

**DERİN ÖĞRENME İLE FARKLI VERİ KAYNAKLARINDAN ELDE EDİLEN
GÖRÜNTÜLERDEN BİNA TESPİTİ**

YÜKSEK LİSANS TEZİ

Şükrü Batuhan BİLGİLİ

Danışman

Prof. Dr. Murat UYSAL

HARİTA MÜHENDİSLİĞİ ANABİLİM DALI

Mart 2025

AFYON KOCATEPE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

DERİN ÖĞRENME İLE FARKLI VERİ KAYNAKLARINDAN
ELDE EDİLEN GÖRÜNTÜLERDEN BİNA TESPİTİ

Şükrü Batuhan BİLGİLİ

Danışman
Prof. Dr. Murat UYSAL

HARİTA MÜHENDİSLİĞİ ANABİLİM DALI

Mart 2025

TEZ ONAY SAYFASI

Şükrü Batuhan BİLGİLİ tarafından hazırlanan “Derin Öğrenme İle Farklı Veri Kaynaklarından Elde Edilen Görüntülerden Bina Tespiti” adlı tez çalışması lisansüstü eğitim ve öğretim yönetmeliğinin ilgili maddeleri uyarınca 20 / 02 / 2025 tarihinde aşağıdaki jüri tarafından **oy birliği** ile Afyon Kocatepe Üniversitesi Fen Bilimleri Enstitüsü **Harita Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Danışman : Prof. Dr. Murat UYSAL

Başkan : Doç. Dr. Nizar POLAT
Harran Üniversitesi,
Mühendislik Fakültesi

..... İmza

Üye : Dr. Öğr. Üyesi Abdullah VARLIK
Necmettin Erbakan Üniversitesi,
Mühendislik ve Mimarlık Fakültesi

..... İmza

Afyon Kocatepe Üniversitesi
Fen Bilimleri Enstitüsü Yönetim Kurulu’nun
..... /..... /..... tarih ve
..... sayılı kararıyla onaylanmıştır.

.....

Prof. Dr. Bekir YALÇIN
Enstitü Müdürü

BİLİMSEL ETİK BİLDİRİM SAYFASI
Afyon Kocatepe Üniversitesi

Fen Bilimleri Enstitüsü, tez yazım kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez içindeki bütün bilgi ve belgeleri akademik kurallar çerçevesinde elde ettiğimi,
- Görsel, işitsel ve yazılı tüm bilgi ve sonuçları bilimsel ahlak kurallarına uygun olarak sunduğumu,
- Başkalarının eserlerinden yararlanılması durumunda ilgili eserlere bilimsel normlara uygun olarak atıfta bulunduğumu,
- Atıfta bulunduğum eserlerin tümünü kaynak olarak gösterdiğimi,
- Kullanılan verilerde herhangi bir tahrifat yapmadığımı,
- Ve bu tezin herhangi bir bölümünü bu üniversite veya başka bir üniversitede başka bir tez çalışması olarak sunmadığımı

beyan ederim.

20 / 02 / 2025

Şükrü Batuhan BİLGİLİ

ÖZET

Yüksek Lisans Tezi

DERİN ÖĞRENME İLE FARKLI VERİ KAYNAKLARINDAN ELDE EDİLEN GÖRÜNTÜLERDEN BİNA TESPİTİ

Şükrü Batuhan BİLGİLİ

Afyon Kocatepe Üniversitesi

Fen Bilimleri Enstitüsü

Harita Mühendisliği Anabilim Dalı

Danışman: Prof. Dr. Murat UYSAL

Uzaktan algılama teknolojilerindeki hızlı gelişmeler ve yüksek çözünürlüklü uydu görüntüleri ile hava araçlarının yaygınlaşması, kentsel alanlarda bina tespiti gibi uygulamaları daha etkin hale getirmiştir. Derin öğrenme yöntemleri, bu süreçte geleneksel yöntemlere kıyasla daha hızlı, hassas ve ölçeklenebilir çözümler sunarak şehir planlaması, afet yönetimi ve çevresel analizler gibi alanlarda kritik bir rol üstlenmiştir. Bu tez çalışmasında, nesne tespiti problemleri için yaygın olarak kullanılan YOLO (Sadece Bir Kez Bak) algoritmasının iki farklı sürümü olan YOLOv8m ve YOLOv11m ile Mask-RCNN (Bölge Tabanlı Evrişimsel Sinir Ağının Maskelenmesi) algoritmaları, iki farklı veri kaynağından (Harita Genel Müdürlüğü ortofotosu ve WorldView03 uydu görüntüsü) elde edilen görüntüler üzerinde bina tespiti çalışması için test edilmiştir. YOLO algoritmaları Google Colab ortamında, Mask-RCNN algoritması ise ArcGIS Pro uygulamasında değerlendirilmiştir. Sonuç olarak, YOLO ve Mask-RCNN algoritmalarının bina tespiti alanındaki potansiyeli ortaya konulmuş ve bu çalışmanın, uzaktan algılama teknolojileri ile yapay zeka tabanlı çözümlerin entegrasyonuna katkı sunması hedeflenmiştir.

2025, x + 62 sayfa

Anahtar Kelimeler: Yapay Zeka, Derin Öğrenme, YOLO, Mask-RCNN, Uzaktan Algılama, Çözünürlük

ABSTRACT

M.Sc. Thesis

BUILDING DETECTION FROM IMAGES OBTAINED FROM DIFFERENT DATA SOURCES USING DEEP LEARNING

Şükrü Batuhan BİLGİLİ

Afyon Kocatepe University

Graduate School of Natural and Applied Sciences

Department of Geomatics Engineering

Supervisor: Prof. Murat UYSAL

The rapid advancements in remote sensing technologies and the widespread use of high-resolution satellite imagery and aerial vehicles have made applications such as building detection in urban areas more effective. Deep learning methods have provided faster, more precise, and scalable solutions compared to traditional methods, playing a critical role in areas such as urban planning, disaster management, and environmental analysis. In this thesis study, two different versions of the YOLO (You Only Look Once) algorithm, YOLOv8m and YOLOv11m, which are widely used for object detection problems, along with the Mask-RCNN (Mask Region-Based Convolutional Neural Network) algorithm, were tested for building detection using images obtained from two different data sources (General Directorate of Mapping orthophoto and WorldView03 satellite imagery). The YOLO algorithms were evaluated in the Google Colab environment, while the Mask-RCNN algorithm was assessed in the ArcGIS Pro application. As a result, the potential of YOLO and Mask-RCNN algorithms in the field of building detection was demonstrated, and this study aims to contribute to the integration of remote sensing technologies with artificial intelligence-based solutions.

2025, x + 62 pages

Keywords: Artificial Intelligence, Deep Learning, YOLO, Mask-RCNN, Remote Sensing, Resolution

TEŞEKKÜR

Yüksek lisans sürecim boyunca bilgi ve tecrübeleriyle bana yol gösteren, sabır ve anlayışla beni destekleyen kıymetli danışmanım Sayın Prof. Dr. Murat UYSAL'a ve sorularımı yanıtsız bırakmayan Arş. Gör. Eren Can SEYREK'e en içten teşekkürlerimi sunarım.

Yüksek lisans sürecim boyunca motivasyon ve teknik yardımlarından ötürü meslektaşım Sefa TAVUKÇU'ya, teşekkür ederim.

Bu süreçte beni her zaman destekleyen ve yanımda olan, sağlamış oldukları maddi ve manevi destekleri ile bana güç veren annem Ayşe BİLGİLİ'ye, babam Nail BİLGİLİ'ye kardeşim Yunus Emre BİLGİLİ'ye sonsuz teşekkür ederim.

Bu tez, tüm bu değerli insanların katkıları sayesinde ortaya çıkmıştır. Hepsine gönülden teşekkür ederim.

Şükrü Batuhan BİLGİLİ

Afyonkarahisar 2025

İÇİNDEKİLER DİZİNİ

	Sayfa
ÖZET	i
ABSTRACT	ii
TEŞEKKÜR	iii
İÇİNDEKİLER DİZİNİ.....	iv
SİMGELER ve KISALTMALAR DİZİNİ	vi
ŞEKİLLER DİZİNİ	vii
ÇİZELGELER DİZİNİ.....	ix
RESİMLER DİZİNİ	x
1. GİRİŞ.....	1
2. LİTERATÜRDE BİNA TESPİTİ ÇALIŞMALARI	3
3. YAPAY ZEKA.....	10
3.1 Makine Öğrenmesi	12
3.1.1 Denetimli Öğrenme.....	13
3.1.2 Denetimsiz Öğrenme	13
3.1.3 Yarı Denetimli Öğrenme	13
3.1.4 Pekiştirmeli Öğrenme	14
3.2 Derin Öğrenme	14
3.2.1 Derin Öğrenme Süreçleri	16
3.3 Nesne Tanıma Algoritmaları	16
3.3.1 Mask R-CNN	17
3.3.2 YOLO Algoritması	18
3.3.2.1 YOLOv8 Algoritması.....	19
3.3.2.2 YOLOv11 Algoritması	20
4. MATERYAL VE METOT	24
4.1 Çalışma Alanları	24
4.2 Veri Seti	24
4.3 Verinin Etiketlenmesi	26
4.4 Değerlendirme Kriterleri	27
5. UYGULAMA.....	29
5.1 Çalışma Alanı 1 Bina Tespit Modelleri ve Doğruluk Analizleri.....	30
5.1.1 Çalışma Alanı 1 YOLOv8 Bina Tespit Modeli	30
5.1.2 Çalışma Alanı 1 YOLOv8 Doğruluk Analizi	31

5.1.3 Çalışma Alanı 1 YOLOv11 Bina Tespit Modeli	34
5.1.4 Çalışma Alanı 1 YOLOv11 Doğruluk Analizi	34
5.1.5 Çalışma Alanı 1 Mask-RCNN Bina Tespit Modeli	37
5.1.6 Çalışma Alanı 1 Mask-RCNN Doğruluk Analizi	38
5.2 Çalışma Alanı 2 Bina Tespit Modelleri ve Doğruluk Analizleri.....	39
5.2.1 Çalışma Alanı 2 YOLOv8 Bina Tespit Modeli	39
5.2.2 Çalışma Alanı 2 YOLOv8 Doğruluk Analizi	40
5.2.3 Çalışma Alanı 2 YOLOv11 Bina Tespit Modeli	43
5.2.4 Çalışma Alanı 2 YOLOv11 Doğruluk Analizi	43
5.2.5 Çalışma Alanı 2 Mask-RCNN Bina Tespit Modeli	47
5.2.6 Çalışma Alanı 2 Mask-RCNN Doğruluk Analizi	47
6. BULGULAR	49
7. TARTIŞMA ve SONUÇ	51
8. KAYNAKLAR.....	52
ÖZGEÇMİŞ.....	59
EKLER	60

SİMGELER ve KISALTMALAR DİZİNİ

Simgeler

b_x	Orta Nokta
b_y	Orta Nokta
b_w	Genişlik
b_h	Yükseklik
p_c	Güven Skoru
c	Bağıl Sınıf Olasılığı

Kısaltmalar

API	Application Programming Interface
AP	Average Precision
CAVIS	Clouds, Aerosols, Vapor, Ice, and Snow
C2PSA	Cross-Stage Partial Architecture
CBS	Convolution-Batch Normalization-Sigmoid Linear Unit
CNN	Convolutional Neural Network
COCO	Common Objects in Context
CPU	Central Processing Unit
ECBA	Efficient Channel Attention
FASTER R-CNN	Faster Region-Based Convolutional Neural Network
FAST R-CNN	Fast Region-Based Convolutional Neural Network
FP	False Positive
FPN	Feature Pyramid Networks
FN	False Negative
GPU	Graphics Processing Unit
HGM	Harita Genel Müdürlüğü
IOU	Intersection over Union
İHA	İnsansız Hava Aracı
LIDAR	Light Detection and Ranging
MAP	Mean Average Precision
MASK R-CNN	Mask Region-Based Convolutional Neural Network
NDVI	Normalized Difference Vegetation Index
R-CNN	Region-Based Convolutional Neural Network
RGB	Red-Green-Blue
ROIALIGN	Region of Interest Align
SAM	Segment Anything Model
SAR	Synthetic Aperture Radar
SEGNET	Segmenting Neural Network
SSD	Single Shot Detector
SPPF	Spatial Pyramid Pooling Fast
SWIR	Short-Wave Infrared
TN	True Negative
TP	True Positive
WV03	WorldView03
YOLO	You Look Only Once

ŞEKİLLER DİZİNİ

	Sayfa
Şekil 3.1 Turing testi ve oyuncular (İnt.Kyn.4).....	11
Şekil 3.2 Yapay zeka ve alt dalları (Piltan 2022).	11
Şekil 3.3 Bir otokodlayıcının yapısı (Piltan 2022).	14
Şekil 3.4 Makine ve derin öğrenme algoritmalarının işleyişi.....	15
Şekil 3.5 Nesne tanıma yaklaşımları (Ersan 2024).	16
Şekil 3.6 Mask-RCNN aşamalarının gösterimi (Yörük vd. 2023).	17
Şekil 3.7 YOLO modeli (Nasrullah ve Diker 2021).....	18
Şekil 3.8 Sınırlayıcı kutu (Ersan 2024).	19
Şekil 3.9 Coco veri seti mAP grafiği (İnt.Kyn.1).....	21
Şekil 4.1 Veri setinden örnek görüntüler.....	25
Şekil 4.2 MakeSenseAI Arayüzü.....	26
Şekil 4.3 Karışıklık matrisi gösterimi (Yıldırım 2023).	27
Şekil 5.1 Çalışmanın YOLO algoritması akış diyagramı.....	29
Şekil 5.2 Çalışmanın MASK-RCNN algoritması akış diyagramı.....	30
Şekil 5.3 Çalışma alanı 1 YOLOv8 modelinin kesinlik eğrisi.....	31
Şekil 5.4 Çalışma alanı 1 YOLOv8 modelinin duyarlılık eğrisi.....	31
Şekil 5.5 Çalışma alanı 1 YOLOv8 modelinin kesinlik – duyarlılık eğrisi.....	32
Şekil 5.6 Çalışma alanı 1 YOLOv8 performans grafikleri.....	32
Şekil 5.7 Çalışma alanı 1 YOLOv8 karışıklık matrisi.....	33
Şekil 5.8 Çalışma alanı 1 YOLOv8 bina tespiti.....	34

Şekil 5.9 Çalışma alanı 1 YOLOv11 modelinin kesinlik eğrisi	35
Şekil 5.10 Çalışma alanı 1 modelinin duyarlılık eğrisi	35
Şekil 5.11 Çalışma alanı 1 YOLOv11 modelinin kesinlik – duyarlılık eğrisi.....	35
Şekil 5.12 Çalışma alanı 1 YOLOv11 performans grafikleri.....	36
Şekil 5.13 Çalışma alanı 1 YOLOv11 karışıklık matrisi.....	37
Şekil 5.14 Çalışma alanı 1 YOLOv11 bina tespiti	38
Şekil 5.15 Çalışma alanı 1 Mask-RCNN karışıklık matrisi	38
Şekil 5.16 Çalışma alanı 1 gerçek bina etiket özellikleri ve bina tespiti	39
Şekil 5.17 Çalışma alanı 2 YOLOv8 modelinin kesinlik eğrisi	40
Şekil 5.18 Çalışma alanı 2 YOLOv8 modelinin duyarlılık eğrisi	40
Şekil 5.19 Çalışma alanı 2 YOLOv8 modelinin kesinlik – duyarlılık eğrisi.....	41
Şekil 5.20 Çalışma alanı 2 YOLOv8 performans grafikleri.....	41
Şekil 5.21 Çalışma alanı 2 YOLOv8 karışıklık matrisi.....	42
Şekil 5.22 Çalışma alanı 2 YOLOv8 bina tespiti	43
Şekil 5.23 Çalışma alanı 2 YOLOv11 modelinin kesinlik eğrisi	44
Şekil 5.24 Çalışma alanı 2 YOLOv11 modelinin duyarlılık eğrisi	44
Şekil 5.25 Çalışma alanı 2 YOLOv11 modelinin kesinlik – duyarlılık eğrisi.....	44
Şekil 5.26 Çalışma alanı 2 YOLOv11 performans grafikleri.....	45
Şekil 5.27 Çalışma alanı 2 YOLOv11 karışıklık matrisi.....	46
Şekil 5.28 Çalışma alanı 2 YOLOv11 bina tespiti	46
Şekil 5.29 Çalışma alanı 2 Mask-RCNN karışıklık matrisi	47
Şekil 5.30 Çalışma alanı 2 gerçek bina etiket özellikleri ve bina tespiti	48

ÇİZELGELER DİZİNİ

	Sayfa
Çizelge 5.1 Çalışma alanı 1 YOLOv8m modelinin 200. epokta değerleri.....	33
Çizelge 5.2 Çalışma alanı 1 YOLO modellerinin 200. epokta değerleri.....	37
Çizelge 5.3 Çalışma alanı 1 IoU değerine göre sonuçları	38
Çizelge 5.4 Çalışma alanı 2 YOLOv8m 200. epokta değerleri.....	42
Çizelge 5.5 Çalışma alanı 2 YOLOv8, YOLOv11 200. epokta değerleri.....	46
Çizelge 5.6 Çalışma alanı 2 IoU değerine göre sonuçları	47

RESİMLER DİZİNİ

	Sayfa
Resim 4.1 Çalışma alanı 1	25
Resim 4.2 Çalışma alanı 2	25



1. GİRİŞ

Uzaktan algılama teknolojilerindeki hızlı gelişmeler, yüksek çözünürlüklü ve çok bantlı sensörlerin yaygınlaşması, uydu ve hava platformlarına dayalı görselleştirme araçlarının artması ve veri işleme maliyetlerinin düşmesi gibi faktörler, özellikle kentsel alanların mekânsal analizinde büyük bir rol oynamaktadır. Bu gelişmeler, bina tespiti ve yapısal özelliklerin belirlenmesi gibi alanlarda önemli katkılar sağlayarak kentsel planlama, afet yönetimi, altyapı iyileştirme, tarihi alanların korunması, akıllı şehir uygulamaları ve çevresel sürdürülebilirlik gibi çok yönlü uygulamaları desteklemektedir. Bu bağlamda, bina tespiti, kentsel gelişim ve yönetim süreçlerinde stratejik bir öneme sahiptir.

Uydu sistemleri ve yapay zeka yöntemlerindeki ilerlemeler, hava fotoğrafları ve uydu görüntülerinden binaların ve diğer nesnelerin otomatik olarak tespiti kolaylaştırmıştır. Bu durum, coğrafi veri tabanlarının güncellenmesi, arazi kullanım yönetimi, kent planlaması, afet yönetimi, nüfus yoğunluğu tahmini ve değişim izleme gibi birçok uygulamada hızlı ve güvenilir veri elde edilmesini mümkün kılmaktadır. Özellikle yüksek mekânsal çözünürlüklü uydu görüntüleri ile makine öğrenmesi ve derin öğrenme yöntemlerinin birleşimi, nesnelerin kısa sürede ve yüksek doğrulukla tespit edilmesine olanak tanımaktadır. Bu süreçte, Google Colaboratory gibi bulut tabanlı ve işbirlikçi programlama ortamları, yapay zeka ve derin öğrenme projelerinin hızlandırılmasında önemli bir rol oynamaktadır.

Bina tespiti, kentsel alanların yapı taşlarından biri olan binaların hava fotoğrafları veya uydu görüntüleri üzerinden belirlenmesini içermektedir. Bu süreç, binaların zaman içindeki sağlık durumlarının analizi, afet risk analizleri, 3 boyutlu kent modellerinin oluşturulması ve kaçak yapıların tespiti gibi birçok uygulamada kritik bir kaynak sağlamaktadır. Özellikle hızla artan kentleşme ve yapılaşma süreci, bina tespiti ve izlenebilirliği konularını daha da önemli hale getirmiştir. Doğal afetlerin yönetimi, şehir planlaması ve çevresel etkilerin değerlendirilmesi gibi alanlarda, bina tespiti büyük bir öneme sahiptir. Bu nedenle, yapay zeka ve derin öğrenme teknikleri, geleneksel yöntemlere kıyasla daha hassas, hızlı ve ölçeklenebilir çözümler sunarak bu alanda öne çıkmaktadır.

06 Şubat 2023 tarihinde Kahramanmaraş ve çevre illerde meydana gelen depremler, uzaktan algılama teknolojilerinin kriz sonrası dönemde bilgi üretimindeki rolünü net bir şekilde ortaya koymuştur. Ancak, hava koşulları, görüntü kalitesi, çatı tiplerindeki farklılıklar, çözünürlük düzeyleri ve veri erişimi gibi kısıtlar, görüntülerden doğru bilgi elde edilmesini zorlaştırmaktadır. Deprem sonrası yüzeydeki deformasyonların farklı bölgelerde değişen büyüklüklerde olması, deprem öncesi ve sonrası verilerin birlikte analiz edilmesini güçleştirmektedir. Bu nedenle, tek bir görüntüden hızlı ve doğru bilgi çıkarımı büyük önem taşımaktadır.

Derin öğrenme yaklaşımlarından biri olan YOLO (You Look Only Once) algoritması, nesne tespiti problemlerinde yüksek performansıyla dikkat çekmektedir. YOLO, tek bir işlemle hem nesnenin yerini hem de sınıflandırmasını gerçekleştirebilme yeteneği sunarak, özellikle büyük veri setleriyle çalışırken işlem hızını artırmaktadır. Bu özellikleriyle YOLO, havadan çekilen görüntülerden veya uydu fotoğraflarından etkili bir şekilde bina bilgisi çıkarma potansiyeline sahiptir. Benzer şekilde, Mask R-CNN (Mask Region Based Convolutional Neural Network) gibi modern derin öğrenme algoritmaları da nesne tespiti ve piksel düzeyinde segmentasyon yetenekleri sayesinde binaların sınırlarını hassas bir şekilde belirleyebilmektedir. Bu çalışmada, YOLOv8, YOLOv11 ve Mask R-CNN gibi derin öğrenme modellerinin bina tespiti görevindeki performansları incelenerek, bu alandaki mevcut yöntemlerin geliştirilmesine katkı sağlanması hedeflenmektedir.

Sonuç olarak, bina tespiti, kentsel planlama, afet yönetimi, çevresel sürdürülebilirlik ve akıllı şehir uygulamaları gibi birçok alanda kritik bir rol oynamaktadır. Yapay zeka ve derin öğrenme teknikleri, bu alanda geleneksel yöntemlere kıyasla daha hızlı, hassas ve ölçeklenebilir çözümler sunarak bina tespiti süreçlerini daha etkili hale getirmektedir. Bu çalışma, bina tespiti üzerine yapılan akademik araştırmalara katkı sağlamayı ve bu alandaki teknik çözümlerin geliştirilmesine ışık tutmayı amaçlamaktadır.

2. LİTERATÜRDE BİNA TESPİTİ ÇALIŞMALARI

Faster R-CNN (Faster Region Based Convolutional Neural Network) algoritması küçük ölçülü nesnelerin tespiti için uyarlanmış ve özel olarak oluşturulan veri seti ile eğitim işlemi gerçekleştirilerek, uydu görüntülerinden bina tespitini uygulamıştır. Model, yeniden eğitim gerektirmeksizin yeni uydu görüntülerinde otomatik olarak binaları tespit edebilmekte ve saniyeler içinde %88,6 doğrulukla sonuç verebilmektedir (Saralioğlu ve Güngör 2022).

Gerçek renkli uydu görüntüleri için farklı nesne tespit yaklaşımları araştırılmıştır. Derin öğrenme tabanlı Convolutional Neural Network (CNN) mimarileri, uzaktan algılama verileri için güçlü tespit algoritmalarıdır; ancak bu modellerin etkin şekilde kullanılabilmesi için uydu görüntülerinin ön işleme tabi tutulması gerekmektedir. Çalışmada, CNN modellerinin eğitimi için bazı hiperparametreler optimize edilmiş ve model performansına etkileri incelenmiştir. YOLO ve Faster R-CNN algoritmaları kullanılarak yapılan deneylerde, özellikle görüntü boyutu, öğrenme oranı ve iterasyon sayısının model başarımı üzerindeki etkileri değerlendirilmiştir. YOLO için 6000 iterasyon, Faster R-CNN için ise 200 bin iterasyon belirlenmiştir. Deneylerde, Faster R-CNN modeli için ResNet-50 ve Inception v2 omurgaları kullanılmış olup, ResNet-50'nin daha düşük yanlış negatif oranına sahip olduğu gözlemlenmiştir. YOLO modeli, bitişik binaların tespitinde başarılı bulunmuş, ancak aynı nesne için fazla sayıda sınırlayıcı kutu oluşturmuştur. Öte yandan, Faster R-CNN algoritmasının daha az nesne kaçırdığı, ancak farklı boyut ve malzemeye sahip binaların tespitinde zorlandığı belirlenmiştir (Özaydın 2021).

YOLOv3 tabanlı geliştirilen YOLO-S-CIOU modeliyle uzaktan algılama görüntülerinde belirli binaların tespiti iyileştirilmiştir. Darknet53 yerine kullanılan SRXnet modülü, benzer karmaşıklıkta daha güçlü özellik öğrenimi sağlar. Kaybın konum kısmında CIOU Loss kullanılması, sınırlayıcı kutu regresyonunu iyileştirir. Testlerde, YOLO-S-CIOU, YOLOv3'e göre daha az parametreyle (%4 daha az) daha yüksek AP (Average Precision) (%97,62) ve F1 (%97,50) sonuçlarına ulaşmıştır (Gao vd. 2021).

YOLOv3 ve YOLOv5 algoritmaları kullanılarak hava fotoğraflarındaki bina nesnelerinin otomatik tespiti gerçekleştirilmiştir. Eğitim süreci, fotoğraf parçalarının boyut ve ölçeğine uygun olarak yürütülmüş, böylece yeni bir hava fotoğrafı üzerinde tekrar eğitime gerek kalmadan hızlı ve otomatik bina tespiti yapılabilmektedir (Kocaman vd. 2023).

YOLOv3 ve YOLOv5 modelleri karşılaştırılarak halka açık binaların tespiti gerçekleştirilmiş ve YOLOv5'in daha yüksek performans sunduğu belirlenmiştir. Model, farklı boyut ve açılardan çekilmiş uydu görüntülerinde başarılı nesne tespiti yaparak gerçek zamanlı takip imkânı sağlamıştır (Karabulut 2022).

YOLOv5x modeli ile yüksek çözünürlüklü İHA (İnsansız Hava Aracı) görüntülerinden bina nesnelerini tespit etmeyi amaçlamıştır. Yalnızca bina çatısı görüntülerine dayanan sınıflandırma hatalarını azaltmak için sayısal topografik harita v2.0 verileri kullanılarak etiketleme yapılmıştır. Sonuçlar, test görüntülerinde %88-98, orto görüntülerde ise %52-96 doğruluk oranları elde etmiştir (Kim ve Hong 2021).

Deprem sonrası yıkılmış binaların tespiti için YOLOv7, YOLOv7x, YOLOv8l ve YOLOv8x modellerinin geliştirilmesi ve eğitilmesine odaklanmaktadır. 344 eğitim ve 124 doğrulama görüntüsünden oluşan veri kümesi üzerinde eğitilen modeller, özellikle YOLOv7'nin %79 mAP@.5 değerine ulaşmasıyla başarılı sonuçlar elde etmiştir. Bu doğruluk oranı, deprem etkisi altındaki bölgelerde yıkılmış bina tespiti açısından modelin etkinliğini ortaya koymaktadır. Önceki çalışmalarla kıyaslandığında, daha küçük bir veri kümesi kullanılmış olmasına rağmen, önerilen YOLO modelleri yüksek çözünürlüklü uydu görüntülerinde yıkılmış binaları doğru şekilde tespit ve kategorize edebilmiştir. Aynı zamanda, kaynak kısıtlı cihazlarda verimli çalışabilmesi ve çoklu görev yapabilmesi, bu modelleri coğrafi bilgi sistemleri tabanlı afet müdahale ve iyileştirme çalışmaları için değerli araçlar haline getirmektedir. Özellikle Kahramanmaraş deprem dizisi bağlamında yapılan analizler, çalışmanın deprem sonrası hasar tespitinde önemli bir gelişme sunduğunu göstermektedir (Ilmak vd. 2024).

YOLOv8 tabanlı derin öğrenme modeli, uydu görüntülerinden bina hasar tespiti yapmak amacıyla geliştirilmiştir. Model, özellikle "No-Damage" ve "Total-Destruction"

sınıflarında yüksek doğruluk göstermiş, ancak ağır hasarlı yapıları tespit etmede sınırlamalar ortaya çıkmıştır. Sonuçlar, modelin afet yönetimi süreçlerinde hızlı ve güvenilir bir değerlendirme aracı olarak kullanılabileceğini göstermektedir (Yap vd. 2024).

YOLOv5 ve YOLO-NAS modelleri sırasıyla 0.744 ve 0.869 F1 skorlarına ulaşırken, bina segmentasyonu için kullanılan RefineNet modeli 0.826 F1 skoru elde etmiştir. Ancak, görüntülerin aşırı bölünmesi bina tespitini zorlaştırmıştır. Bu sorunu gidermek için yapılan ince ayarlamalar sayesinde, iyileştirilmiş YOLOv5, YOLO-NAS ve RefineNet modelleri sırasıyla 0.883, 0.975 ve 0.932 F1 skorlarına ulaşmıştır. Özellikle, YOLO-NAS modeli 0.975 F1 skoru ile en yüksek nesne tespit başarımını gösterirken, YOLO-NAS-Segment Anything Model yöntemi 0.912 IoU (Intersection over Union) değeri ile bina sınırlarını en doğru şekilde belirlemiştir (Tasyurek 2024).

Segmenting Neural Network (SegNet) tabanlı derin öğrenme yönteminin, İHA görüntülerinden bina tespiti ve çıkarımı üzerindeki performansı değerlendirilmiş ve yöntemin uygulanabilirliği ile avantajları doğrulanmıştır. SegNet mimarisi ile eğitilen denetimli model, farklı lokasyonlardan toplanan test verilerinde binaları %90'a yakın bir genel doğrulukla başarılı bir şekilde çıkarmıştır (Boonpook vd. 2018).

Kentsel alanlarda bina tespiti için uzaktan algılama verileri Synthetic Aperture Radar (SAR) ve optik uydu görüntüleri ile vektörel bina verileri kullanılarak bir derin öğrenme modeli geliştirilmiştir. CNN tabanlı U-Net algoritması, SAR görüntüleri üzerinde bina tespiti için ilk kez uygulanmış ve yüksek doğruluk oranları elde edilmiştir. Model, farklı bantlardan (X band ve C band) elde edilen SAR görüntüleri üzerinde test edilmiş, ancak farklı bantlar arasında doğruluk düşüşleri ve gürültü artışı gözlemlenmiştir. Ayrıca, bitki sınıflandırma hatalarını azaltmak için Normalized Difference Vegetation Index (NDVI) bandı kullanılmış ve K-Ortalamlar yöntemiyle bina sınıfı bandı türetilmiştir. Modelin doğruluğu %81 olarak hesaplanmış ve kayıp değeri 0.4 olarak bulunmuştur (Emek 2022).

Doğal afet durumlarında zarar görme riski taşıyan yapılaşmış alanların yarı otomatik olarak tespit edilmesine yönelik yenilikçi bir derin öğrenme metodolojisi sunmaktadır.

Çalışmada, U-Net modeli kullanılarak, uydu ve hava görüntüleri üzerinden bina tespiti yapılmış ve eğitim sürecinde veri çeşitliliğini artırmak amacıyla veri genişletme (data augmentation) teknikleri uygulanmıştır. Modelin doğruluğunu artırmak için iki farklı kayıp fonksiyonu test edilmiş ve IoU tabanlı kayıp fonksiyonunun en iyi sonucu verdiği belirlenmiştir. Modelin farklı coğrafi bölgelerdeki performansını değerlendirmek amacıyla, heyelan riski taşıyan bölgelerdeki bina tespit yeteneği incelenmiş ve modelin iyi bir coğrafi transfer edilebilirlik düzeyine sahip olduğu gözlemlenmiştir (Francini vd. 2022).

Yalnızca jeoreferanslı nokta bulutları kullanılarak bina tespitinin yapılabilirliği araştırılmış, tespit edilen binaların izdüşüm alanları elde edilerek doğruluk analizi gerçekleştirilmiştir. İstanbul-Yeni Bosna, İzmir-Bergama ve Almanya-Vaihingen bölgelerine ait farklı lazer tarayıcılarla üretilmiş Light Detection and Ranging (LIDAR) verileri ile Afyon Kocatepe Üniversitesi Ahmet Necdet Sezer Kampüsü ve İzmir-Bergama'da İHA ile üretilen görüntü tabanlı nokta bulutları kullanılmıştır. Nokta bulutları, görüntü formatına çevrilerek yükseklik modelleri oluşturulmuş ve bina tespitinde uygun doku parametreleri araştırılmıştır. Görsel analizler sonucunda "Benzemezlik" parametresinin bina dokusunu en iyi şekilde yansıttığı görülmüştür. Ancak bitişik nizam yapılar ve ağaçlarla bütünleşen binaların doğru tespitini sağlamak amacıyla morfolojik aşınma operatörü uygulanarak ağaçların ve birleşik objelerin ayrıştırılması sağlanmıştır. Elde edilen bina izdüşüm alanları vektör formatına dönüştürülmüş ve Douglas-Peucker algoritması ile pürüzsüz hale getirilmiştir. Performans karşılaştırması için Envi LIDAR yazılımı kullanılmış, ancak önerilen yöntemin daha başarılı sonuçlar verdiği görülmüştür. Doğruluk analizi için üretici doğruluğu, kullanıcı doğruluğu ve kalite metrikleri hesaplanmış ve önerilen yöntemin bina tespit çalışmalarında kullanılabilir olduğu gösterilmiştir. Sonuç olarak, LIDAR ve görüntü tabanlı nokta bulutlarının bina tespitinde etkin bir şekilde kullanılabileceği ortaya konulmuştur. İHA ile gerçekleştirilen nadir ve eğik uçuşların ayrı ayrı değerlendirilmesi, LIDAR ve görüntü tabanlı verilerin karşılaştırılması ve Benzemezlik doku parametresinin bina tespitine uygulanması literatüre katkı sağlamaktadır. Bununla birlikte, aşınma operatörünün düşük yükseklikteki binaları etkileyebilmesi ve bitişik nizam yapıların ayrıştırılmasında sınırlamalar olması yöntemin dezavantajları arasında yer almaktadır (Polat 2018).

Farklı boyutlardaki binaları etkili bir şekilde tespit edebilen çoklu görevli bir bina tespiti modeli önerilmiştir. Ayrıca, model yol etiketlerini kullanmadan, yol bilgilerini dolaylı olarak değerlendirebilmektedir. Önerilen model, geleneksel U-Net modeline kıyasla önemli bir iyileşme sağlamıştır (Hamaguchi ve Hikosaka 2018).

Düşük ışıklı uydu görüntülerinden bina tespiti için etkili bir model önerilmektedir. Öncelikle, dalgacık dönüşümü ve tekil değer ayrıştırması kullanılarak görüntü kontrastı artırılmaktadır. Daha sonra, EDLines çizgi dedektörü ile bina kenarları belirlenerek algısal grupta yöntemiyle tespit işlemi gerçekleştirilmiştir. QuickBird uydu görüntüleri üzerinde yapılan deneyler, önerilen yöntemin %89,02 doğruluk oranına ulaştığını ve önceki yaklaşımlara kıyasla daha hızlı çalıştığını göstermektedir. Sonuçlar, dalgacık dönüşümünün düşük ışıklı görüntülerin iyileştirilmesinde etkili olduğunu ve bina tespitinde yüksek doğruluk sağladığını ortaya koymaktadır (Aamir vd. 2019).

Gelişmiş makine öğrenmesi teknikleri ve coğrafi veri işleme entegrasyonu ile kent morfolojisini detaylı bir şekilde incelemeyi mümkün kılmaktadır. Mask R-CNN-HR modelinin kullanımıyla bina ayak izi çıkarımı, bina türü sınıflandırması ve yükseklik tahmini gibi işlemler yüksek doğrulukla yapılmaktadır. Model, konut binalarının yükseklik tahminlerinde büyük başarı gösterirken, enerji modelleme gibi alanlarda da pratikte etkin sonuçlar elde edilmiştir (Wang vd. 2025).

Uydu görüntülerinde bina tespitini iyileştirmek amacıyla Segment Anything Model (SAM) kullanılmıştır. Geleneksel bina tespit modelleri Red-Green-Blue (RGB) görüntülerle çalışırken, bina sınırlarını belirlemede yetersiz kalmaktadır. Bu sorunu gidermek için SAM ürettiği segmentasyon maskesi ek bir kanal olarak dahil edilmiştir. DeepLabV3+ modeli ve Dilated ResNet C42 omurgası kullanılarak geliştirilen model, SpaceNet veri seti ile eğitilmiş ve Güneydoğu Asya'ya özel bir veri seti ile ince ayar yapılmıştır. Sonuçlar, modelin %94 doğruluk, %80.5 IoU ve %89.2 F1 skoru elde ettiğini göstermektedir. Özellikle, SAM sağladığı ek bilgilerin bina sınırlarının daha keskin ve doğru tespit edilmesini sağladığı belirlenmiştir. Bu çalışma, SAM yönteminin uydu görüntüleri ile bina tespitinde başarılı bir şekilde kullanılabileceğini ve şehir planlama, afet yönetimi ve bina haritalama gibi alanlara katkı sunabileceğini ortaya koymaktadır (Huang vd. 2024).

Derin öğrenme tabanlı görüntü segmentasyon modelleri (U-net, Feature Pyramid Network (FPN)) kullanılarak 6 Şubat 2023 Pazarcık ve Elbistan depremlerinde yıkılan binaların tespitini incelemektedir. Yapılan değerlendirmelerde FPN modeli en yüksek doğruluk ve özgüllük değerlerine ulaşırken, U-Net modeli geri çağırma, F1 skoru ve IoU açısından üstün performans sergilemiştir. Sonuçlar, derin öğrenme modellerinin afet sonrası hasar tespitinde etkili olduğunu göstermekte ve modellerin gerçek zamanlı afet yönetim sistemlerine entegrasyonu için önemli bir temel oluşturmaktadır (Hacıfendioğlu vd. 2024).

Yüksek çözünürlüklü uydu görüntülerinden bina çıkarımını iyileştirmek için Unet modeli geliştirildi. Modelin doğruluğunu artırmak için Efficient Channel Attention (ECBA) dikkat modülü ve ağırlıklı sınır kayıp fonksiyonu entegre edildi. ECBA, bina kenarlarını daha iyi belirleyerek eksik veya hatalı tespitleri azalttı. Ağırlıklı sınır kayıp fonksiyonu ise sınır bütünlüğünü koruyarak daha doğru segmentasyon sağladı. Deneyler, modelin önceki yöntemlere göre daha yüksek doğruluk ve hassasiyet sunduğunu gösterdi (Liu vd. 2025).

Binaların tespiti ve sınıflandırılmasına odaklanan uydu görüntülerinden oluşan veri kümesi sunulmuştur. Veri kümesi, Beijing ve Münih'teki kentsel alanları kapsamakta olup, binaların çatı tipi gibi geometrik özellikleri ve kullanım amacı gibi işlevsel özellikleri temel alınarak hem kaba hem de ayrıntılı sınıflandırma yapılabilir. Güncel nesne tespiti modelleriyle yapılan deneyler, yoğun kent dokusunda binaların tespitinin ve sınıflandırılmasının çeşitli zorluklar içerdiğini göstermektedir. Binaların farklı boyut, şekil ve dokulara sahip olması, çevresel ve kültürel faktörlerin etkisi ile birleşerek süreci karmaşık hâle getirmektedir. Bina işlevlerinin genellikle doğrudan görünümünden çıkarılamaması nedeniyle, ek coğrafi bilgiler gerekmektedir. İlk sürümde yalnızca RGB uydu görüntüleri kullanılmış olup, veri kümesinin kapsamının küresel ölçekte genişletilmesi, multispektral ve SAR görüntülerin eklenmesi, ayrıca çok zamanlı verilerle zenginleştirilmesi planlanmaktadır. Artan veri miktarıyla birlikte mevcut sınıfların ayrıştırılması ve yeni sınıfların eklenmesi de mümkündür (Huang vd. 2024)

Bina tespiti için özellik ayrıştırmaya dayalı bir Single Shot Detector (SSD) yöntemi önerilmiş ve mevcut yöntemlerin karmaşık sahne görüntülerinde yüksek yanlış alarm ve

eksik tespit sorunlarını giderme amacı güdülmüştür. Bu amaçla, giriş özelliklerini iki bileşene ayıran bir özellik ayrıştırma modülü geliştirilmiştir: hedef tespiti için avantajlı ayırmacı özellikler ve tespiti zorlaştıran girişim özellikleri. Girişim özellikleri, yanlış alarmlara neden olabilecek karmaşık arka plan öğelerini içerirken, ayırmacı özellikler ise ilgili hedef nesneleri barındırmaktadır. Nihai modelde, yalnızca ayırmacı özellikler kullanılarak çok ölçekli nesne tespiti gerçekleştirilmiştir. Önerilen özellik ayrıştırma modülü, belirli bir nesne tespit algoritmasına bağımlı olmayıp, SSD tabanlı tüm dedektörlerde uygulanabilmektedir. Gerçek veri seti üzerinde yapılan deneyler, yöntemin yanlış alarm oranlarını önemli ölçüde azalttığını ve karmaşık sahnelerde bina nesne tespit performansını artırdığını göstermektedir (Zheng ve Zhao 2024).



3. YAPAY ZEKA


İnsan gibi düşünen ve hareket eden sistemler tasarlama fikri, insanlığın yüzyıllardır ilgisini çeken bir konu olmuştur. Bu çabalar, terminolojik olarak “yapay zekâ” kavramının ortaya çıkmasından çok daha önce, tarih boyunca farklı şekillerde ele alınmıştır. Örneğin, Yunan mitolojisinde Daedalus, hem yetenekli bir heykeltıraş hem de mekanik sistemlere ilgi duyan bir zanaatkâr olarak tanımlanır. Daedalus’un yaptığı heykeller, gerçeğe yakınlıklarıyla bir tür “yapay insan” olarak değerlendirilmiştir. Bu durum, yapay zekâ terimi o dönemde kullanılmasa da, benzer bir arayışın tarih boyunca devam ettiğini göstermektedir (Piltan 2022).

Yapay zekâ, bilgisayarların veya bilgisayar kontrollü makinelerin insan benzeri görevleri yerine getirebilmesi olarak tanımlanmaktadır. İnsana özgü özellikler sergileyen yapay zekâ sistemleri, hızlı, doğru ve etkili kararlar verme yetenekleri sayesinde son yıllarda geniş bir kullanım alanı bulmuştur (Ersan 2024).

Makine zekâsının sınırlarını tartışmaya açan ve yapay bir zekânın varlığını sorgulayan isimlerin başında Alan Mathison Turing gelmektedir. Turing, 1950 yılında “Computing Machinery and Intelligence” başlıklı makalesiyle, bugün hala geçerliliğini koruyan “Turing Testi” kavramını ortaya koymuştur. Bu test, bir makinenin insan zekâsını taklit edebilme yeteneğini ölçmeyi amaçlamaktadır. Turing’in çalışmaları, makinelerin düşünebilir olmasına ilişkin felsefi ve mantıksal bir temel sunmuştur ve bu alandaki araştırmalar için önemli bir başlangıç noktası olmuştur (Piltan 2022).


Turing Testi, bir makinenin insan zekâsını taklit edebilme kapasitesini ölçmek amacıyla geliştirilmiş bir yöntemdir. Testte, bir değerlendirici (C) ve iki ikna edici oyuncu (A ve B) bulunmaktadır. Oyunculardan bir tanesi insan (B), diğeri ise insan gibi düşünen taklit eden bir cihazdır. (A). Analizci, yönlendirdiği sorulara yazılı olarak aldığı yanıtlar doğrultusunda hangi oyuncunun makine olduğunu belirleyemezse, makine değerlendiren kişiyi insan olduğuna inandırarak ve testi üstün performansla tamamlamış kabul edilir. Turing, bu test ile makinelerin düşünebilme yeteneğine ilişkin tartışmaları somut bir çerçevede ele almayı amaçlamıştır. O dönemde, makinelerin insan zekâsını taklit

edebileceği tezi geniş çapta tartışılrsa da, makine ve insan arasındaki beceri farklılıklarının bu yeteneği sınırlayacağı yönündeki görüşler yaygındı. Turing, insan ve makine arasındaki bu farklılıkları görünmez kılmayı hedefleyerek tezinin geçerliliğini ortaya koymaya çalışmıştır. Günümüzde yapay zekâ alanındaki çalışmalara ilham veren Turing, bu nedenle “yapay zekânın babası” olarak anılmaktadır (Piltan 2022).



Şekil 3.1 Turing testi ve oyuncular (İnt.Kyn.4).

Son yıllarda oldukça popüler hale gelen yapay zekâ, teknolojik gelişmelere paralel olarak pek çok alanda araştırmacıların ilgisini çekmiş ve özellikle disiplinler arası mühendislik problemlerinin çözümünde yaygın bir şekilde kullanılmaya başlanmıştır. Yapay zekâ kavramının kökleri oldukça eskiye dayanmakla birlikte, özellikle 1990’lı yıllarda bilişim teknolojilerindeki ilerlemelerle birlikte bu alana olan ilgi artmıştır (Gündüz 2023).



Şekil 3.2 Yapay zeka ve alt dalları (Piltan 2022).

2000’li yıllarda ise bilişim altyapısındaki gelişmeler ve bilgisayarların işlem kapasitelerinin artmasıyla birlikte yapay zekâ alanında somut ilerlemeler kaydedilmiştir.

Özellikle makine ve derin öğrenme yani deep learning kavramının alt kavramların zaman içinde gelişim sağlaması, bu teknolojilerin daha geniş veri setleri üzerinde uygulanabilir hale gelmesini sağlamıştır. Yapay zekâ ve alt dallarının ilişkisi, bu alandaki çalışmaların kapsamını ve etkileşimini daha net bir şekilde ortaya koymaktadır (Gündüz 2023).

3.1 Makine Öğrenmesi

Öğrenme, bireylerin deneyimlerden ya da talimatlardan bilgi, beceri ve anlayış kazanmalarını sağlayan bir süreç olarak tanımlanabilir. Makine öğrenmesi ise, bir bilgisayar programının insan müdahalesine ihtiyaç duymaksızın veri analizi yoluyla problemlere çözüm üretebilmesi amacıyla geliştirilen bir yöntemdir. Bu disiplin, istatistik, yapay zekâ ve bilgisayar biliminin kesişim noktasında yer almakta ve belirli bir matematiksel denklemden ziyade, öğrenme sürecini gerçekleştirmek için çeşitli algoritmalar ve modeller kullanmaktadır. Günümüz büyük veri çağında, makine öğrenmesi, çok sayıda veri ve değişken içeren problemlerin tanımlanması, analiz edilmesi ve çözümlenmesi noktasında kritik bir öneme sahiptir (Yasak 2021).

Makine öğrenmesi algoritmaları, klasik yapay zekâ sistemlerinden farklı olarak, programcı müdahalesine gerek kalmaksızın kendini geliştirir ve yeni kurallar oluşturur. Bu özellik, makine öğrenmesi sistemlerinin, geleneksel programlamadan çok "eğitilen sistemler" olarak görülmesini sağlamaktadır. Geleneksel programlama, belirli "eğer o zaman" kuralları doğrultusunda sonuç üretirken, makine öğrenmesi algoritmaları veri setlerini analiz ederek tahminlerde bulunur ve zaman içinde bu tahminlerini geliştirir (Khalaf 2021).

Makine öğrenmesi, özellikle büyük miktarda verinin bulunduğu bilgisayar bilimleri alanında önemli bir avantaj sağlamaktadır. Günümüzde makine öğrenmesi birçok alanda uygulanmaktadır; cep telefonu kameralarında görüntü algılama, sesli arama sistemleri ve görüntüden metne dönüştürme uygulamaları gibi. Bu süreçte makine öğrenmesi üç temel adımdan oluşmaktadır: veri girişi, tahmin edilen çıktı örnekleri ve gerçek çıktı ile tahmin edilen çıktının karşılaştırılması. Bu adımlar, algoritmanın doğruluğunu değerlendirme ve sistemin iyileştirilmesi için kritik bir rol oynamaktadır (Khalaf 2021).

3.1.1 Denetimli Öğrenme

Denetimli öğrenim, algoritmaların eğitim verileri kullanarak girdileri hedef çıktılara dönüştüren kuralları öğrenmesini amaçlar. Bu süreçte, kullanıcılar verileri etiketleyerek algoritmaların daha etkili çalışmasını sağlar. Verilerin doğru şekilde etiketlenmesi ve tüm olasılıkları kapsaması, modelin doğruluğunu artıran temel unsurlardandır. Örneğin, bir nesne tespit probleminde, insanların farklı fiziksel özelliklerini içeren kapsamlı ve etiketlenmiş bir veri seti, algoritmanın doğru tahminlerde bulunmasını sağlar. Veri etiketleme işlemi, uzmanlık gerektiren durumlarda alan uzmanları tarafından, diğer durumlarda ise herhangi bir kullanıcı tarafından yapılabilir. Ayrıca, açık veri kaynaklarının artışı sayesinde birçok projede önceden etiketlenmiş veri setlerinden yararlanılarak iş yükü azaltılmaktadır (Piltan 2022).


3.1.2 Denetimsiz Öğrenme

Denetimsiz öğrenim algoritmaları, etiketlenmiş veri olmaksızın çalışarak verileri benzerliklerine göre gruplara ayırır ve kümeleme işlemini gerçekleştirir. Bu algoritmalar, veri hakkında ön bilgiye sahip olunmadığında tercih edilmekle birlikte, sonuçların hedeflenen sınıfları içermemesi veya bazı verilerin temsil edilememesi gibi dezavantajlar barındırır. Ayrıca, algoritmalar verilerin "ne olduğu" yerine, "nelere benzediği veya farklı olduğu" bilgisini sunabilir. Buna karşın, denetimsiz öğrenme algoritmaları veri analizi, veri sıkıştırma, kümeleme, boyut indirgeme ve gürültü azaltma gibi birçok faydalı amaç için kullanılmaktadır. Özellikle, kullanıcı tarafından fark edilemeyen öznelilikleri açığa çıkarmada etkili bir rol oynarlar (Piltan 2022).

3.1.3 Yarı Denetimli Öğrenme

Yarı denetimli, denetimsiz ve denetimli öğrenim yöntemlerinin avantajlarını birleştiren bir yaklaşımdır. Etiketli veriye olan bağımlılığı azaltarak, sezgisel yöntemlerle etiket oluşturma süreci içerir. Bu alanda otokodlayıcılar, hem bilgi çıkarımı hem de boyut indirgeme için sıkça kullanılan bir derin öğrenme yöntemidir. Otokodlayıcılar, veriyi yeniden yapılandırmak üzere tasarlanmış sinir ağlarıdır ve girdi verisinin boyutunu

azaltarak önemli öznitelikleri öğrenir. Kodlayıcı kısmında veriler boyutları azaltılırken, kod çözücü kısmında bu veriler yeniden oluşturulur. Bu yöntem, yapay sinir ağlarıyla benzer bir prensipte çalışmakta olup görüntü tanıma, gürültü azaltma ve boyut indirgeme gibi uygulamalarda kullanılır (Piltan 2022).



Şekil 3.3 Bir otokodlayıcının yapısı (Piltan 2022).

3.1.4 Pekiştirmeli Öğrenme


Pekiştirmeli öğrenme, amaç odaklı çalışarak bir ajanın çevresiyle etkileşime girip doğru kararları öğrenmesini sağlayan bir makine öğrenme yöntemidir. Bu algoritmalar, ajanın eylemlerine ödül puanı vererek öğrenme sürecini teşvik eder. Ajan, ödül puanını maksimuma çıkarmak için çevresini keşfetmeye ve başarılı eylemleri tekrarlamaya devam eder. Deneme-yanılma temelli bu yöntem, öğrenme sürecini aşamalı olarak geliştirir ve makine öğrenmesinde önemli bir alan olarak öne çıkmaktadır (Piltan 2022).

3.2 Derin Öğrenme

Derin öğrenme, insan zekasının irdeleme, öğrenme ve karar alma süreçlerini taklit eden zaman içinde kendini geliştiren makine öğrenim yöntemidir. Büyük veri ve Graphics Processing Unit (GPU) teknolojilerindeki gelişmeler, derin öğrenmenin çeşitli alanlarda kullanımını artırmıştır. Bu teknik, denetimli veya denetimsiz şekilde özellik çıkarma ve sınıflandırma işlemlerini gerçekleştirirken, yapay sinir ağlarının özel bir türü olarak hiper

parametreler, aktivasyon fonksiyonları ve öğrenme algoritmaları gibi bileşenlerden yararlanır. Derin ağlar, her katmanın farklı işlevlerde yoğunlaşmasını sağlayarak yapay sinir ağlarından ayrılır. Derin öğrenme, kullanıcı tarafından belirlenmeden farklı katmanlarda veri özelliklerini keşfederek öğrenme yeteneği sunar (Karabulut 2022).

Geçmişte makineleri düşündürmek bir hayal olarak görülse de, teknoloji alanındaki sınırlamalar nedeniyle bu alanda ilerlemek zordu. Ancak yüksek hızlı Central Processing Unit (CPU) ve GPU'ların gelişimi, büyük veri kümelerinin oluşturulması ve algoritmaların iyileştirilmesiyle bu durum değişti. Günümüzde derin öğrenme, Facebook'un DeepFace teknolojisi, Google Asistan ve Haritalar gibi uygulamalarda etkin bir şekilde kullanılmaktadır. Yapay sinir ağları üzerine kurulu olan derin öğrenme, insan beynini modelleyerek giriş verilerini analiz eder ve anlamlı çıktılar üretir. Bu süreçte her bir katman belirli özellikleri tanımaktan sorumlu olup, katmanlar arasındaki ardışık öğrenme mekanizması ile küçük problemleri birleştirerek daha karmaşık sorunları çözebilir. Özellikle görüntü ve video işleme alanında sıkça kullanılan bu yaklaşım, veri setleriyle karşılaştırma yaparak yüksek doğrulukta sonuçlar üretmektedir (Khalaf 2021).



Şekil 3.4 Makine ve derin öğrenme algoritmalarının işleyişi

Bu yöntem, özellikle tıbbi görüntü analizi, cisim algılama ve segmentasyonu gibi alanlarda yaygın olarak kullanılan bir yöntemdir. Derin öğrenme, sınıflandırılacak


nesneler için belirgin özellikleri ve kombinasyonlarını geniş etiketli veri setleri üzerinden öğrenerek, hem eğitildiği nesneleri hem de benzer yapıya sahip yeni nesneleri tanıyabilen modeller geliştirebilmektedir. Bu sayede, döndürme, ölçeklendirme gibi zorluklara rağmen yüksek doğrulukta tanıma ve sınıflandırma yapılması mümkün hale gelmektedir (Çeçen 2023).

3.2.1 Derin Öğrenme Süreçleri

Bir derin öğrenme eğitim süreci, belirli aşamalarla ilerlemektedir. Öncelikle, girdi ve çıktı verileri tanımlanır ve uyumlulukları kontrol edilir. Ardından, hatalı veya uygun olmayan veriler ayıklanarak çıkarılır. Bu hazırlık aşamalarını takiben, uygulanacak derin öğrenme algoritması seçilir. Eğitim süreci başladıktan sonra, performans ölçütleri kullanılarak modelin başarısı değerlendirilir. Eğitim başarılı olduğunda süreç, uygulama aşamasına geçilerek tamamlanır (Karabulut 2022).

3.3 Nesne Tanıma Algoritmaları

Cisim tespiti ve takibinde geliştirilen algoritmalarından bahsederek R-CNN (Region Based Convolutional Neural Network), YOLO, SSD, Mask R-CNN, Fast R-CNN (Fast Region Based Convolutional Neural Network), Faster R-CNN'dir.




Şekil 3.5 Nesne tanıma yaklaşımları (Ersan 2024).

R-CNN, nesne tespiti için bölge önerileri oluşturup bu önerilere CNN uygular ve

sınıflandırma için Support Vector Machines kullanır. Daha hızlı bir versiyonu olan Fast R-CNN, bölge önerilerini oluşturmak için özellik haritası kullanırken, Faster R-CNN ise çalışma süresini kısaltmak için Region Proposal Network ekler. Mask R-CNN, Faster R-CNN üzerine geliştirilmiş olup cisim algılama sırasında piksel seviyesinde segmentasyon maskeleri oluşturur (Tan vd. 2021). SSD, tek bir derin sinir ağıyla tek aşamada nesne tespiti gerçekleştirir ve fazla düşük çözünürlüklü görüntülerle Faster R-CNN'nin doğruluk analizini eşleştirirken hız avantajı sağlar. YOLO algoritması ise nesne tespitini tek bir sinir ağıyla uçtan uca optimize ederek gerçek zamanlı tespit yapar ve yüksek hızıyla dikkat çeker (Tan vd. 2021). Bu algoritmaların her biri farklı yöntemler ve iyileştirmelerle nesne tespiti performansını artırmayı hedeflemektedir (Tan vd. 2021).

3.3.1 Mask R-CNN


Mask-RCNN, Faster R-CNN modelinin bir uzantısı olarak nesne tespiti ve piksel bazında hassas segmentasyonu birleştiren bir derin öğrenme modelidir. Modelin temel yeniliği, tespit edilen nesneler için ayrıntılı segmentasyon maskeleri üretebilen ek bir "maske başlığı" dalının eklenmesidir (İnt.Kyn.2). ROIAAlign (Region of Interest Align) ve FPN gibi geliştirmelerle modelin performansı artırılmıştır. ROIAAlign, mekansal doğruluğu artırarak segmentasyon sonuçlarını iyileştirirken, FPN farklı ölçeklerdeki özellikleri birleştirerek modelin nesneleri daha kapsamlı algılamasını sağlar. Bu özellikler, Mask R-CNN'in çeşitli nesne boyutlarında etkili bir tespit ve segmentasyon gerçekleştirmesine olanak tanır (İnt.Kyn.2).



Şekil 3.6 Mask-RCNN aşamalarının gösterimi (Yörük vd. 2023).

3.3.2 YOLO Algoritması

YOLO, yüksek performanslı ve derin öğrenmeye dayalı bir nesne algılama algoritmasıdır. Özellikle gerçek zamanlı görüntü işleme uygulamalarında kullanılmak üzere geliştirilmiştir. Algoritma, giriş görüntüsünü bir ızgara yapısına ayırarak her hücredeki nesneleri tahmin eder ve düşük olasılıklı sonuçları eleyerek en yüksek tahmin olasılığına sahip sınırlayıcı kutuları belirler. YOLO, hem sınıflandırma hem de algılama problemlerini çözmek için evrişimsel sinir ağlarını kullanarak nesnelerin yerlerini ve türlerini aynı anda algılayabilmektedir (Çelik ve Altınörs 2023).



Şekil 3.7 YOLO modeli (Nasrullah ve Diker 2021).

YOLO algoritması, Joseph Redmon vesilesiyle gerçek real time olarak cisim tespiti için 2015 yılında geliştirilmiştir. Tüm görüntüyü işleyerek nesneleri hızlı ve verimli bir şekilde algılar. Eğitimi sırasında bağlamsal bilgileri öğrenerek nesnelerin genelleştirilebilir temsillerini oluşturur ve bu sayede doğal görüntüler üzerinde diğer yöntemlere kıyasla üstün performans sergiler (Nasrullah ve Diker 2021).

$$\phi(x) = \begin{cases} x, & \text{eğer } x > 0 \text{ ise} \\ 0.1x, & \text{diğer durumlarda} \end{cases} \quad (3.1)$$

$$\lambda_{koordinat} \sum_{i=0}^{S^2} \sum_{j=0}^B 1_{ij}^{nesne} \left[(x_i - \hat{x}_j)^2 + (y_i - \hat{y}_j)^2 \right] \quad (3.2)$$


$$+ \lambda_{koord} \sum_{i=0}^{S^2} \sum_{j=0}^B 1_{ij}^{nesne} \left[(\sqrt{w_i} - \sqrt{\widehat{w}_j})^2 + (\sqrt{h_i} - \sqrt{\widehat{h}_j})^2 \right] \quad (3.3)$$

$$+ \sum_{i=0}^{S^2} \sum_{j=0}^B 1_{ij}^{nesne} (C_i - \widehat{C}_j)^2 \quad (3.4)$$

$$+ \lambda_{nesneyok} \sum_{i=0}^{S^2} \sum_{j=0}^B 1_{ij}^{nesneyok} (C_i - \widehat{C}_j)^2 \quad (3.5)$$

$$+ \sum_{i=0}^{S^2} 1_i^{nesne} \sum_{c \in \text{sınıflar}} (p_i(c) - \widehat{p}_i(c))^2 \quad (3.6)$$

Şekil 3.8’de bahsedilen; b_x : Cismin orta noktasının x koordinatı, b_y : Cismin orta noktasının y koordinatı, b_w : Cismin genişliği, b_h : Cismin yüksekliği Bir cismin sınıfına karşılık gelen c değeri ifade eder. Burada denklem’i analiz edersek skor modelin geçerli bölge içinde cisim bulunduğunu yada bulunmadığını işaretler.



Şekil 3.8 Sınırlayıcı kutu (Ersan 2024).

3.3.2.1 YOLOv8 Algoritması

YOLOv8, gelişmiş özellik çıkarma ve nesne algılama performansı sunan modern omurga ve boyun mimarileri ile tasarlanmıştır. Daha verimli ve doğru bir algılama süreci sağlamak amacıyla çapasız bölünmüş bir Ultralytics başlığı kullanarak çapa tabanlı yaklaşımlara kıyasla üstün performans göstermektedir. Model, hız ve doğruluk arasında en uygun seviyeleri test edilmiş ve güçlendirilmiş model sunarak çeşitli uygulamalarda gerçek vakitli cisim irdeleme görevleri için uygun hale getirilmiştir. Ayrıca, farklı görev ve performans gereksinimlerini karşılamak üzere çeşitli önceden eğitilmiş modeller sunarak kullanıcıların özel kullanım durumlarına uygun modeller seçmesini kolaylaştırmaktadır (İnt.Kyn.1). YOLO model ailesi, zaman içinde geliştirilmiş ve

YOLOv8, yüksek hız ve doğruluk sunan gelişmiş bir mimariye sahiptir. Omurga, giriş resminden çeşitli seviyelerde özellikler çıkaran önceden eğitilmiş bir CNN içerir. Boyun, farklı ölçeklerdeki özellik haritalarını iyileştirip birleştirir ve C2f, SPPF (Spatial Pyramid Pooling Fast) ile evrişim katmanlarından oluşur. Baş, nesnelerin sınırlayıcı kutu koordinatlarını, sınıfını ve güvenini tahmin eder. Çapasız tespit yaklaşımıyla, önceden belirlenmiş çapa kutularına dayanmadan nesnelerin merkez noktası ve boyutlarını doğrudan hesaplar. Bu yapılar, YOLOv8'in nesne tespiti görevlerinde hem doğruluk hem de verimlilik açısından üstün performans sergilemesini sağlamaktadır (Venkatesh ve Hashmi 2024). YOLOv8, Ultralytics tarafından geliştirilmiş, yüksek hız ve doğruluk sağlayan ileri nesne tespit algoritmalarından biridir. Önceki YOLO sürümlerine kıyasla daha geniş bir öznitelik haritası ve etkili evrişimsel ağlar kullanarak performansını artırmıştır. Çapasız tasarımı sayesinde nesne boyut ve konumlarını doğrudan tahmin ederken, C2f modülü ve yeni kayıp fonksiyonu ile tespit doğruluğunu optimize eder. FPN ve Path Aggregation Network mimarileri, çoklu ölçek ve çözünürlükte bilgi toplayarak farklı boyutlardaki nesnelerin tanınmasını kolaylaştırır. YOLOv8, nesne tespiti, sınıflandırma ve segmentasyon gibi görevler için kapsamlı bir çerçeve sunarken kullanıcı dostu bir API (Application Programming Interface) ve gelişmiş etiketleme araçlarıyla da dikkat çeker (Çelik 2024).


C2f modülü, YOLOv8'in omurga yapısının temel bileşenlerinden biri olup, önceki C3 modülünün yerini almıştır. C3 modülü, 3 evrişim katmanına sahip darboğaz modülü olarak işlev görürken, C2f modülü yalnızca 2 evrişim katmanı kullanır. Bu tasarım, modeli daha hızlı ve verimli hale getirir. Ayrıca, C2f modülü, küçük nesneleri ve diğer nesneler tarafından kısmen örtülmüş nesneleri tespitte önemli bir avantaj sağlamaktadır (Çelik 2024). YOLOv8 (n, s, m, l, x) olmak üzere beş çeşit algoritma vardır YOLOv8 için m modeli tercih edilmiştir.

3.3.2.2 YOLOv11 Algoritması

YOLOv11, daha doğru nesne algılama ve karmaşık görevlerin etkin şekilde gerçekleştirilmesini sağlayan geliştirilmiş bir omurga ve boyun mimarisine sahiptir. Rafine edilmiş mimari tasarımlar ve optimize edilmiş eğitim süreçleri sayesinde model,

daha yüksek işlem hızları sunarken doğruluk ile performans arasında dengeli bir çözüm sunmaktadır (İnt.Kyn.1).

Model tasarımındaki iyileştirmelerle YOLOv11m, COCO (Common Objects in Context) veri kümesinde daha yüksek bir mAP (Mean Average Precision) elde ederken, YOLOv8m ile karşılaştırıldığında %22 daha az parametre kullanarak daha hesaplama verimli bir yapı sunmaktadır. Uç cihazlar, bulut platformları ve NVIDIA GPU'ları gibi farklı sistemlerle uyumlu yapısı, modelin çeşitli ortamlarda esnek bir şekilde dağıtılmasını mümkün kılmaktadır (İnt.Kyn.1).



Şekil 3.9 Coco veri seti mAP grafiği (İnt.Kyn.1).

YOLOv11 mimarisi, işlem hızını artırmak ve performansı korumak amacıyla C2f modülünü, iki daha küçük evrişim katmanı içeren özel bir dar boğaz katmanı olan C3K2 modülüyle değiştirmiştir. YOLOv8'den SPPF modülü korunurken, çok başlı dikkat mekanizmalarıyla kanal ve uzamsal bilgileri entegre eden C2PSA (Cross-Stage Partial Architecture) modülü tanıtılmış, özellik çıkarma verimliliği artırılmıştır. Uyarlanabilir çapa kutusu mekanizması, farklı veri kümeleri arasında, daha iyi yapılandırmalar sunmak için rafine edilerek tespit doğruluğu iyileştirilmiştir (He vd. 2024).

YOLOv11 nesne tespit yöntemi, performansını, birden fazla bileşeni içeren kapsamlı bir kayıp fonksiyonunu en aza indirerek artırır. Bu kayıp fonksiyonu, sınıf olasılığı kaybı, sınırlayıcı kutu regresyon kaybı ve dağıtılmış odak kaybı gibi bileşenleri içerir.

Optimizasyon süreci, bu kayıpların birleştirilmesini ve gelişmiş algoritmalar kullanılarak modelin nesne tespit performansını iyileştirmeyi hedefler (He vd. 2024).

YOLOv11 modeli, üç ana bileşenden oluşur: Omurga, Boyun ve Başlık. Omurga, giriş görüntülerinden çoklu ölçekli özellik haritaları çıkarır; Boyun, bu haritaları birleştirerek daha güçlü temsiller oluşturur; Başlık ise nesne sınırlayıcı kutuları ve kategori etiketlerini tahmin eder. Bu mimari, çok ölçekli nesne tespitinde yüksek doğruluk ve etkinlik sağlar (He vd. 2024).

Omurga (Backbone), YOLO'nun omurga bileşeni, giriş görüntüsünü çok ölçekli özellik haritalarına dönüştürmek için evrişimli sinir ağlarını kullanır. YOLOv11'de omurgada yapılan yenilikler arasında, önceki modellerde kullanılan C2f bloklarının yerine, hesaplama açısından daha verimli olan C3k2 bloklarının getirilmesi yer alır. Ayrıca SPPF bloğu korunurken, C2PSA bloğu eklenmiştir. Bu dikkat mekanizması, modelin görüntüdeki kritik bölgelere daha etkili bir şekilde odaklanmasını sağlamaktadır (Khanam ve Hussain 2024).

Boyun (Neck) kısmı, farklı ölçeklerdeki özellik haritalarını birleştirerek tahmin için başa iletir. YOLOv11, burada C2f bloğunun yerine C3k2 bloklarını kullanarak işlem verimliliğini artırmıştır. Ayrıca, C2PSA modülü aracılığıyla modelin küçük ve kısmen gizlenmiş nesneleri daha doğru şekilde tespit etmesine olanak tanıyan bir dikkat mekanizması da bu kısımda entegre edilmiştir (Khanam ve Hussain 2024).

Baş (Head), YOLO'nun baş kısmı, nesne yerelleştirme ve sınıflandırma tahminlerini gerçekleştiren bölümdür. YOLOv11'de baş kısmında çoklu C3k2 blokları kullanılarak özellik haritalarının daha verimli işlenmesi sağlanmıştır. CBS (Convolution-BatchNorm-SiLU) katmanları, C3k2 bloklarından sonra yer almakta ve verileri normalleştirip optimize ederek model performansını artırmaktadır. Son olarak, Detect katmanı, nesnelerin sınır kutusu koordinatlarını, obje skorlarını ve sınıf tahminlerini birleştiren nihai çıktıyı oluşturmaktadır (Khanam ve Hussain 2024).

YOLOv11, önceki sürümlere kıyasla omurga, boyun ve baş bölümlerinde gerçekleştirilen

mimari yenilikler ve parametre optimizasyonlarıyla üstün tespit performansı elde etmiştir. Özellikle C3k2 bloklarının kullanımı ve C2PSA gibi dikkat mekanizmalarının entegrasyonu, modelin hızını artırırken doğruluğunu da geliştiren temel unsurlar arasında yer almaktadır (Khanam ve Hussain 2024).



4. MATERYAL VE METOT

4.1 Çalışma Alanları


Bu çalışmada farklı veri kaynakları ile elde edilen görüntüler yardımıyla 2 çalışma alanında uygulama yapılmıştır. Çalışma alanı 1’de Harita Genel Müdürlüğünden (HGM) temin edilen Aydın/Nazilli ilçesinin 2022 yılı 30 cm konumsal çözünürlüklü ortofotosu kullanılmıştır (Resim4.1). Çalışma alanında 224 adet bina bulunmaktadır. Çalışma alanı 2’de Openmaxar’dan temin edilen Adana ili 2022 yılı 1.24 m konumsal çözünürlüklü WorldView 03 uydu görüntüsü kullanılmıştır (Resim4.2). Çalışma alanında 549 adet bina bulunmaktadır. DigitalGlobe tarafından geliştirilen WorldView-3 (WV03), yüksek çözünürlüklü görüntüleme kapasitesine sahip yeni nesil ticari bir uydu olarak 2014 yılında fırlatılmıştır. Uydu, 31 cm pankromatik, 1.24 m çok bantlı, 3.7 m SWIR (Short Wave Infrared) ve 30 m CAVIS (Clouds, Aerosols, Vapor, Ice, and Snow) çözünürlüğü sunmaktadır. CAVIS sistemi, atmosferik engelleri düzelterek görüntü kalitesini artırmaktadır (İnt.Kyn.3). Ortofoto, hava araçlarıyla elde edilen yeryüzüne ait üç boyutlu koordinat (X, Y, Z) bilgisini içeren hava fotoğraflarının, sensör eğikliği ve arazi yüksekliği gibi unsurlardan kaynaklanan geometrik hatalarının düzeltilmesiyle oluşturulan görüntülerdir. Bu görüntüler, belirli fotogrametrik ve jeodezik hesaplamalar sonucunda, ham hava fotoğraflarının işlenmesiyle üretilir. Ortofoto üretim sürecinde, fotoğrafın tamamı yerine daha küçük bölümler halinde düzeltme işlemi uygulanarak, arazi yükseklik farklılıklarından kaynaklanan hatalar giderilir. Bu işlemin sağlıklı bir şekilde gerçekleştirilebilmesi için araziye ait yükseklik verilerine ihtiyaç duyulmaktadır (Yavuz 2024).

4.2 Veri Seti

Veri artırımı, derin öğrenme modellerinin daha genel ve kararlı hale gelmesini sağlamak için mevcut veri kümesindeki örneklerin çeşitli dönüşümlerle çoğaltılması işlemidir. Bu yöntem, modelin aşırı öğrenmesini engelleyerek farklı varyasyonlara karşı daha iyi genelleme yapmasına yardımcı olur ve özellikle sınırlı veri setlerinde performansı önemli ölçüde artırır.



Resim 4.1 Çalışma alanı 1



Resim 4.2 Çalışma alanı 2




Şekil 4.1 Veri setinden örnek görüntüler

Görüntü işlemede döndürme, ölçekleme ve parlaklık değişiklikleri gibi tekniklerle uygulanarak modelin daha geniş bir örneklemele eğitilmesi sağlanır (İnt.Kyn.6). Veri seti olarak kullanılacak bina görüntülerine veri artırımı işlemi uygulanmıştır. Bu verilerin eğitim işleminde yeterli sayısına ulaşılabilmesi için aşağıdaki işlem adımlarından geçmiştir. Görüntüleri yatay çevirme, döndürme, ölçekleme, parlaklık değişimi, gürültü ekleme bu işlemler uygulanarak veri seti artırılmıştır. Eğitim aşamasında ve etiketleme aşamasında kullanılacak görüntüler 640x640 piksellere dönüştürülmüştür. Bu işlemler de python koduyla yapılmıştır.

4.3 Verinin Etiketlenmesi

MakeSense AI, YOLO gibi derin öğrenme tabanlı nesne tespiti modelleri için veri etiketleme sürecini kolaylaştıran açık kaynaklı bir araçtır. Tarayıcı tabanlı yapısı sayesinde kullanıcılar, nesne tespiti için görüntüleri hızlıca etiketleyerek YOLO formatında eğitim verisi oluşturabilirler. Bu sayede, modelin doğruluğunu artıran yüksek kaliteli veri setleri üretmek mümkün hale gelir (İnt.Kyn.5). Çalışmada, 746 görüntüden oluşan eğitim veri setinin YOLO formatına uygun şekilde etiketlenmesi için ücretsiz bir çevrimiçi yazılım olan MakeSenseAI tercih edilmiştir.



Şekil 4.2 MakeSenseAI Arayüzü

4.4 Değerlendirme Kriterleri

Değerlendirme metrikleri, bir modelin başarımını objektif bir şekilde ölçmek ve karşılaştırmak için kullanılan önemli araçlardır. Nesne tespit algoritmalarında başarımlar genellikle mAP ölçütü ile ifade edilir. mAP, modelin doğruluğunu belirlemek için karışıklık matrisi (confusion matrix), duyarlılık (recall), kesinlik (precision) ve kesiştirilmiş bölgeler IoU gibi ölçütlerden yararlanılarak hesaplanır. Elde edilen mAP değeri, 0 ile 1 arasında bir aralıkta ifade edilir ve değerin 1'e yakın olması, modelin daha başarılı olduğunu gösterir (Yıldırım 2023).

Karışıklık Matrisi, modelin tahmin performansını görselleştirmek için kullanılan ve iki sınıflı sınıflandırma problemlerinde yaygın olarak başvurulmuş bir araçtır. Karışıklık matrisi, sınıflandırma modellerinin performansını değerlendirmek için kullanılan bir araçtır ve True Positive (TP), True Negative (TN), False Positive (FP) ve False Negative (FN) gibi değerleri içerir dört ana bileşenden oluşur. Bu bileşenler, modelin hedef sınıfları doğru veya yanlış sınıflandırma durumlarını temsil eder. Bu matrisin çıktılarından faydalanılarak duyarlılık ve kesinlik hesaplamaları gerçekleştirilir (Yıldırım 2023).

Doğru Pozitif, modelin nesne varlığını tespit edip doğru bir tahminde bulunmasıdır. Doğru Negatif, modelin nesne bulunmadığını doğru bir şekilde tespit etmesidir. Yanlış Pozitif, nesne olmadığı halde modelin yanlış bir şekilde nesne tespitinde bulunmasıdır. Yanlış Negatif, nesne var olduğu halde modelin bu nesneyi tespit edememesi durumudur.

		GERÇEK	
		Pozitif	Negatif
TAHMİN	Negatif Pozitif	TP	FP
	Negatif Negatif	FN	TN

Şekil 4.3 Karışıklık matrisi gösterimi (Yıldırım 2023).

Duyarlılık, doğru pozitif tahmin sonuçlarının, doğru pozitif ve yanlış negatif tahmin sonuçlarına oranıdır. Modelin pozitif hedefleri ne kadar iyi yakaladığını ölçer.

$$Duyarlılık = \frac{TP}{(TP+FN)} \quad (4.1)$$

Kesinlik, doğru pozitif tahmin sonuçlarının, bütün pozitif tahmin sonuçlarına oranıdır. Modelin pozitif sınıflandırmalarındaki doğruluk oranını gösterir.

$$Kesinlik = \frac{TP}{(TP+FP)} \quad (4.2)$$

Kesiştirilmiş Bölgeler IoU, etiketlenmiş sınır kutusuyla modelin tahmin ettiği sınır kutusunun örtüşme oranını ifade eder. Bu çalışmalarda IoU değeri genellikle 0.5 olarak alınır. IoU değeri 0.5'in altında olan tahminler, yanlış pozitif olarak değerlendirilir ve bu eşik değeri üzerinden karışıklık matrisi, duyarlılık ve kesinlik hesaplamaları yapılır (Yıldırım 2023).

mAP Ölçütü sonuçları, veri içindeki her bir sınıf için AP değerleri hesaplanarak hesaplanan sonuçların ortalaması alınır. AP hesaplaması, kesinlik-duyarlılık grafiğinin altındaki alanın hesaplanmasıyla gerçekleştirilir. IoU eşik değeri 0.5 olarak alındığında, bu ölçüt mAP50 olarak adlandırılır ve nesne tespit çalışmalarında yaygın bir şekilde kullanılır. Modelin genel performansını nesne tespiti açısından değerlendirmek için etkili bir metriktir (Yıldırım 2023).

$$F_1 = 2 \times \frac{Pr \times Re}{Pr + Re} \quad (4.3)$$


$$AP = \int_0^1 Pr(Re) . dPr \quad (4.4)$$

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i \quad (4.5)$$


5. UYGULAMA

Çalışma kapsamında öncelikle verilerin toplanması, ön işlenmesi ve etiketlenmesi sağlanmıştır. Daha sonra, hazırlanan veriler kullanılarak YOLO tabanlı ve Mask-RCNN derin öğrenme modelleri eğitilmiş ve test edilmiştir. Modellerin doğruluk analizi yapılarak performansı değerlendirilmiştir.

Çalışmanın YOLO ve MASK-RCNN algoritması akış diyagramı sırasıyla şekil 5.1’de ve şekil 5.2’de gösterilmektedir.



Şekil 5.1 Çalışmanın YOLO algoritması akış diyagramı



Şekil 5.2 Çalışmanın MASK-RCNN algoritması akış diyagramı

5.1 Çalışma Alanı 1 Bina Tespit Modelleri ve Doğruluk Analizleri


5.1.1 Çalışma Alanı 1 YOLOv8 Bina Tespit Modeli

Bu bölümde eğitim veri seti hazırlandıktan sonra bulut depolama hizmetine yükleme yapılmıştır. YOLOv8m modeli seçilmiştir. Eğitim için Google Colab ortamında T4 GPU


kullanılarak Ultralytics'ten kodlardan yararlanarak eğitim işlemi ve test işlemleri gerçekleştirilmiştir. Model için eğitimlerde epoch sayısı 200, parti boyutu 8 seçilmiştir.

5.1.2 Çalışma Alanı 1 YoloV8 Doğruluk Analizi


Şekil 5.3'de Precision, Şekil 5.4'de Recall eğrileri yer almaktadır. Precision ve Recall değerleri 0 ile 1 arasında değişir. Bu değerlerin 1'e yaklaşması, modelin performansının arttığını gösterir. Recall, aynı zamanda doğruluk oranı olarak da bilinmektedir.



Şekil 5.3 Çalışma alanı 1 YOLOv8 modelinin kesinlik eğrisi




Şekil 5.4 Çalışma alanı 1 YOLOv8 modelinin duyarlılık eğrisi




Şekil 5.5 Çalışma alanı 1 YOLOv8 modelinin kesinlik – duyarlılık eğrisi

Şekil 5.5’de Precision-Recall eğrisi yer almaktadır. Bu eğride bina için 0.871 mAP değeri olarak ifade edilmiştir. Burada mAP (0.5), AP hesaplanırken güven eşliğinin Intersection over Union 0.5 değerinden büyük olması demektir. Eğer $IoU \geq 0.5$ ise tahmin doğrudur.



Şekil 5.6 Çalışma alanı 1 YOLOv8 performans grafikleri

YOLOv8m modeli çalışmanın sonuçları, eğitim sırasında kaybın azaldığını göstermektedir. Şekil 5.6'da ifade edilen sol üç grafik eğitim kayıp fonksiyonlarını, sol alt köşedeki üç grafik ise doğrulama kayıp fonksiyonlarını temsil etmektedir. Grafik analizlerine göre, eğitim kaybının zamanla azaldığı ve mAP metrik değerinin bire doğru yükseldiği gözlemlenmiştir. Bu durum, aşırı tespit gerçekleştiğinde daha büyük modellerin daha sık elde edilebileceğini göstermektedir. Ayrıca, Precision ve Recall grafiklerinde de modelin doğruluğunda artış kaydedilmiştir. Eğitim sürecinin sonunda, precision 0.972 ve recall 0.783, F1 0.867 olarak elde edilmiştir. Precision, Recall ve F1 skoru modelin genel performansı hakkında önemli bilgiler sunmaktadır.



Şekil 5.7 Çalışma alanı 1 YOLOv8 karışıklık matrisi

Şekil 5.7'de ifade edilen çalışma alanı veri 1 için karışıklık matrisi değerleridir. 136, 4, 39 sayıları sırasıyla TP, FP, FN değerlerini ifade eder. Çizelge 5.1'de YOLOv8m modelinin eğitimi sonrası elde edilen performansları verilmiştir.

Çizelge 5.1 Çalışma alanı 1 YOLOv8m modelinin 200. epokta değerleri

Model	mAP50	mAP50-95	Precision (Pr)	Recall (Re)	F1 Score	Eğitim Süresi (Saat)
YOLOv8m	0.871	0.732	0.972	0.783	0.867	1.782

YOLOv8m algoritmasıyla test edilen HGM ortofotosunda 224 bina içinden 136 doğru pozitif bina etiketleyerek %60.71 başarı oranı elde edilmiştir.




Şekil 5.8 Çalışma alanı 1 YOLOv8 bina tespiti

5.1.3 Çalışma Alanı 1 YOLOv11 Bina Tespit Modeli


Bu bölümde eğitim veri seti hazırlandıktan sonra bulut depolama hizmetine yükleme yapılmıştır. YOLOv11m modeli seçilmiştir. Eğitim için Google Colab ortamında T4 GPU kullanılarak Ultralytics'ten kodlardan yararlanarak eğitim işlemi ve test işlemleri gerçekleştirilmiştir. Model için eğitimde epoch sayısı 200, parti boyutu 8 seçilmiştir.

5.1.4 Çalışma Alanı 1 YOLOv11 Doğruluk Analizi


Şekil 5.9'da Precision, Şekil 5.10'da Recall eğrileri yer almaktadır. Precision ve Recall değerleri 0 ile 1 arasında değişir. Bu değerlerin 1'e yaklaşması, modelin performansının arttığını gösterir. Recall, aynı zamanda doğruluk oranı olarak da bilinmektedir.



Şekil 5.9 Çalışma alanı 1 YOLOv11 modelinin kesinlik eğrisi




Şekil 5.10 Çalışma alanı 1 modelinin duyarlılık eğrisi



Şekil 5.11 Çalışma alanı 1 YOLOv11 modelinin kesinlik – duyarlılık eğrisi


Şekil 5.11’de Precision-Recall eğrisi yer almaktadır. Bu eğride bina için 0.887 mAP değeri olarak ifade edilmiştir. Burada mAP (0.5), AP hesaplanırken güven eşliğinin Intersection over Union 0.5 değerinden büyük olması demektir. Eğer $IoU \geq 0.5$ ise tahmin doğrudur.



Şekil 5.12 Çalışma alanı 1 YOLOv11 performans grafikleri

YOLOv11m modeli çalışmanın sonuçları, eğitim sırasında kaybın azaldığını göstermektedir. Şekil 5.12’de ifade edilen sol üç grafik eğitim kayıp fonksiyonlarını, sol alt köşedeki üç grafik ise doğrulama kayıp fonksiyonlarını temsil etmektedir. Grafik analizlerine göre, eğitim kaybının zamanla azaldığı ve mAP metrik değerinin bire doğru yükseldiği gözlemlenmiştir. Bu durum, aşırı tespit gerçekleştiğinde daha büyük modellerin daha sık elde edilebileceğini göstermektedir. Ayrıca, Precision ve Recall grafiklerinde de modelin doğruluğunda artış kaydedilmiştir. Eğitim sürecinin sonunda precision 0.949 ve recall 0.811, F1 değeri 0.875 olarak elde edilmiştir. Precision, Recall ve F1 skoru modelin genel performansı hakkında önemli bilgiler sunmaktadır.

Şekil 5.13’de ifade edilen çalışma alanı veri 1 için karışıklık matrisi değerleridir. 137, 4, 38 sayıları sırasıyla TP, FP, FN değerlerini ifade eder. Çizelge 5.2’de YOLOv8m ve YOLOv11m modelinin eğitimi sonrası elde edilen performansları verilmiştir.



Şekil 5.13 Çalışma alanı 1 YOLOv11 karışıklık matrisi

Çizelge 5.2 Çalışma alanı 1 YOLO modellerinin 200. epokta değerleri

Model	mAP50	mAP50-95	Precision (Pr)	Recall (Re)	F1 Score	Eğitim Süresi (Saat)
YOLOv8m	0.871	0.732	0.972	0.783	0.867	1.782
YOLOv11m	0.878	0.683	0.949	0.811	0.875	1.894

YOLOv11m algoritmasıyla test edilen HGM ortofotosunda 224 bina içinden 137 doğru pozitif bina etiketleyerek %61.16 başarı oranı elde edilmiştir (Şekil 5.14).

5.1.5 Çalışma Alanı 1 Mask-RCNN Bina Tespit Modeli

Bu bölümde çalışma alanı verisi ArcGIS Pro uygulamasına yüklenmiştir. Eğitim için manuel olarak bina etiketleme işlemi yapıp etiketler rcnn masks formatında kaydedilmiştir. Etiketlenen binalara göre Mask-RCNN algoritmasıyla model dosyası oluşturulmuştur. Model dosyası oluşturulduktan sonra bina tespiti işlemi yapılmıştır. Doğruluk analizi için çalışma alanındaki binalar gerçek bina etiket özellikleri olarak

etiketlenmiştir ve doğruluk analizi gerçekleştirilmiştir. Mask R-CNN omurgası olarak ResNet-50 ağı ve 200 epok 8 batch seçilmiştir.



Şekil 5.14 Çalışma alanı 1 YOLOv11 bina tespiti

5.1.6 Çalışma Alanı 1 Mask-RCNN Doğruluk Analizi

Şekil 5.15’de ifade edilen çalışma alanı veri 1 için karışıklık matrisi değerleridir. 166, 626, 58 sayıları sırasıyla TP, FP, FN değerlerini ifade eder.


True Positive	False Positive	False Negative
166,0000	626,0000	58,0000

Şekil 5.15 Çalışma alanı 1 Mask-RCNN karışıklık matrisi

Çizelge 5.3 Çalışma alanı 1 IoU değerine göre sonuçları

Model	IoU	AP	Precision (Pr)	Recall (Re)	F1 Score
Mask RCNN	0.5	0.649	0.210	0.741	0.327

Çizelge 5.3’de ifade edilen Mask-RCNN algoritmasıyla test edilen HGM ortofotosu IoU: 0.5 mAP50 değerine göre seçildiğinde precision, recall, F1 değerleri sırasıyla 0.210, 0.741, 0.327 değeri elde edilmiştir.



Şekil 5.16 Çalışma alanı 1 gerçek bina etiket özellikleri ve bina tespiti

IoU: 0.5 değerine göre 224 bina içinden 166 doğru pozitif bina etiketleyerek %74.11 başarı oranı elde edilmiştir.


5.2 Çalışma Alanı 2 Bina Tespit Modelleri ve Doğruluk Analizleri

5.2.1 Çalışma Alanı 2 YOLOv8 Bina Tespit Modeli


Bu bölümde eğitim veri seti hazırlandıktan sonra bulut depolama hizmetine yükleme yapılmıştır. YOLOv8m modeli seçilmiştir. Eğitim için Google Colab ortamında T4 GPU kullanılarak Ultralytics’ten kodlardan yararlanarak eğitim işlemi ve test işlemleri gerçekleştirilmiştir. Model için eğitimlerde epoch sayısı 200, parti boyutu 8 seçilmiştir.

5.2.2 Çalışma Alanı 2 YOLOv8 Doğruluk Analizi


Şekil 5.17’de Precision, Şekil 5.18’de Recall eğrileri yer almaktadır. Precision ve Recall değerleri 0 ile 1 arasında değişir. Bu değerlerin 1’e yaklaşması, modelin performansının arttığını gösterir. Recall, aynı zamanda doğruluk oranı olarak da bilinmektedir.



Şekil 5.17 Çalışma alanı 2 YOLOv8 modelinin kesinlik eğrisi




Şekil 5.18 Çalışma alanı 2 YOLOv8 modelinin duyarlılık eğrisi




Şekil 5.19 Çalışma alanı 2 YOLOv8 modelinin kesinlik – duyarlılık eğrisi

Şekil 5.19’da Precision-Recall eğrisi yer almaktadır. Bu eğride bina için 0.968 mAP değeri olarak ifade edilmiştir. Burada mAP (0.5), AP hesaplanırken güven eşiğinin Intersection over Union 0.5 değerinden büyük olması demektir. Eğer $IoU \geq 0.5$ ise tahmin doğrudur.



Şekil 5.20 Çalışma alanı 2 YOLOv8 performans grafikleri

YOLOv8m modeli çalışmanın sonuçları, eğitim sırasında kaybın azaldığını göstermektedir. Şekil 5.20’de ifade edilen sol üç grafik eğitim kayıp fonksiyonlarını, sol alt köşedeki üç grafik ise doğrulama kayıp fonksiyonlarını temsil etmektedir. Grafik analizlerine göre, eğitim kaybının zamanla azaldığı ve mAP metrik değerinin bire doğru yükseldiği gözlemlenmiştir. Bu durum, aşırı tespit gerçekleştiğinde daha büyük modellerin daha sık elde edilebileceğini göstermektedir. Ayrıca, Precision ve Recall grafiklerinde de modelin doğruluğunda artış kaydedilmiştir. Eğitim sürecinin sonunda, precision 0.985, recall 0.900 ve F1 değeri 0.941 olarak elde edilmiştir. Precision, Recall ve F1 skoru modelin genel performansı hakkında önemli bilgiler sunmaktadır.



Şekil 5.21 Çalışma alanı 2 YOLOv8 karışıklık matrisi

Şekil 5.21’de ifade edilen çalışma alanı veri 2 için karışıklık matrisi değerleridir. 385, 15, 33 sayıları sırasıyla TP, FP, FN değerlerini ifade eder.

Çizelge 5.4’de YOLOv8m modelinin eğitimi sonrası elde edilen performansları verilmiştir.

Çizelge 5.4 Çalışma alanı 2 YOLOv8m 200. epokta değerleri

Model	mAP50	mAP50-95	Precision (Pr)	Recall (Re)	F1 Score	Eğitim Süresi (Saat)
YOLOv8m	0.967	0.771	0.985	0.900	0.941	1.754



Şekil 5.22 Çalışma alanı 2 YOLOv8 bina tespiti


YOLOv8m algoritmasıyla test edilen WV03 uydu görüntüsünde 549 bina içinden 385 doğru pozitif bina etiketleyerek %70,13 başarı oranı elde edilmiştir.

5.2.3 Çalışma Alanı 2 YOLOv11 Bina Tespit Modeli


Bu bölümde eğitim veri seti hazırlandıktan sonra bulut depolama hizmetine yükleme yapılmıştır. YOLOv11m modeli seçilmiştir. Eğitim için Google Colab ortamında T4 GPU kullanılarak Ultralytics'ten kodlardan yararlanarak eğitim işlemi ve test işlemleri gerçekleştirilmiştir. Model için eğitimde epoch sayısı 200, parti boyutu 8 seçilmiştir.

5.2.4 Çalışma Alanı 2 YOLOv11 Doğruluk Analizi


Şekil 5.23'de Precision, Şekil 5.24'de Recall eğrileri yer almaktadır. Precision ve Recall değerleri 0 ile 1 arasında değişir. Bu değerlerin 1'e yaklaşması, modelin performansının arttığını gösterir. Recall, aynı zamanda doğruluk oranı olarak da bilinmektedir.



Şekil 5.23 Çalışma alanı 2 YOLOv11 modelinin kesinlik eğrisi




Şekil 5.24 Çalışma alanı 2 YOLOv11 modelinin duyarlılık eğrisi



Şekil 5.25 Çalışma alanı 2 YOLOv11 modelinin kesinlik – duyarlılık eğrisi


Şekil 5.25’de Precision-Recall eğrisi yer almaktadır. Bu eğride bina için 0.964 mAP değeri olarak ifade edilmiştir. Burada mAP (0.5), AP hesaplanırken güven eşliğinin Intersection over Union 0.5 değerinden büyük olması demektir. Eğer $IoU \geq 0.5$ ise tahmin doğrudur.



Şekil 5.26 Çalışma alanı 2 YOLOv11 performans grafikleri

YOLOv11m modeli çalışmanın sonuçları, eğitim sırasında kaybın azaldığını göstermektedir. Şekil 5.26’da ifade edilen sol üç grafik eğitim kayıp fonksiyonlarını, sol alt köşedeki üç grafik ise doğrulama kayıp fonksiyonlarını temsil etmektedir. Grafik analizlerine göre, eğitim kaybının zamanla azaldığı ve mAP metrik değerinin bire doğru yükseldiği gözlemlenmiştir. Bu durum, aşırı tespit gerçekleştiğinde daha büyük modellerin daha sık elde edilebileceğini göstermektedir. Ayrıca, Precision ve Recall grafiklerinde de modelin doğruluğunda artış kaydedilmiştir. Eğitim sürecinin sonunda, precision 0.934, recall 0.919 ve F1 değeri 0.926 olarak elde edilmiştir. Precision, Recall ve F1 skoru modelin genel performansı hakkında önemli bilgiler sunmaktadır.

Şekil 5.27’de ifade edilen çalışma alanı veri 2 için karışıklık matrisi değerleridir. 389, 31, 29 sayıları sırasıyla TP, FP, FN değerlerini ifade eder. Çizelge 5.5’de YOLOv8m ve YOLOv11m modelinin eğitimi sonrası elde edilen performansları verilmiştir.



Şekil 5.27 Çalışma alanı 2 YOLOv11 karışıklık matrisi

Çizelge 5.5 Çalışma alanı 2 YOLOv8, YOLOv11 200. epokta değerleri

Model	mAP50	mAP50-95	Precision (Pr)	Recall (Re)	F1 Score	Eğitim Süresi (Saat)
YOLOv8m	0.967	0.771	0.985	0.900	0.941	1.754
YOLOv11m	0.964	0.681	0.934	0.919	0.926	1.927



Şekil 5.28 Çalışma alanı 2 YOLOv11 bina tespiti

YOLOv11m algoritmasıyla test edilen WV03 uydu görüntüsünde 549 bina içinden 389 doğru pozitif bina etiketleyerek %70.86 başarı oranı elde edilmiştir.

5.2.5 Çalışma Alanı 2 Mask-RCNN Bina Tespit Modeli

Bu bölümde çalışma alanı verisi ArcGIS Pro uygulamasına yüklenmiştir. Eğitim için manuel olarak bina etiketleme işlemi yapıp etiketler rcnn masks formatında kaydedilmiştir. Etiketlenen binalara göre Mask-Rcnn algoritmasıyla model dosyası oluşturulmuştur. Model dosyası oluşturulduktan sonra bina tespiti işlemi yapılmıştır. Doğruluk analizi için çalışma alanındaki binalar gerçek bina etiket özellikleri olarak etiketlenmiştir ve doğruluk analizi gerçekleştirilmiştir. Mask R-CNN omurgası olarak ResNet-50 ağı ve 200 epok 8 batch seçilmiştir.

5.2.6 Çalışma Alanı 2 Mask-RCNN Doğruluk Analizi

Şekil 5.29'da ifade edilen çalışma alanı veri 2 için karışıklık matrisi değerleridir. 371, 2007, 180 sayıları sırasıyla TP, FP, FN değerlerini ifade eder.

True Positive	False Positive	False Negative
371,0000	2007,0000	180,0000

Şekil 5.29 Çalışma alanı 2 Mask-RCNN karışıklık matrisi

Çizelge 5.6 Çalışma alanı 2 IoU değerine göre sonuçları

Model	IoU	AP	Precision (Pr)	Recall (Re)	F1 Score
Mask RCNN	0.5	0.517	0.156	0.673	0.253

Çizelge 5.6'da ifade edilen Mask R-CNN algoritmasıyla test edilen WV03 uydu görüntüsü IoU: 0.5 mAP50 değerine göre seçildiğinde precision, recall, F1 değerleri sırasıyla 0.156, 0.673, 0.253 değeri elde edilmiştir.

IoU: 0.5 değerine göre 549 bina içinden 371 doğru pozitif bina etiketleyerek %67.58 başarı oranı elde edilmiştir.



Çalışma alanı veri 2 WorldView-3 uydu görüntüsü genel görünüm

Çalışma alanı veri 2 WorldView-3 uydu görüntüsü gerçek bina etiket özellikleri



Çalışma alanı veri 2 WorldView-3 uydu görüntüsü bina tespiti

Şekil 5.30 Çalışma alanı 2 gerçek bina etiket özellikleri ve bina tespiti

6. BULGULAR

Bu bölümde, YOLOv8m, YOLOv11m ve Mask R-CNN algoritmalarının bina tespiti performansları incelenmiş ve elde edilen sonuçlar tablo halinde sunulmuştur. Değerlendirmeler, HGM ortofotosuna ve WV03 uydu görüntüsüne dayalı olarak gerçekleştirilmiştir.

Çizelge 6.1 YOLOv8, YOLOv11, Mask-RCNN algoritmalarının değerlendirmeleri

Çalışma Alanı	Model	Epok Sayısı	Batch	Bina Sayısı	Doğru Pozitif Bina Sayısı	Başarı Oranı (Yüzde)
Çalışma Alan 1	YOLOv8m	200	8	224	136	60.71
Çalışma Alan 1	YOLOv11m	200	8	224	137	61.16
Çalışma Alan 1	MASK-RCNN IoU:0.5	200	8	224	166	74.11
Çalışma Alan 2	YOLOv8m	200	8	549	385	70.13
Çalışma Alan 2	YOLOv11m	200	8	549	389	70.86
Çalışma Alan 2	MASK-RCNN IoU:0.5	200	8	549	371	67.58

Yapılan bina tespiti analizlerine göre, kullanılan YOLOv8m, YOLOv11m ve Mask R-CNN algoritmalarının farklı başarı oranı değerleri sunduğu görülmektedir. Özellikle WV03 uydu görüntüsü üzerinden yapılan analizlerde YOLOv11m algoritmasının %70.86 doğruluk oranı ile en yüksek başarıyı sağladığı görülmüştür. Uydu görüntülerinin geniş alanları kapsayabilmesi daha bütüncül bir perspektif sunmasından dolayı bu modelin daha başarılı sonuçlar üretmesine katkı sağlamıştır. YOLOv8m ise %70.13 başarı oranı ile benzer sonuçlar sunmuştur, ancak YOLOv11m'in daha ileri optimizasyonları nedeniyle bir miktar daha iyi performans gösterdiği gözlemlenmiştir.

Buna karşın, HGM ortofotosu verileri üzerinde yapılan çalışmalarda, Mask R-CNN algoritmasının %74.11 doğruluk oranı ile en iyi sonucu verdiği görülmüştür. Mask R-CNN'in bölge tabanlı tahmin yapma yeteneği, daha küçük ve karmaşık yapıların bulunduğu ortofoto görüntülerinde daha iyi performans göstermesine neden olmuştur. YOLO tabanlı algoritmalar ise bu verilerde Mask R-CNN'e kıyasla daha düşük başarı oranına sahiptir; YOLOv8m %60.71 ve YOLOv11m %61.16 doğruluk oranına ulaşmıştır.



7. TARTIŞMA ve SONUÇ

Uzaktan algılama teknolojilerinin hızlı gelişimi, uydu platformları ve yüksek çözünürlüklü görüntüleme sensörleri, kentsel analiz ve bina tespiti gibi uygulamalarda kritik bir rol oynamaktadır. Bu tez çalışması, YOLOv8m, YOLOv11 ve Mask R-CNN algoritmalarının farklı veri kaynakları üzerinde bina tespit performanslarını inceleyerek derin öğrenme tabanlı bina tespiti yaklaşımlarının etkinliğini değerlendirmiştir.

YOLOv8m modeli, WV03 uydu görüntüsünde %70.13 doğruluk oranı elde etmiş olup, yüksek çözünürlüklü uydu görüntülerinde başarılı bir performans göstermiştir. YOLOv11m modeli ise %70.86 doğruluk oranıyla YOLOv8m'e kıyasla biraz daha iyi bir performans sunmuştur. Mask R-CNN ise %67.58 doğruluk oranına sahip olup, segmentasyon bazlı yaklaşım nedeniyle özellikle bina kenarlarını belirlemede güçlüdür, ancak obje bazlı tespitlerde YOLO tabanlı modeller kadar başarılı değildir.

HGM ortofoto görüntüleri kullanıldığında ise, YOLOv8m %60.71, YOLOv11m %61.16 ve Mask R-CNN %74.11 doğruluk oranlarına ulaşmıştır. Bu sonuçlar, Mask R-CNN'in ortofoto görüntülerde daha yüksek başarı gösterdiğini ortaya koymaktadır. Bu durum, Mask R-CNN'in detay bazlı analiz yapabilme yeteneğinin, ortofoto gibi belirgin ve yüksek çözünürlüklü hava görüntülerinde daha etkili çalışmasına bağlanabilir.

YOLOv8m ve YOLOv11m'nin özellikle binaların birbirine çok yakın olduğu bölgelerde hata oranlarının arttığı gözlemlenmiştir. Mask R-CNN'in ise segmentasyon bazlı olması nedeniyle, bazı küçük ve karmaşık yapıları tespit edemediği belirlenmiştir.

Bu çalışma, derin öğrenme algoritmalarının bina tespitinde hangi verilerde daha iyi performans sergilediğini ortaya koyarak, kentsel planlama, afet yönetimi ve coğrafi bilgi sistemleri gibi alanlar için yol gösterici bir temel oluşturmuştur. Gelecek çalışmalar olarak ise segmentasyon ve bina tespitinin yüksek performansta çalışabilmesi için olanak sağlayacak şekilde yöntemlerinin geliştirilmesi, veri setlerinin zenginleştirilmesi ve derin öğrenme modellerinin optimize edilmesi planlanmaktadır.

8. KAYNAKLAR

- Aamir, M., Pu, Y.-F., Rahman, Z., Tahir, M., Naeem, H., & Dai, Q. (2019). A framework for automatic building detection from low-contrast satellite images. *Symmetry*, 11(3), 1-19. <https://doi.org/10.3390/sym11010003>
- Boonpook, W., Tan, Y., Ye, Y., Torteeka, P., Torsri, K., & Dong, S. (2018). A deep learning approach on building detection from unmanned aerial vehicle-based images in riverbank monitoring. *Sensors*, 18(11), 3921. <https://doi.org/10.3390/s18113921>
- Çeçen, Ş. (2023). Derin öğrenme teknikleri kullanılarak ratlarda östrus dönemlerinin YOLOv5 modeli ile sınıflandırılması (Yüksek Lisans Tezi, Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalı, Yazılım Bilim Dalı). Elazığ, Türkiye.
- Çelik, M. T. (2024). YOLOv8 Nesne Tespit Modeli ile Plastik Parça Yüzey Kusurlarının Gerçek Zamanlı Tespiti (Yüksek Lisans Tezi, Bursa Teknik Üniversitesi, Lisansüstü Eğitim Enstitüsü, Endüstri Mühendisliği Anabilim Dalı). Bursa, Türkiye.
- Çelik, S., & Altınörs, A. (2023). Environmental waste detection from UAV images with YOLOv3 deep learning algorithm. *International Journal of Innovative Engineering Applications*, 7(1), 76-85. <https://doi.org/10.46460/ijiea.1195428>
- Emek, R. A. (2022). Derin Öğrenme Metotları Kullanılarak SAR (SENTETİK AÇIKLIKLI RADAR) GÖRÜNTÜLERİNDEN BİNA TESPİTİ (Yüksek Lisans Tezi, Akdeniz Üniversitesi, Fen Bilimleri Enstitüsü, Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Ana Bilim Dalı). Antalya, Türkiye.
- Ersan, S. (2024). YOLOv7 algoritması ile dış röntgenlerinde lezyon ve çürük tespiti (Yüksek Lisans Tezi, Dicle Üniversitesi, Fen Bilimleri Enstitüsü, Biyomedikal

Mühendisliği Anabilim Dalı). Diyarbakır, Türkiye.

Francini, M., Salvo, C., Viscomi, A., & Vitale, A. (2022). A deep learning-based method for the semi-automatic identification of built-up areas within risk zones using aerial imagery and multi-source GIS data: An application for landslide risk. *Remote Sensing*, 14(17), 4279. <https://doi.org/10.3390/rs14174279>

Gao, J., Chen, Y., Wei, Y., & Li, J. (2021). Detection of specific building in remote sensing images using a novel YOLO-S-CIOU model: Case gas station identification. *Sensors*, 21(4), 1375. <https://doi.org/10.3390/s21041375>

Gündüz, M. Ş. (2023). Gerçek zamanlı videolardan kalabalık ve sosyal mesafe tespiti için YOLO algoritmalarının performans analizi: COVID-19 uygulaması (Yüksek Lisans Tezi, Iğdır Üniversitesi, Lisansüstü Eğitim Enstitüsü, Mekatronik Ana Bilim Dalı). Iğdır, Türkiye.

Hacıfendioğlu, K., Başağa, H. B., Kahya, V., Özgan, K., & Altunışık, A. C. (2024). Automatic detection of collapsed buildings after the 6 February 2023 Türkiye earthquakes using post-disaster satellite images with deep learning-based semantic segmentation models. *Buildings*, 14(3), 582. <https://doi.org/10.3390/buildings14030582>

Hamaguchi, R., & Hikosaka, S. (2018). Building detection from satellite imagery using ensemble of size-specific detectors. PASCO Corporation.

He, Z., Wang, K., Fang, T., Su, L., Chen, R., & Fei, X. (2024). Comprehensive performance evaluation of YOLOv11, YOLOv10, YOLOv9, YOLOv8, and YOLOv5 on object detection of power equipment. *arXiv preprint arXiv:2411.18871*. <https://doi.org/10.48550/arXiv.2411.18871>

Huang, X., Hou, C., Lim, K. H., Kwoh, L. K., & Liew, S. C. (2024). Enhancing building detection in satellite imagery: Integrating segment anything model's output as an

additional channel. IGARSS 2024 - IEEE International Geoscience and Remote Sensing Symposium. <https://doi.org/10.1109/IGARSS53475.2024.10640982>

Huang, X., Ren, L., Liu, C., Wang, Y., Yu, H., Schmitt, M., Hänsch, R., Sun, X., Huang, H., & Mayer, H. (2024). Urban Building Classification (UBC) – A dataset for individual building detection and classification from satellite imagery. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 1413-1421.

Ilmak, D., Iban, M. C., & Şeker, D. Z. (2024). A geospatial dataframe of collapsed buildings in Antakya City after the 2023 Kahramanmaraş earthquakes using object detection based on YOLO and VHR satellite images. IGARSS 2024 - IEEE International Geoscience and Remote Sensing Symposium. <https://doi.org/10.1109/IGARSS53475.2024.10642920>

Karabulut, Ş. (2022). Uydu görüntülerinden alınan halka açık binaların derin öğrenme yöntemleriyle sınıflandırılması ve performans ölçümü (Yüksek Lisans Tezi, Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Ekobilisim Anabilim Dalı). Elazığ, Türkiye.

Khalaf, R. S. (2021). Guns detection using YOLO algorithm (Master's Thesis, Fırat University, Graduate School of Natural and Applied Science, Department of Software Engineering). Elazığ, Türkiye.

Khanam, R., & Hussain, M. (2024). YOLOv11: An overview of the key architectural enhancements. YOLO Vision 2024 Conference, Huddersfield University, UK. <https://doi.org/10.12345/yolo.v11.2024>

Kim, J. S., & Hong, I. Y. (2021). Analysis of building object detection based on the YOLO neural network using UAV images. Journal of the Korean Society of Surveying, Geodesy, Photogrammetry and Cartography, 39(6), 381-392. <https://doi.org/10.7848/ksgpc.2021.39.6.381>

- Kocaman, H., Garip, Z., & Özden, A. (2023). Derin öğrenmeye dayalı nesne tanıma yöntemi ile hava fotoğrafı üzerinden karşılaştırmalı bina tespiti. 2nd International Conference on Innovative Academic Studies, Konya, Turkey.
- Liu, P., Gao, Y., Zheng, X., Wang, H., Zhao, Y., Wu, X., Lu, Z., Yue, Z., Xie, Y., & Hao, S. (2025). Integrating attention mechanism and boundary detection for building segmentation from remote sensing images. *Frontiers in Neurorobotics*, 18, 1482051.
- Nasrullah, M., & Diker, A. (2021). Derin öğrenme ve YOLO algoritmaları ile nesne tespiti ve şerit belirleme. 2. Uluslararası Akıllı Ulaşım Sistemleri Konferansı Tam Metin Kitabı, 68-78. Bandırma, Türkiye.
- Özaydın, E. (2021). Derin Öğrenme Yaklaşımı İle Çok Yüksek Çözünürlüklü Uydu Görüntülerinde Bina Tespiti (Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi, Lisansüstü Eğitim Enstitüsü, Geomatik Mühendisliği Anabilim Dalı). İstanbul, Türkiye.
- Piltan, S. (2022). YOLO-V4 Algoritması ile Sosyal Mesafelerin Fotogrametrik Yöntemle Üç Boyutlu Gerçek Zamanlı Tespiti (Yüksek Lisans Tezi, Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Harita Mühendisliği Anabilim Dalı). Trabzon, Türkiye.
- Polat, N. (2018). 3B nokta bulutlarından bina tespiti (Doktora tezi, Afyon Kocatepe Üniversitesi, Fen Bilimleri Enstitüsü, Harita Mühendisliği Anabilim Dalı).
- Sarahoğlu, E., & Güngör, O. (2022). Yüksek çözünürlüklü uydu görüntülerinden daha hızlı bölge tabanlı derin öğrenme modeli ile bina tespiti. *Gümüşhane Üniversitesi Fen Bilimleri Dergisi (GUJS)*, 12(2), 550-563. <https://doi.org/10.17714/gumusfenbil.1012519>
- Tan, F. G., Yüksel, A. S., Aydemir, E., & Ersoy, M. (2021). Derin öğrenme teknikleri ile nesne tespiti ve takibi üzerine bir inceleme. *Avrupa Bilim ve Teknoloji Dergisi*,

(25), 159-171. <https://doi.org/10.31590/ejosat.878552>

Tasyürek, M. (2024). BBD: A new hybrid method for geospatial building boundary detection from huge size satellite imagery. *Multimedia Tools and Applications*. <https://doi.org/10.1007/s11042-024-19279-5>

Venkatesh, K., & Hashmi, M. F. (2024). Object detection for remote sensing images using YOLOv8. *15th International Conference on Computing Communication and Networking Technologies (ICCCNT)*, IIT Mandi, Kamand, India. <https://doi.org/10.1109/ICCCNT61001.2024.10725328>

Wang, T., Reinhart, C., & Ang, Y. Q. (2025). sat2shp: Extracting key building features from a single satellite image for urban building energy modelling and beyond. *Sustainable Cities and Society*, 118, 106054. <https://doi.org/10.1016/j.scs.2024.106054>

Yap, Y. L., Azizah, K., Lim, S. L., Hilman, M. H., & Jatmiko, W. (2024). Building detection from satellite images using deep learning. *2024 Multimedia University Engineering Conference (MECON)*. IEEE. <https://doi.org/10.1109/MECON62796.2024.10776219>

Yasak, S. S. (2021). Coğrafyada Yapay Zeka Uygulamaları: YOLO V3 ile Gerçek Zamanlı Kayaç Tespit Uygulaması Örneği (Yüksek Lisans Tezi, Marmara Üniversitesi, Sosyal Bilimler Enstitüsü, Coğrafya Anabilim Dalı). İstanbul, Türkiye.

Yavuz, A. (2024). İyileştirilmiş Sayısal Yükseklik Modeli ile Yeni Bir Gerçek Ortofoto Modülü Geliştirilmesi (Yüksek Lisans Tezi, Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü). Trabzon, Türkiye.

Yıldırım, B. (2023). YOLO ile Engelli Bireylerin Kullandığı Yardımcı Gereçlerin Tespiti (Yüksek Lisans Tezi, Eskişehir Osmangazi Üniversitesi, Fen Bilimleri Enstitüsü,

Elektrik Elektronik Mühendisliği Anabilim Dalı). Eskişehir, Türkiye.

Yörük, Y. E., Saraoğlu, H. M., & Özer, Ö. F. (2023). Mask R-CNN ile Mikroskobik İdrar Görüntüsü İçeriklerinin Tespiti. Afyon Kocatepe Üniversitesi Fen ve Mühendislik Bilimleri Dergisi, 23(055202), 1180-1189. <https://doi.org/10.35414/akufemubid.1278080>

Zheng, X., & Zhao, X. (2024). Single Shot MultiBox Detector-based feature fusion model for building object detection. Journal of Applied Science and Engineering, 28(2), 391-398. [https://doi.org/10.6180/jase.202502_28\(2\).0017](https://doi.org/10.6180/jase.202502_28(2).0017)

İnternet Kaynakları

- 1- <https://www.ultralytics.com/tr>, 01.12.2024
- 2- <https://blog.roboflow.com/mask-rcnn/>, 25.11.2024
- 3-<https://www.eoportal.org/satellite-missions/worldview-3#mission-capabilities>, 23.12.2024
- 4- https://en.wikipedia.org/wiki/Turing_test, 10.01.2025
- 5- <https://skalskip.github.io/make-sense/>, 25.02.2025
- 6- <https://www.ibm.com/think/topics/data-augmentation>, 22.02.2025



EKLER

EK 1. Eğitim Veri Seti İçin Görüntü Boyutlandırma

```
from PIL import Image
import os

# Giriş ve çıkış klasörlerini tanımlayın
input_folder = "C:/Users/sbbpc/Desktop/verigörüntü/görüntü" # Görsellerin bulunduğu
klasör
output_folder = "C:/Users/sbbpc/Desktop/verigörüntü/görüntü640" # Yeniden
boyutlandırılmış görsellerin kaydedileceği klasör

# Çıkış klasörü yoksa oluştur
os.makedirs(output_folder, exist_ok=True)

# Görüntüleri yeniden boyutlandır
for filename in os.listdir(input_folder):
    if filename.lower().endswith(('.png', '.jpg', '.jpeg', '.bmp', '.gif', '.tiff')):
        input_path = os.path.join(input_folder, filename)
        output_path = os.path.join(output_folder, filename)

        try:
            # Görüntüyü aç
            with Image.open(input_path) as img:
                # Yeniden boyutlandır
                resized_img = img.resize((640, 640), Image.ANTIALIAS)
                # Yeni görüntüyü kaydet
                resized_img.save(output_path)
                print(f'{filename}' başarıyla yeniden boyutlandırıldı ve kaydedildi.")
        except Exception as e:
            print(f'{filename}' işlenirken hata oluştu: {e}"))
```

EK 2. Eğitim Veri Seti için Veri Artırımı

```
import os
import numpy as np
from PIL import Image
from imgaug import augmenters as iaa

# Giriş ve çıkış klasörlerini belirleyin
input_folder = "C:/Users/sbbpc/Desktop/binaveriyolo/foto1" # Orijinal görüntülerin
bulunduğu klasör
output_folder = "C:/Users/sbbpc/Desktop/binaveriyolo/fotoart1" # Artırılmış
görüntülerin kaydedileceği klasör
os.makedirs(output_folder, exist_ok=True)
# Veri artırımı için imgaug augmenters
augmenters = iaa.Sequential([
    iaa.Fliplr(0.7), # Görüntüleri yatay çevirme
    iaa.Affine(rotate=(-75, 75)), # Döndürme
    iaa.Affine(scale=(0.7, 1.0)), # Ölçekleme
    iaa.Multiply((0.7, 0.9)), # Parlaklık değişimi
    iaa.AdditiveGaussianNoise(scale=(0, 0.06*255)) # Gürültü ekleme
])
# Klasördeki tüm görüntüleri işleme
for file_name in os.listdir(input_folder):
    if file_name.lower().endswith(".jpg"): # Sadece JPG dosyalarını işleme
        file_path = os.path.join(input_folder, file_name)
        # Görüntüyü yükle
        image = np.array(Image.open(file_path))
        # Artırılmış görüntüler oluştur
        for i in range(5): # Her bir görüntü için 5 varyasyon
            augmented_image = augmenters(image=image)
            # Yeni dosya adını oluştur
            output_file_name = f"{os.path.splitext(file_name)[0]}_aug_{i}.jpg"
```

```
output_path = os.path.join(output_folder, output_file_name)
# Görüntüyü kaydet
Image.fromarray(augmented_image).save(output_path)

print(f'Artırılmış görüntüler {output_folder} klasörüne kaydedildi.")
```