerine uyarlanmış özel bir uydu görüntüsü veri kümesi (TE23D) oluşturulması ve değerlendirilmesi yoluyla afet sonrası otomatik hasar tespit çalışması yapacak araştırmacılar için kapsamlı bir veri kümesi geliştirerek bu alanda yapılacak çalışmalara katkı sağlamaktır. Buna ilaveten, veri kümesi etiketleme işleminin zaman alıcı olmasından ötürü doğal afetlerden kaynaklanan hasarın bir anomali olarak değerlendirilebileceği ve buna bağlı olarak uydu görüntülerinden oluşan veri kümesinde sadece hasarlı alanların etiketlenmesinin, hasarlı alanların segmente edilmesinde yeterli olacağı hipotezi değerlendirilmiştir.

TE23D veri kümesi; $TE23D_A$, $TE23D_{B1}$ ve $TE23D_{B2}$ veri kümeleri olmak üzere üç parçadan oluşmaktadır. $TE23D_A$ veri kümesinde, anomalilere odaklanmanın segmentasyon sürecini kolaylaştırabileceği ve model doğruluğunu artırabileceği hipotezine uygun olarak, tüm binaların etiketlenmesi yerine sadece hasarlı alanlar etketlenmiştir. $TE23D_{B1}$ ve $TE23D_{B2}$ veri kümeleri, hasarsız bina etiketlerinin orijinal $TE23D_A$ veri kümesine entegre edilmesiyle oluşturulmuştur. Bu geliştirilmiş versiyonlar, binaların, arka planın ve hasarlı alanların segmentasyonunu sağlayarak afet sonrası peyzajın daha kapsamlı bir temsilini sağlamayı ve hipotezin test edilmesini amaçlamıştır. İstanbul Veri Kümesi üzerinde eğitilen U-Net++ modeli, $TE23D_{B1}$ veri kümesi oluşturulurken ve Massachusetts Buildings Dataset üzerinde eğitilen U-Net modeli $TE23D_{B2}$ veri kümesi oluşturulurken hasarsız bina segmentasyonu için kullanılarak bina etiketlerinin hem doğru hem de güvenilir olması sağlanmıştır. $TE23D_{B1}$ ve $TE23D_{B2}$ veri kümelerinin oluşturulma süreci, model tahminlerinin ve manuel etiketlerin dikkatli bir şekilde çapraz eşleştirilmesini ve yüksek doğruluğu korumak için manuel etiketlere öncelik verilmesini içermektedir. Bu süreç, arka plan, bina ve hasarlı alan etiketlerine sahip, afet sonrası durumun dengeli ve ayrıntılı bir görünümünü sunan $TE23D_{B1}$ ve $TE23D_{B2}$ veri kümelerinin oluşturulması ile sonuçlanmıştır.

İlk kıyaslama deneylerinde $TE23D_A$ veri kümesi üzerinde etkinliğini gösteren SegFormer modeli tüm değerlendirme ölçütlerinde üstün performans sergileyerek veri kümesinin hasar tespiti potansiyelini doğrulamıştır. Ardından model, hipotezin test edilmesi için $TE23D_{B1}$ ve $TE23D_{B2}$ veri kümeleri üzerinde de eğitilmiş ve karşılaştırmalı analizden elde edilen sonuçlar, hasarlı alanların segmentasyonu görevinde $TE23D_A$ veri kümesi üzerinde eğitilmiş olan $SegFormer_A$ modelinin $TE23D_{B1}$ veri kümesi üzerinde eğitilmiş olan $SegFormer_{B1}$ ve $TE23D_{B2}$ veri kümesi üzerinde eğitilmiş olan $SegFormer_{B2}$ modellerinden daha iyi performans gösterdiğini ortaya koymuştur. Bu sonuç, bina etiketlerini dahil etmek yerine yalnızca hasarlı alanları etiketlemeye odaklanmanın etkili hasar tespiti için yeterli olduğu hipotezini desteklemektedir. Binaların etiketlenmesinin getirdiği ek karmaşıklık daha iyi sonuçlar vermemiştir, bu da anomali tabanlı etiketleme yaklaşımını desteklemektedir. Bu bulgular, TE23D veri kümesinin afet sonrası müdahale ve iyileştirme çabalarının iyileştirilmesindeki değerinin altını çizmektedir. Kolaylaştırılmış etiketleme yaklaşımı, doğal afetlerin ardından hızlı değerlendirme ve karar verme için kritik öneme sahip olan verimli ve doğru segmentasyonun sağlanmasına yardımcı olmaktadır.

Bu tezin sonuçları, afet yönetimi ve kentsel planlama alanı için daha geniş kapsamlı bazı çıkarımlara sahiptir. TE23D veri kümesinin oluşturulması ve etiketlenmesi için geliştirilen metodoloji, diğer doğal afet türlerine uygulanabilir ve çeşitli senaryolarda hasarın hızlı ve doğru bir şekilde değerlendirilmesini kolaylaştırabilir. Anomali tabanlı etiketleme yaklaşımı, büyük hacimli uydu görüntülerinin işlenmesi için ölçeklenebilir bir çözüm sunmakta ve afet sonrası değerlendirmelerin yapılma şeklini potansiyel olarak dönüştürmektedir.

Gelecekteki çalışmalarda, bu tezin bulgularını ilerletmek için çeşitli yöntemler geliştirebilir. Potansiyel yönlerden biri, uydu görüntülerini tamamlamak ve etkilenen alanların daha kapsamlı bir görünümünü sağlamak amacıyla drone görüntüleri ve yer seviyesi fotoğrafları gibi ek veri kaynaklarının entegrasyonudur. Ayrıca, hasar tespit modellerinin doğruluğunu ve verimliliğini daha da artırmak için yarı denetimli ve denetimsiz öğrenme dahil olmak üzere gelişmiş makine öğrenimi teknikleri ve farklı segmentasyon yöntemleri kullanılabilir.

Gelecekteki araştırmalar için bir diğer alan, afet sonrası mücadelenin daha hızlı ve efektif olarak yapılabilmesi için uydulardan alınan görüntülerin kadastro bilgisi ile eşleştirilmesidir. Bu sayede deprem sonrasında hasarlı alanların lokalizasyonunun daha başarılı bir şekilde yapılması sağlanacaktır. Buna ek olarak çalışmada hipotezin test edilebilmesi için binalar yapay zeka yöntemleri ile otomatize edilerek etiketlenmiştir. Bunun yerine veri kümesi kadastro bilgisi ile eşleştirilerek daha

sağlıklı bina etiketleri elde edilebilir. Böylece veri kümesindeki bina etiketlerinin güvenilirliği kuşkuya yer bırakmayacak şekilde kesinleşmiş olacaktır. Bu şartlar altında hipotez testi daha güvenilir olarak yapılabilir.

Bu tezin bulguları, afet sonrası değerlendirme ve müdahale stratejilerinin geliştirilmesinde yüksek kaliteli veri kümelerinin ve gelişmiş makine öğrenimi modellerinin kritik rolünü vurgulamaktadır. TE23D veri kümesi ve tez kapsamında geliştirilen yaklaşım ile, deprem sonrası genel durumun ayrıntılı ve güvenilir bir temsilini sağlayarak, doğal afetlerin etkilerinin daha iyi anlaşılmasına katkıda bulunmayı ve etkili iyileştirme çabalarının geliştirilmesini amaçlamaktadır.

KAYNAKÇA

[1] *World health organization*, https://www.who.int/health-topics/earthquakes, Accessed: 2024-02-25.

[2] *British red cross*, https://www.redcross.org.uk/stories/disasters-and-emergencies/world/turkey-syria-earthquake, Accessed: 2024-02-25.

[3] Z. Zheng, Y. Zhong, J. Wang, A. Ma, L. Zhang, "Building damage assessment for rapid disaster response with a deep object-based semantic change detection framework: From natural disasters to man-made disasters," *Remote Sensing of Environment*, vol. 265, p. 112 636, 2021.

[4] J. Sublime, E. Kalinicheva, "Automatic post-disaster damage mapping using deep-learning techniques for change detection: Case study of the tohoku tsunami," *Remote Sensing*, vol. 11, no. 9, p. 1123, 2019.

[5] J. Z. Xu, W. Lu, Z. Li, P. Khaitan, V. Zaytseva, "Building damage detection in satellite imagery using convolutional neural networks," *arXiv preprint arXiv:1910.06444*, 2019.

[6] C. Xiong, Q. Li, X. Lu, "Automated regional seismic damage assessment of buildings using an unmanned aerial vehicle and a convolutional neural network," *Automation in Construction*, vol. 109, p. 102 994, 2020.

[7] Y. Qing *et al.*, "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, p. 102 899, 2022.

[8] Z. Hong *et al.*, "Classification of building damage using a novel convolutional neural network based on post-disaster aerial images," *Sensors*, vol. 22, no. 15, p. 5920, 2022.

[9] T. Ci, Z. Liu, Y. Wang, "Assessment of the degree of building damage caused by disaster using convolutional neural networks in combination with ordinal regression," *Remote Sensing*, vol. 11, no. 23, p. 2858, 2019.

[10] T. Chowdhury, R. Murphy, M. Rahnemoonfar, "Rescuenet: A high resolution uav semantic segmentation benchmark dataset for natural disaster damage assessment," *arXiv preprint arXiv:2202.12361*, 2022.

[11] A. Fujita, K. Sakurada, T. Imaizumi, R. Ito, S. Hikosaka, R. Nakamura, "Damage detection from aerial images via convolutional neural networks," in *2017 Fifteenth IAPR international conference on machine vision applications (MVA)*, IEEE, 2017, pp. 5–8.

[12] S. A. Chen, A. Escay, C. Haberland, T. Schneider, V. Staneva, Y. Choe, "Benchmark dataset for automatic damaged building detection from post-hurricane remotely sensed imagery," *arXiv preprint arXiv:1812.05581*, 2018.

[13] R. Gupta *et al.*, "Xbd: A dataset for assessing building damage from satellite imagery," *arXiv preprint arXiv:1911.09296*, 2019.

[14] F. Alam, T. Alam, M. A. Hasan, A. Hasnat, M. Imran, F. Ofli, "Medic: A multi-task learning dataset for disaster image classification," *Neural Computing and Applications*, vol. 35, no. 3, pp. 2609–2632, 2023.

[15] E. Weber *et al.*, "Detecting natural disasters, damage, and incidents in the wild," in *Computer Vision–ECCV 2020: 16th European Conference, Glasgow, UK, August 23–28, 2020, Proceedings, Part XIX 16*, Springer, 2020, pp. 331–350.

[16] E. Weber, D. P. Papadopoulos, A. Lapedriza, F. Ofli, M. Imran, A. Torralba, "Incidents1m: A large-scale dataset of images with natural disasters, damage, and incidents," *IEEE transactions on pattern analysis and machine intelligence*, vol. 45, no. 4, pp. 4768–4781, 2022.

[17] B. Tasci, M. R. Acharya, M. Baygin, S. Dogan, T. Tuncer, S. B. Belhaouari, "Incr: Inception and concatenation residual block-based deep learning network for damaged building detection using remote sensing images," *International Journal of Applied Earth Observation and Geoinformation*, vol. 123, p. 103 483, 2023.

[18] D. Duarte, F. Nex, N. Kerle, G. Vosselman, "Multi-resolution feature fusion for image classification of building damages with convolutional neural networks," *Remote sensing*, vol. 10, no. 10, p. 1636, 2018.

[19] Y. Wang, W. Feng, K. Jiang, Q. Li, R. Lv, J. Tu, "Real-time damaged building region detection based on improved yolov5s and embedded system from uav images," *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 16, pp. 4205–4217, 2023.

[20] D. Song, X. Tan, B. Wang, L. Zhang, X. Shan, J. Cui, "Integration of super-pixel segmentation and deep-learning methods for evaluating earthquake-damaged buildings using single-phase remote sensing imagery," *International Journal of Remote Sensing*, vol. 41, no. 3, pp. 1040–1066, 2020.

[21] Y. Xie *et al.*, "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.

[22] Y. Zhan, W. Liu, Y. Maruyama, "Damaged building extraction using modified mask r-cnn model using post-event aerial images of the 2016 kumamoto earthquake," *Remote Sensing*, vol. 14, no. 4, p. 1002, 2022.

[23] T. Li, C. Wang, H. Zhang, F. Wu, X. Zheng, "Ddformer: A dual-domain transformer for building damage detection using high-resolution sar imagery," *IEEE Geoscience and Remote Sensing Letters*, vol. 20, pp. 1–5, 2023.

[24] B. Kalantar, N. Ueda, H. A. Al-Najjar, A. A. Halin, "Assessment of convolutional neural network architectures for earthquake-induced building damage detection based on pre-and post-event orthophoto images," *Remote Sensing*, vol. 12, no. 21, p. 3529, 2020.

[25] C. Wu *et al.*, "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.

[26] S. Ghaffarian, N. Kerle, E. Pasolli, J. Jokar Arsanjani, "Post-disaster building database updating using automated deep learning: An integration of pre-disaster openstreetmap and multi-temporal satellite data," *Remote sensing*, vol. 11, no. 20, p. 2427, 2019.

[27] M. Tkachenko, M. Malyuk, A. Holmanyuk, N. Liubimov, *Label Studio: Data labeling software*, Open source software available from https://github.com/heartexlabs/label-studio, 2020-2022. [Online]. Available: `https://github.com/heartexlabs/label-studio`.

[28] T. Bakirman, I. Komurcu, E. Sertel, "Comparative analysis of deep learning based building extraction methods with the new vhr istanbul dataset," *Expert Systems with Applications*, vol. 202, p. 117 346, 2022.

[29] V. Mnih, "Machine learning for aerial image labeling," Ph.D. dissertation, University of Toronto, 2013.

[30] K. He, G. Gkioxari, P. Dollár, R. Girshick, "Mask r-cnn," in *Proceedings of the IEEE international conference on computer vision*, 2017, pp. 2961–2969.

[31] R. Girshick, "Fast r-cnn," in *Proceedings of the IEEE international conference on computer vision*, 2015, pp. 1440–1448.

[32] J. Hui, *Image segmentation with mask r-cnn*, Apr. 2018. [Online]. Available: `https://jonathan-hui.medium.com/image-segmentation-with-mask-r-cnn-ebe6d793272`.

[33] O. Ronneberger, P. Fischer, T. Brox, "U-net: Convolutional networks for biomedical image segmentation," in *Medical image computing and computer-assisted intervention–MICCAI 2015: 18th international conference, Munich, Germany, October 5-9, 2015, proceedings, part III 18*, Springer, 2015, pp. 234–241.

[34] Z. Zhou, M. M. Rahman Siddiquee, N. Tajbakhsh, J. Liang, "Unet++: A nested u-net architecture for medical image segmentation," in *Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support: 4th International Workshop, DLMIA 2018, and 8th International Workshop, ML-CDS 2018, Held in Conjunction with MICCAI 2018, Granada, Spain, September 20, 2018, Proceedings 4*, Springer, 2018, pp. 3–11.

[35] J. Hu, L. Shen, G. Sun, "Squeeze-and-excitation networks," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2018, pp. 7132–7141.

[36] J. Deng, W. Dong, R. Socher, L.-J. Li, K. Li, L. Fei-Fei, "Imagenet: A large-scale hierarchical image database," in *2009 IEEE conference on computer vision and pattern recognition*, Ieee, 2009, pp. 248–255.

[37] H. Bao, L. Dong, S. Piao, F. Wei, "Beit: Bert pre-training of image transformers," *arXiv preprint arXiv:2106.08254*, 2021.

[38] T. Ridnik, E. Ben-Baruch, A. Noy, L. Zelnik-Manor, *Imagenet-21k pretraining for the masses*, 2021. arXiv: 2104.10972 [cs.CV].

[39] B. Zhou *et al.*, "Semantic understanding of scenes through the ade20k dataset," *International Journal of Computer Vision*, vol. 127, pp. 302–321, 2019.

[40] R. Ranftl, A. Bochkovskiy, V. Koltun, "Vision transformers for dense prediction," in *Proceedings of the IEEE/CVF international conference on computer vision*, 2021, pp. 12 179–12 188.

[41] S. Mehta, M. Rastegari, "Mobilevit: Light-weight, general-purpose, and mobile-friendly vision transformer," *arXiv preprint arXiv:2110.02178*, 2021.

[42] L.-C. Chen, G. Papandreou, F. Schroff, H. Adam, "Rethinking atrous convolution for semantic image segmentation," *arXiv preprint arXiv:1706.05587*, 2017.

[43] M. Everingham, S. A. Eslami, L. Van Gool, C. K. Williams, J. Winn, A. Zisserman, "The pascal visual object classes challenge: A retrospective," *International journal of computer vision*, vol. 111, pp. 98–136, 2015.

[44] E. Xie, W. Wang, Z. Yu, A. Anandkumar, J. M. Alvarez, P. Luo, "Segformer: Simple and efficient design for semantic segmentation with transformers," *Advances in Neural Information Processing Systems*, vol. 34, pp. 12 077–12 090, 2021.

[45] N. Qin, W. Tan, L. Ma, D. Zhang, J. Li, "Opengf: An ultra-large-scale ground filtering dataset built upon open als point clouds around the world," in *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition*, 2021, pp. 1082–1091.

[46] S. Mehta, M. Rastegari, A. Caspi, L. Shapiro, H. Hajishirzi, "Espnet: Efficient spatial pyramid of dilated convolutions for semantic segmentation," in *Proceedings of the European Conference on Computer Vision (ECCV)*, 2018, pp. 552–568.

TEZDEN ÜRETİLMİŞ YAYINLAR

Poster

1 C. Ekkazan and M. E. Karslıgil, “A Dataset of Feb 6, 2023 Turkey Earthquakes and Evaluation” in *GradColloquium’24 Artificial Intelligence*, Yıldız Teknik Üniversitesi Yayınevi, 2024, pp. 47–47.