

**YOLO VE RT-DETR TABANLI DERİN ÖĞRENME
MODELLERİ İLE AĞAÇ TESPİTİ**

YÜKSEK LİSANS TEZİ

Hamdi Görkem KAYMAK

Danışman

Prof. Dr. Mustafa YILMAZ

HARİTA MÜHENDİSLİĞİ ANABİLİM DALI

Haziran 2026

AFYON KOCATEPE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

**YOLO VE RT-DETR TABANLI DERİN ÖĞRENME
MODELLERİ İLE AĞAÇ TESPİTİ**

Hamdi Görkem KAYMAK

Danışman

Prof. Dr. Mustafa YILMAZ

HARİTA MÜHENDİSLİĞİ ANABİLİM DALI

Haziran 2026

TEZ ONAY SAYFASI

Hamdi Grkem KAYMAK tarafından hazırlanan “YOLO VE RT-DETR TABANLI DERİN RENME MODELLERİ İLE AĖAÇ TESPİTİ” adlı tez alıřması lisansst eēitim ve ēretim ynetmeliēinin ilgili maddeleri uyarınca 18 / 06 / 2026 tarihinde ařaēıdaki jri tarafından **oy birliēi** ile Afyon Kocatepe niversitesi Fen Bilimleri Enstits **Harita Mhendisliēi Anabilim Dalı’nda YKSEK LİSANS TEZİ** olarak kabul edilmiřtir.

Danıřman : Prof. Dr. Mustafa YILMAZ

Bařkan : Prof. Dr. Murat UYSAL
Afyon Kocatepe niversitesi
Mhendislik Fakltesi

..... İmza

ye : Dr. ēr. yesi Abdullah VARLIK
Necmettin Erbakan niversitesi
Mhendislik ve Mimarlık Fakltesi

..... İmza

Afyon Kocatepe niversitesi
Fen Bilimleri Enstits Ynetim Kurulu’nun
..... /..... /..... tarih ve
..... sayılı kararıyla onaylanmıřtır.

.....

Prof. Dr. Bekir YALIN

Enstit Mdr

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.

18 / 06 / 2026

Hamdi Görkem KAYMAK

ÖZET

Yüksek Lisans Tezi

YOLO VE RT-DETR TABANLI DERİN ÖĞRENME MODELLERİ İLE AĞAÇ TESPİTİ

Hamdi Görkem KAYMAK

Afyon Kocatepe Üniversitesi

Fen Bilimleri Enstitüsü

Harita Mühendisliği Anabilim Dalı

Danışman: Prof. Dr. Mustafa YILMAZ

Kentlerde ve kırsal alanlarda artan nüfus, tüketim ihtiyaçları, fosil yakıtlara olan bağımlılık, sanayileşme ve kentleşme süreçleri, doğal ekosistemleri çok yönlü olarak tahrip etmektedir. Bu tahribatların izlenmesi ve yönetilmesinde teknolojik gelişmeler, derin öğrenme yöntemlerini klasik yaklaşımlara kıyasla önemli ölçüde daha etkin hale getirmektedir. Bu çalışmanın temel amacı, YOLO ve RT-DETR algoritmalarına dayalı derin öğrenme modellerinin aynı veri seti ve hiperparametreler altında ağaç tespiti performansının karşılaştırılmasıdır. Bu kapsamda; RT-DETR L, YOLOv3 m, YOLOv5 m, YOLOv6 m, YOLOv8 m, YOLOv9 m, YOLOv10 m, YOLOv11 m, YOLOv12 m ve YOLOv26 m modelleri, İsviçre'nin Vaud (2023) ve Bern (2024) kantonlarına ait 10 cm çözünürlüklü SWISSIMAGE ortofoto verileri kullanılarak eğitilmiş ve test edilmiştir. Tüm işlemler Ultralytics kütüphanesi ile gerçekleştirilmiş; model performansları eğitim metrikleri (mAP50, Precision, Recall, F1 Score) ve iki bağımsız çalışma alanındaki tespit doğruluk oranları üzerinden değerlendirilmiştir. Çalışma, nesne tespitindeki temel problemleri ve yaklaşımları göz önüne sererek gelecekte yapılacak daha detaylı bilimsel çalışmalara yol göstermeyi amaçlamaktadır.

2026, x + 106 sayfa

Anahtar Kelimeler: Yapay Zekâ, Derin Öğrenme, YOLO, Uzaktan Algılama, Ağaç Tespiti, RT-DETR

ABSTRACT

M.Sc. Thesis

TREE DETECTION FROM ORTHOPHOTO IMAGERY USING YOLO AND RT-DETR DEEP LEARNING MODELS

Hamdi Görkem KAYMAK

Afyon Kocatepe University

Graduate School of Natural and Applied Sciences

Department of Geomatics Engineering

Supervisor: Prof. Dr. Mustafa YILMAZ

Rising populations in urban and rural areas, escalating consumption demands, reliance on fossil fuels, industrialization, and urbanization processes inflict multifaceted degradation upon natural ecosystems. In monitoring and managing these deteriorations, technological advancements have rendered deep learning methodologies considerably more effective than classical approaches. The fundamental objective of this study is to comparatively evaluate the tree detection performance of deep learning models based on YOLO and RT-DETR algorithms under identical dataset and hyperparameter conditions. Within this framework, the RT-DETR L, YOLOv3 m, YOLOv5 m, YOLOv6 m, YOLOv8 m, YOLOv9 m, YOLOv10 m, YOLOv11 m, YOLOv12 m, and YOLOv26 m models were trained and tested using 10 cm resolution SWISSIMAGE orthophoto data from the cantons of Vaud (2023) and Bern (2024) in Switzerland. All procedures were implemented utilizing the Ultralytics library; model performance was evaluated based on training metrics (mAP50, Precision, Recall, F1 Score) and detection accuracy rates across two independent study areas. By elucidating fundamental challenges and methodologies in object detection, this work aims to provide guidance for more comprehensive scientific investigations in the future.

2026, x + 106 pages

Keywords: Artificial Intelligence, Deep Learning, YOLO, Remote Sensing, Tree Detection, RT-DETR

TEŞEKKÜR

Yüksek lisans sürecim boyunca bilgi ve tecrübeleriyle bana yol gösteren, sabır ve anlayışla beni destekleyen sayın Prof. Dr. Mustafa YILMAZ'a ve sorularımı yanıtsız bırakmayan İnş. Müh. Saim KAYMAK'a içten teşekkürlerimi sunarım.

Bu süreçte beni her zaman destekleyen ve yanımda olan, sağlamış oldukları maddi ve manevi destekleri ile bana güç veren annem Düriye KAYMAK'a, babam Nihat KAYMAK'a kardeşim Sanem Kardelen KAYMAK'a sonsuz teşekkür ederim.

Hamdi Gökem KAYMAK

Afyonkarahisar 2026

İÇİNDEKİLER DİZİNİ

	Sayfa
ÖZET.....	i
ABSTRACT	ii
TEŞEKKÜR	iii
İÇİNDEKİLER DİZİNİ	iv
SİMGELER VE KISALTMALAR DİZİNİ	vii
ŞEKİLLER DİZİNİ.....	viii
RESİM DİZİNİ	x
ÇİZELGE DİZİNİ.....	xi
1.GİRİŞ	1
2. LİTERATÜR TARAMA	4
3. DERİN ÖĞRENME	9
3.1 Derin Öğrenme Süreçleri.....	11
3.1.1 Veri Toplama ve Ön İşleme.....	12
3.1.2 Model Seçimi ve Tasarımı	12
3.1.3 Model Eğitimi.....	12
3.1.4 Model Değerlendirmesi	12
3.1.5 Modelin Dağıtımı ve Uygulama.....	13
3.2 Nesne Tanıma Algoritmaları.....	13
3.2.1 Derin Öğrenme Tabanlı Yöntemler	13
3.2.1.1 YOLO (You Only Look Once)	15
3.2.1.1.1 RT-DETR.....	16
3.2.1.1.2 YOLOv3	17
3.2.1.1.3 YOLOv5	19
3.2.1.1.4 YOLOv6	20

3.2.1.1.5 YOLOv8	22
3.2.1.1.6 YOLOv9	23
3.2.1.1.7 YOLOv10	24
3.2.1.1.8 YOLOv11	25
3.2.1.1.9 YOLOv12	27
3.2.1.1.10 YOLOv26	28
4 MATERYAL VE METOT	29
4.1 Çalışma Alanları	29
4.2 Veri Seti.....	31
4.3 Verinin Etiketlenmesi	32
4.4 Eğitim İçin Model Seçimi.....	32
4.5 Değerlendirme Kriterleri.....	34
5 UYGULAMA.....	37
5.1 Ağaç Tespit Modelleri ve Doğruluk Analizleri.....	37
5.1.1 RT-DETR Ağaç Tespit Modeli	37
5.1.2 RT-DETR Doğruluk Analizi	38
5.1.3 YOLOv3 Ağaç Tespit Modeli.....	43
5.1.4 YOLOv3 Doğruluk Analizi	43
5.1.5 YOLOv5 Ağaç Tespit Modeli.....	49
5.1.6 YOLOv5 Doğruluk Analizi	49
5.1.7 YOLOv6 Ağaç Tespit Modeli.....	54
5.1.8 YOLOv6 Doğruluk Analizi	54
5.1.9 YOLOv8 Ağaç Tespit Modeli.....	60
5.1.10 YOLOv8 Doğruluk Analizi	60
5.1.11 YOLOv9 Ağaç Tespit Modeli.....	65
5.1.12 YOLOv9 Doğruluk Analizi	65
5.1.13 YOLOv10 Ağaç Tespit Modeli.....	71
5.1.14 YOLOv10 Doğruluk Analizi	71
5.1.15 YOLOv11 Ağaç Tespit Modeli.....	76
5.1.16 YOLOv11 Doğruluk Analizi	76
5.1.17 YOLOv12 Ağaç Tespit Modeli.....	82

5.1.18	YOLOv12 Doğruluk Analizi	82
5.1.19	YOLOv26 Ağaç Tespit Modeli.....	87
5.1.20	YOLOv26 Doğruluk Analizi	87
6	BULGULAR	93
7	TARTIŞMA ve SONUÇ	96
8	KAYNAKLAR	99
	İnternet Kaynakları.....	105
	ÖZGEÇMİŞ	106

SİMGELER VE KISALTMALAR DİZİNİ

Simgeler

%	Yüzde
$\approx$	Yaklaşık

Kısaltmalar

AI / IA	Artificial Intelligence / Yapay Zekâ
AP	Average Precision / Ortalama Hassasiyet
CNN	Convolutional Neural Networks / Evrişimli Sinir Ağları
CO ₂	Karbondiyoksit
DETR	Detection Transformer / Tespit Transformer'ı
DFL	Distribution Focal Loss / Dağılım Odaklı Kayıp
FLOPs	Floating Point Operations per Second / Saniyedeki Kayan Nokta İşlemleri
FN	False Negative / Yanlış Negatif
FP	False Positive / Yanlış Pozitif
FPS	Frames Per Second / Saniyedeki Kare Sayısı
GPU	Graphics Processing Unit / Grafik İşlem Birimi
GSD	Yer örnekleme aralığı
İHA	Unmanned Aerial Vehicle / İnsansız Hava Aracı
IoU	Intersection over Union / Birleşim Üzerinden Kesişim
LR	Learning Rate / Öğrenme Oranı
mAP	Mean Average Precision / Ortalama Hassasiyet Ortalaması
NMS	Non-Maximum Suppression / Maksimum Olmayan Bastırma
R-CNN	Region-Based Convolutional Neural Networks / Bölge Tabanlı Evrişimli Sinir Ağları
R-ELAN	Residual Efficient Layer Aggregation Networks / Artıklı Verimli Katman Birleştirme Ağları
ReLU	Rectified Linear Unit / Doğrultulmuş Lineer Birim
RF	Random Forest / Rastgele Orman
RNN	Recurrent Neural Network / Tekrarlayan Sinir Ağı
RS	Remote Sensing / Uzaktan Algılama
SGD	Stochastic Gradient Descent / Stokastik Gradyan İnişi
SSD	Single Shot MultiBox Detector / Tek Atışlı Çoklu Kutu Dedektörü
STAL	Spatial-Temporal Attention Loss / Mekansal-Zamansal Dikkat Kaybı
TN	True Negative / Doğru Negatif
TP	True Positive / Doğru Pozitif
ViT	Vision Transformer / Görme Transformer'ı
YOLO	You Only Look Once / Sadece Bir Kez Bak

ŞEKİLLER DİZİNİ

	Sayfa
Şekil 5. 1 Çalışmada Kullanılan YOLO Algoritmasının İş Akış Diyagramı.....	37
Şekil 5. 2 RT-DETR L modelinin kesinlik analizi.....	38
Şekil 5. 3 RT-DETR L modelinin duyarlılık eğrisi.....	39
Şekil 5. 4 RT-DETR L modelinin kesinlik-duyarlılık eğrisi.....	39
Şekil 5. 5 RT-DETR L modelinin F1-Güven eğrisi.....	40
Şekil 5. 6 RT-DETR L modeli performans grafikleri.....	40
Şekil 5. 7 RT-DETR L modeli karışıklık matrisi.....	41
Şekil 5. 8 YOLOv3 m modelinin kesinlik analizi.....	44
Şekil 5. 9 YOLOv3 m modelinin duyarlılık eğrisi.....	44
Şekil 5. 10 YOLOv3 m modelinin kesinlik-duyarlılık eğrisi.....	45
Şekil 5. 11 YOLOv3 m modelinin F1-Güven eğrisi.....	45
Şekil 5. 12 YOLOv3 m modeli performans grafikleri.....	46
Şekil 5. 13 YOLOv3 modeli karışıklık matrisi.....	47
Şekil 5. 14 YOLOv5 m modelinin kesinlik analizi.....	49
Şekil 5. 15 YOLOv5 m modelinin duyarlılık eğrisi.....	50
Şekil 5. 16 YOLOv5 m modelinin kesinlik-duyarlılık eğrisi.....	50
Şekil 5. 17 YOLOv5 m modelinin F1-Güven eğrisi.....	51
Şekil 5. 18 YOLOv5 m modeli performans grafikleri.....	51
Şekil 5. 19 YOLOv5 m modeli karışıklık matrisi.....	52
Şekil 5. 20 YOLOv6 m modelinin kesinlik analizi.....	55
Şekil 5. 21 YOLOv6 m modelinin duyarlılık eğrisi.....	55
Şekil 5. 22 YOLOv6 m modelinin kesinlik-duyarlılık eğrisi.....	56
Şekil 5. 23 YOLOv6 m modelinin F1-Güven eğrisi.....	56
Şekil 5. 24 YOLOv6 m modeli performans grafikleri.....	57
Şekil 5. 25 YOLOv6 m modeli karışıklık matrisi.....	58
Şekil 5. 26 YOLOv8 m modelinin kesinlik analizi.....	60
Şekil 5. 27 YOLOv8 m modelinin duyarlılık eğrisi.....	61
Şekil 5. 28 YOLOv8 m modelinin kesinlik-duyarlılık eğrisi.....	61
Şekil 5. 29 YOLOv8 m modelinin F1-Güven eğrisi.....	62
Şekil 5. 30 YOLOv8 m modeli performans grafikleri.....	62
Şekil 5. 31 YOLOv8 m modeli karışıklık matrisi.....	63
Şekil 5. 32 YOLOv9 m modelinin kesinlik analizi.....	66
Şekil 5. 33 YOLOv9 m modelinin duyarlılık eğrisi.....	66
Şekil 5. 34 YOLOv9 m modelinin kesinlik-duyarlılık eğrisi.....	67
Şekil 5. 35 YOLOv9 m modelinin F1-Güven eğrisi.....	67
Şekil 5. 36 YOLOv9 m modeli performans grafikleri.....	68
Şekil 5. 37 YOLOv9 m modeli karışıklık matrisi.....	69
Şekil 5. 38 YOLOv10 m modelinin kesinlik analizi.....	71
Şekil 5. 39 YOLOv10 m modelinin duyarlılık eğrisi.....	72
Şekil 5. 40 YOLOv10 m modelinin kesinlik-duyarlılık eğrisi.....	72
Şekil 5. 41 YOLOv10 m modelinin F1-Güven eğrisi.....	73
Şekil 5. 42 YOLOv10 m modeli performans grafikleri.....	73

Şekil 5. 43 YOLOv10 m modeli karışıklık matrisi	74
Şekil 5. 44 YOLOv11 m modelinin kesinlik analizi	77
Şekil 5. 45 YOLOv11 m modelinin duyarlılık eğrisi	77
Şekil 5. 46 YOLOv11 m modelinin kesinlik-duyarlılık eğrisi	78
Şekil 5. 47 YOLOv11 m modelinin F1-Güven eğrisi.....	78
Şekil 5. 48 YOLOv11 m modeli performans grafikleri.....	79
Şekil 5. 49 YOLOv11 m modeli karışıklık matrisi.....	80
Şekil 5. 50 YOLOv12 m modelinin kesinlik analizi	82
Şekil 5. 51 YOLOv12 m modelinin duyarlılık eğrisi	83
Şekil 5. 52 YOLOv12 m modelinin kesinlik-duyarlılık eğrisi	83
Şekil 5. 53 YOLOv12 m modelinin F1-Güven eğrisi	84
Şekil 5. 54 YOLOv12 m modeli performans grafikleri	84
Şekil 5. 55 YOLOv12 m modeli karışıklık matrisi	85
Şekil 5. 56 YOLOv26 m modelinin kesinlik analizi	88
Şekil 5. 57 YOLOv26 m modelinin duyarlılık eğrisi	88
Şekil 5. 58 YOLOv26 m modelinin kesinlik-duyarlılık eğrisi	89
Şekil 5. 59 YOLOv26 m modelinin F1-Güven eğrisi	89
Şekil 5. 60 YOLOv26 m modeli performans grafikleri.....	90
Şekil 5. 61 YOLOv26 m modeli karışıklık matrisi	91

RESİM DİZİNİ

	Sayfa
Resim 4. 1 Çalışma alanı 1	30
Resim 4. 2 Çalışma alanı 2	30
Resim 4. 3 Çalışma alanlarının Dünya üzerindeki konumu	31
Resim 4. 4 Roboflow ile etiketleme işlemi.	32
Resim 5. 1 RT-DETR L modeli ağaç tespiti çalışma alanı 1	42
Resim 5. 2 RT-DETR L modeli ağaç tespiti çalışma alanı 2	43
Resim 5. 3 YOLOv3 m modeli ağaç tespiti çalışma alanı 1	48
Resim 5. 4 YOLOv3 m modeli ağaç tespiti çalışma alanı 2	48
Resim 5. 5 YOLOv5 m modeli ağaç tespiti çalışma alanı 1	53
Resim 5. 6 YOLOv5 m modeli ağaç tespiti çalışma alanı 2	54
Resim 5. 7 YOLOv6 m modeli ağaç tespiti çalışma alanı 1	59
Resim 5. 8 YOLOv6 m modeli ağaç tespiti çalışma alanı 2	59
Resim 5. 9 YOLOv8 m modeli ağaç tespiti çalışma alanı 1	64
Resim 5. 10 YOLOv8 m modeli ağaç tespiti çalışma alanı 2	65
Resim 5. 11 YOLOv9 m modeli ağaç tespiti çalışma alanı 1	70
Resim 5. 12 YOLOv9 m modeli ağaç tespiti çalışma alanı 2	70
Resim 5. 13 YOLOv10 m modeli ağaç tespiti çalışma alanı 1	75
Resim 5. 14 YOLOv10 m modeli ağaç tespiti çalışma alanı 2	76
Resim 5. 15 YOLOv11 m modeli ağaç tespiti çalışma alanı 1	81
Resim 5. 16 YOLOv11 m modeli ağaç tespiti çalışma alanı 2	81
Resim 5. 17 YOLOv12 m modeli ağaç tespiti çalışma alanı 1	86
Resim 5. 18 YOLOv12 m modeli ağaç tespiti çalışma alanı 2	87
Resim 5. 19 YOLOv26 m modeli ağaç tespiti çalışma alanı 1	92
Resim 5. 20 YOLOv26 m modeli ağaç tespiti çalışma alanı	92

ÇİZELGE DİZİNİ

	Sayfa
Çizelge 5. 1 RT-DETR L modeli eğitim değerleri.....	42
Çizelge 5. 2 YOLOv3 modeli eğitim değerleri	47
Çizelge 5. 3 YOLOv5 m modeli eğitim değerleri	53
Çizelge 5. 4 YOLOv6 m modeli eğitim değerleri	58
Çizelge 5. 5 YOLOv8 m modeli eğitim değerleri	64
Çizelge 5. 6 YOLOv9 m modeli eğitim değerleri	69
Çizelge 5. 7 YOLOv10 m modeli eğitim değerleri	75
Çizelge 5. 8 YOLOv11 m modeli eğitim değerleri	80
Çizelge 5. 9 YOLOv12 m modeli eğitim değerleri	86
Çizelge 5. 10 YOLOv26 m modeli eğitim değerleri	91
Çizelge 6. 1 YOLO modellerinin eğitim değerlendirmeleri.....	94
Çizelge 6. 2 Çalışma alanı 1 ve Çalışma alanı 2 için tespit edilen ağaç sayıları.....	95

1.GİRİŞ

Günümüzde dünya nüfusunun sürekli artışı, tüketim talepleri, fosil yakıt kullanımı, sanayileşme, kentleşme, küreselleşme ve teknolojik gelişmeler çevremizi ve gezegenimizi olumsuz etkileyen faktörler arasında yer almaktadır. Bunun yanı sıra, insanların ihtiyaç ve taleplerinin çeşitlenmesi ve artması doğal sistemler ile kaynaklar üzerinde ciddi tahribatlara yol açmaktadır.

Küresel ölçekte orman alanlarının dünya kara yüzeyinin yaklaşık %31'ini kapladığı ve bu ormanların önemli bir bölümünün beş ülkede yoğunlaştığı literatürde bildirilmektedir (Sarre, 2020).

Dünya üzerinde yaklaşık 73.300 ağaç türünün var olduğunu ve bunların önemli bir kısmının henüz bilimsel olarak tanımlanmadığını tahmin etmektedir. Söz konusu türlerin birçoğu, ormansızlaşma ve iklim değişikliği baskısı altında yok olma riski taşımaktadır (Cazzolla Gatti vd. 2022).

Günümüzde hızlı şehirleşme ile birlikte araç trafiğinin artması, karbondioksit (CO₂) emisyonlarının önemli ölçüde yükselmesine neden olmuştur. Ancak, kentlerdeki CO₂ emisyonlarının azaltılmasında kentsel ağaçların katkısının ne olduğu tam olarak anlaşılamamaktadır. Mevcut ve gelecekteki karbon depolama ve tutma işlevlerinin daha iyi kavranabilmesi için kentsel ağaçlar üzerine bilimsel araştırmalara gereksinim duyulmaktadır (Nowak vd. 2002).

Kentsel yeşil alanlar, ekosistem hizmetleri üreten ve kent yaşanabilirliğini destekleyen mekânsal sistemlerdir. Yol ve refüj ağaçlandırmaları ise bu sistem içinde yeşil alan bağlantılılığını sağlayan koridorlar olarak işlev görmekte; ayrıca estetik, fonksiyonel, ekolojik, psikolojik ve ekonomik açılardan kentsel çevreye katkı sağlamaktadır (Säumel vd. 2016).

Kentsel ağaçlandırma; afet yönetiminden çevre sürdürülebilirliğine kadar geniş bir yelpazede kent planlamasının önemli bir bileşeni olarak ele alınmaktadır. Yapay zekâ

tabanlı ağaç tespiti yöntemlerinin geliştirilmesiyle birlikte, envanterleme süreçlerinde doğruluk ve işlem hızı parametrelerinde iyileşmeler kaydedildiği bildirilmektedir (Wang vd. 2024a).

Kent ağaçları, yoğun trafik ve yapılaşma baskısı altındaki kentsel alanlarda ekosistem hizmetleri sunmaktadır. Bunlar arasında atmosferik karbonun biyokütle içinde depolanması, hava kirleticilerinin filtrelenmesi ve yerel ölçekli iklim regülasyonu sayılabilir. Bununla birlikte, kent ağaçlarının işlevi yalnızca biyofiziksel parametrelerle sınırlı kalmamaktadır. Mevcut literatür, kent yeşil alanlarının ve ağaçlandırmaların bireyler üzerindeki stres azaltıcı etkisini, psikolojik refah üzerindeki olumlu katkılarını ve termal konfor üzerindeki düzenleyici işlevini sistematik olarak belgelemektedir (Nowak ve Dwyer, 2007).

İlaveten, kentsel ağaçlandırmaların çocukların biyoçeşitlilikle doğrudan temas kurmasını sağlayarak çevre eğitiminin informal bir mecrası olarak işlev gördüğü belirtilmektedir (Säumel vd. 2016).

Bu çerçevede, kent ağaçlarının doğru tespiti ve envanterlenmesi; teknik bir veri toplama süreci olmanın ötesinde, kentsel yaşam kalitesinin sürdürülebilirliği ve gelecek nesillere sağlıklı çevre koşullarının aktarılması bağlamında stratejik bir planlama aracı olarak değerlendirilmektedir.

Derin öğrenme yaklaşımlarından biri olan YOLO (You Only Look Once) algoritması, nesne tespiti problemlerinde yüksek performansıyla dikkat çekmektedir. YOLO'nun asıl gücü, görüntüyü tek seferde tarayarak nesnenin konumunu ve türünü eşzamanlı belirleyebilmesinde yatmaktadır; bu sayede özellikle kapsamlı veri setleriyle çalışıldığında işlem süreleri önemli ölçüde kısalmaktadır. YOLO tabanlı nesne tespit sistemleri, geniş ölçekli ortofoto verilerinin işlenmesinde geleneksel manuel yöntemlere kıyasla işlem sürelerini önemli ölçüde kısaltma potansiyeli taşımaktadır (Wang vd. 2024a).

Sonu olarak, yapay zekâ destekli nesne tespiti sistemleri, derin ğrenme mimarilerinin sunduėu yksek doėruluk ve iřlem hızıyla kentsel analizlerine olanak sunmaktadır. Havadan grntleme teknolojileriyle btnleřen bu algoritmalar; yeřil alan planlamasından afet ynetimine kadar geniř bir yelpazede karar vericilere veriye dayalı bir zemin sunmaktadır. Bu alıřma, srdrlebilir kentleřme ve yařanabilir evreler hedefiyle aėa tespiti alanındaki akademik arařtırmalara katkı saėlamayı amalamaktadır.

Bu alıřmada RT-DETR L, YOLOv3 m, YOLOv5 m, YOLOv6 m, YOLOv8 m, YOLOv9 m, YOLOv10 m, YOLOv11 m, YOLOv12 m ve YOLOv26 m modellerinin derin ğrenme ile aėa tespiti bařarıları arařtırılmıř, bu alandaki bilimsel literatre katkı saėlanması amalanmıřtır.

2. LİTERATÜR TARAMA

YOLO mimarilerinin ağaç algılamadaki etkinliği: Hiperparametre ayarlamasının ve SGD, Adam ile AdamW optimizasyon algoritmalarının etkisi isimli makalede derin öğrenme tabanlı ağaç tespiti çalışmalarında kullanılan YOLOv5, YOLOv8 ve YOLOv11 modellerinin performansları incelenmiştir. YOLOv5 de AdamW, YOLOv8 de Adam ve AdamW, YOLOv11 de SGD, Adam ve AdamW olarak analiz edilmiştir. En iyi optimizasyonu YOLOv5 de Adamw, LR 0.001 ile 0.916 mAP50 değerini, YOLOv8 de AdamW LR 0.0001 ile 0.956 mAP50 değerini ve YOLOv11 de ise SGD, LR 0.001 ile 0.952 mAP50 değerlerini almıştır. Hiperparametre ayarlamasının model başarısını belirleyici rolünü gösterilmiştir. Çalışma, derin öğrenme tabanlı ağaç tespit sistemlerinin optimizasyonu için kapsamlı bir metodoloji sunmaktadır (Moraes vd. 2025).

Kentsel Ağaç Algılama: Hava görüntülerinden doğru tek-ağaç tanımlama için YOLOv8s ve DeepForest karşılaştırması çalışmasında kentsel ağaç envanteri oluşturmak için otomatik tek ağaç algılama yöntemlerini karşılaştırma amaçlı Almanya Münih bölgesinde yaklaşık olarak 13 hektarlık alanda 10 cm mekânsal çözünürlüklü hava görüntüleri ile YOLOv8s ve DeepForest modelleri değerlendirme metrikleri ile incelenmiştir. DeepForest modelinde ağaç özgü modelleri ile ağırlıkların güçlendirilebilmesi için, 10 epok boyunca ince ayar (fine-tuning) işlemleri sonucunda F1 skoru 0.7365'den 0.8030'a yükselmiştir. YOLOv8s ise genel coco önceden eğitilmiş genel ağırlıkları kullanarak, hiperparametre optimizasyonu gerektirmeden, erken durdurma özelliği ile maksimum 80 epok boyunca eğitilerek 0.8077 F1 değerini almıştır. YOLOv8s modeli ince ayar gerektirmeden yüksek F1 değeri elde etmiştir. DeepForest ise ince ayarla yakın performansa ulaşmıştır. Bu durumda mevcut algoritmaların kent özelindeki veri setleriyle beslendiğinde ve yerel koşullara adapte edildiğinde, sokak ağaçlarının karmaşık yapısını daha iyi kavrayabileceğini göstermektedir (Stark vd. 2025).

Evrişimli sinir ağları ile bireysel ağaç taç algılama ve sınırlandırmanın sistematik derlemesi isimli çalışmada, bireysel ağaç düzeyinin ve taç yapılarının algılanması, orman yönetimi çalışmaları için ayrıntılı bilgi vermektedir. Makalede taç sınırlandırma yaklaşımları önerilmiştir. Evrişimli sinir ağları ile, bireysel ağaç taç algılama görevlerinde

belirgin yetkinlik sağladığı RGB görüntülerinde F1 skorunda yüzde 11 ile 30'a varan iyileştirmelerin yapılabileceği ve 35 makale kapsamlı analize tabi tutularak incelendiğinde, çalışmanın 26 sınıf RGB görüntüler olduğunu ve 24 çalışmada İHA tercih edildiği analiz edilmiştir. Ortalama yer örnekleme mesafesinin 24 İHA çalışmasında 4,69 cm civarında olduğunu, 9 hava platformu çalışmasında 15 cm ve 2 uydu platformu çalışmasında ise 50 cm'dir. Ve çözünürlüğe bağlı, doğruluğun doğru orantılı bir çalışmanın ortalaması olarak şekilde değiştiği gözlemlenmiştir. Çalışma alanının 15 adeti plantasyon, 9'u doğal orman, 6'sı kentsel orman ve 5 karışık orman dokusunun olduğu tespit edilmiştir. Orman ortamının etkisi açısından performansı en çok etkileyen 3 faktör stand yoğunluğu (bitişik/taç çakışması), taç özellikleri (boyut, şekil, renk çeşitliliği) ve arka plan koşulları (çalı, ot, yapay nesneler) olduğu analiz edilmiştir. Veri artırma tekniklerinin (döndürme, çevirme, parlaklık ayarı) model performansına etkisi ise teknik bir parametre ayarı olmanın ötesinde; farklı coğrafyalardaki, mevsimlerdeki ve ışık koşullarındaki ağaçların çeşitliliğini yapay zekâya öğretebilme çabasının bir yansımasıdır ve bu etki ortamın kendine özgü karakteristiği ile seçilen model mimarisinin uyumuyla şekillenmektedir (Zhao vd. 2023).

Yüksek çözünürlüklü havadan, uydu ve yer seviyesi görüntülerde derin öğrenme algoritmaları kullanarak kentsel ağaç tespiti gerçekleştirmiştir. Çalışmada YOLO mimarisi kullanılmış ve sokak ağaçlarının %79'u tespit edilmiştir. Havadan, uydu ve yer seviyesi görüntülerin birlikte kullanılması, tek bir kaynağa göre daha güvenilir sonuçlar vermiştir (Velasquez-Camacho vd. 2023).

Tropikal ormanlarda Mask R-CNN kullanılarak otomatik ağaç tepesi tespiti gerçekleştirilmiştir. Yoğun ve katmanlı yapısıyla yüksek biyokütle yoğunluğu ve karmaşık yapısal katmanlılığına sahip tropikal orman ekosistemlerinde, iki aşamalı dedektörler yüksek doğruluk sağlamış; ancak bu başarı, YOLO gibi tek aşamalı modellere kıyasla daha uzun sürelerde elde edilmiştir. Veri artırma tekniklerinin (çevirme, döndürme, doygunluk) model başarısını etkilediği görülmüştür (Braga vd. 2020).

İHA görüntülerinden liçi ağaçlarının tepesi örnek segmentasyonu YOLACT kullanılarak gerçekleştirilmiştir. YOLO tabanlı bu yaklaşım, gerçek zamanlı işleme kapasitesiyle

çiftçilerin tarlasını anında tarayabilmesini sağlamış ve tarımsal uygulamalarda pratik bir çözüm sunmuştur. Çalışma, YOLO türevi mimarilerin meyve bahçelerinde hızlı sayım ve sürdürülebilir yönetim için kullanılabilirliğini göstermektedir (Mo vd. 2021).

Yüksek çözünürlüklü uzaktan algılama görüntülerinden büyük ölçekli yağ palmyesi tespiti derin öğrenme ile gerçekleştirilmiştir. YOLOv4, %97,74 doğrulukla en iyi performansı göstererek geniş tarla alanlarındaki sayım işlemlerini hızlandırmıştır. Çalışma, YOLO mimarisinin tarımsal ölçekli ağaç envanteri için ölçeklenebilirliğini ortaya koymaktadır (Wibowo vd. 2022).

Koruluk alanlarında ağaç türü sınıflandırması için YOLOv7-KCC modeli önerilmiştir. İHA görüntüleriyle geliştirilen bu model, koordinat tabanlı konvolüsyon ve dikkat mekanizması entegrasyonu ile %98,91 doğruluk sağlamıştır. Çalışma, Çin'in Sincan bölgesindeki koruluk yönetimi için bilimsel temel oluşturmaktadır (Liu vd. 2024).

Uzaktan algılama görüntülerinde küçük nesne tespiti için SEMA-YOLO modeli eğitilmiş. SLE modülü sığ katmanlardaki özellikleri güçlendirirken, GCP-ASFF modülü çok ölçekli tutarsızlıkları azaltmaktadır. 3,6 milyon parametre ve 185 FPS hızla çalışan model, YOLOv8n'e göre sınırlı mAP50 artışı sağlamaktadır. Çalışma, hafif mimari tasarım sunmakla birlikte, ağaç tespiti özelinde uygulanabilirliği sınırlı kalmaktadır (Wu vd. 2025).

Zeytin ağaçlarının İHA görüntülerinden tespit edilmesi amacıyla YOLOv8, YOLOv10, YOLOv11, YOLOv12 ile transformer tabanlı RT-DETR ve RF-DETR modellerinin karşılaştırması yapılmıştır. OTD veri setinde YOLOv11n, YOLOv11s ve YOLOv12s %98,7 mAP oranına ulaşırken, RF-DETR 66,21 FPS ile en düşük performansı göstermiştir. Buna karşılık, YOLOv12 modelleri 185–307 FPS hızında gerçek zamanlı işleme yeteneği sağlamıştır. Araştırmalar, hassas tarım uygulamalarında hafif YOLO modellerinin doğruluk ve hız bakımından transformer tabanlı modellere göre daha üstün olduğunu ortaya koymaktadır (Atik ve Arkali 2026).

YOLOv12, dikkat mekanizmalarını merkeze alan yeni nesil gerçek zamanlı nesne tespit mimarisi olarak önerilmektedir. Model, CNN tabanlı hız ile transformer tabanlı doğruluğu birleştirerek YOLOv10-N ve YOLOv11-N'e kıyasla sırasıyla %2,1 ve %1,2 daha yüksek mAP değerleri sağlamaktadır. Ayrıca YOLOv12-S, RT-DETR-R18'e göre %42 daha hızlı çalışırken yalnızca %36 hesaplama ve %45 parametre kullanmaktadır. Bu sonuçlar, YOLOv12'nin ağaç tespiti dahil olmak üzere uzaktan algılama uygulamaları için güçlü ve verimli bir temel sunduğunu göstermektedir (Tian vd. 2026).

Derin öğrenme modellerinin yüksek performans göstermesi, kaliteli ve kapsamlı eğitim verilerine bağlıdır. Ancak heterojen orman ortamlarında bireysel ağaç taçlarının manuel segmentasyonu; spektral benzerlikler ve taç örtüşmeleri nedeniyle zaman alıcı ve hataya açıktır (Grondin vd. 2023).

Bazı durumlarda, insan gözüyle bile net sınırlar çizmek zorken, modellerden kusursuz bir kesinlik beklemek pek de gerçekçi olmaz. Bunun yanı sıra, farklı coğrafi alanlar ve orman türleri için genel geçerliliği olan veri setleri oluşturmak da önemli bir zorluk teşkil etmektedir (Zhao vd. 2023).

Doğal ortamlar, ağaç tespiti için kullanılan görüntü verilerinde önemli değişkenliklere neden olur;

Gölgeler ve Işıklandırma: Görüntülerdeki gölgelenme ve ışıklandırma, güneş ışığının açısı, bulutluluk oranı ve arazinin topoğrafik yapısı gibi çeşitli etkenlerden etkilenir. Özellikle yoğun gölgeler, ağaç sınırlarını belirsizleştirebilir veya gölgelerin kendileri hatalı bir şekilde ağaç olarak yorumlanabilir. Bu tür durumlar, modelin genel sağlamlığını (robustluğunu) olumsuz yönde etkileyebilir (Xu vd. 2025).

Mevsimsel Değişimler: Yaprak döken ağaçların mevsimlere göre gösterdiği belirgin farklılıklar (örneğin, yazın yeşil yapraklı olmaları, kışın ise yapraksız kalmaları), modellerin farklı mevsimlerde genelleme yapma kabiliyetini önemli ölçüde kısıtlamaktadır. Bir mevsimde eğitilmiş bir modelin, farklı bir mevsimde aynı düzeyde başarı sergilemesi beklenmemelidir (Xu vd. 2025).

Farklı ağaç türleri, özellikle RGB görüntülerde, benzer renk ve doku özelliklerine sahip olabilir. Bu spektral benzerlik, derin öğrenme modellerinin türler arasında ayırım yapmasını veya hatta bireysel ağaçları genel bitki örtüsünden ayırmasını zorlaştırır. Model, görsel olarak ayırt edilemeyen ağaçları yanlış sınıflandırabilir veya tek bir ağaç olarak algılayabilir. Bu durum, özellikle tür bazında kesin ağaç tespiti gerektiren uygulamalarda önemli bir sınırlama oluşturur (Huang vd. 2024).

Ağaçlar, boyut ve şekil açısından büyük farklılıklar gösterebilir; genç fidanlardan devasa yaşlı ağaçlara kadar geniş bir ölçek aralığı mevcuttur. Derin öğrenme modelleri, farklı ölçeklerdeki nesneleri etkili bir şekilde tespit etmek için çok ölçekli özellik çıkarımına ihtiyaç duyar. Ancak, küçük ağaçlar veya uzaktan çekilen görüntülerdeki ağaçlar, modelin alıcı alanından daha küçük piksellerle temsil edilebilir. Bu durum, modelin küçük nesnelerden yeterli bağlamsal bilgi çıkaramamasına ve "özellik bulanıklığına" (feature blurring) yol açarak tespit doğruluğunu düşürmesine neden olabilir (Wang vd. 2021).

3. DERİN ÖĞRENME

Yapay zekâ (IA) araştırmaları, insan zihinsel süreçlerini simüle etme (taklit etme) veya replike etme (aynı içsel süreçlerle kopyalama) hedefleri arasında bölünmüştür. Günümüzde derin öğrenme olarak adlandırılan yaklaşımların temelini oluşturan bağlantıcılık (connectionism), zihni sembolleri manipüle eden bir mekanizma olarak değil, beyni taklit eden bir sinir ağı olarak görür. Fetzer'e göre, klasik sıralı dijital makinelerin zihinsel süreçleri kopyalamadaki yetersizliği, bağlantıcı mimarilerin geliştirilmesiyle aşılabılır bir engel haline gelmiştir (Fetzer 1990).

Yapay zekâ alanındaki en dönüştürücü gelişmelerden biri olan derin öğrenme, bilgisayarların büyük veri setlerinden otomatik olarak özellik çıkarımı yapmasını ve karmaşık kalıpları tanımasını sağlayan bir metodoloji olarak öne çıkmaktadır (LeCun vd. 2015).

Derin öğrenme, "derin" sıfatını, veriyi işlemek için kullanılan çok sayıda gizli katman (hidden layer) içermesinden almaktadır. Bu katmanlar, verinin hiyerarşik olarak temsil edilmesine olanak tanıyarak, basit özelliklerin birleşerek daha karmaşık kavramlara dönüşmesini sağlar (Goodfellow vd. 2016).

Derin öğrenmenin kökleri 1940'lara dayanmaktadır. Biyolojik nöronların matematiksel modellenmesi üzerine yaptıkları çalışmalarla yapay sinir ağlarının teorik temellerini atmışlardır. Ancak, bu alandaki gerçek potansiyel, hesaplama gücünün artması, büyük veri setlerinin kullanılabilirliği ve algoritmik gelişmeler sayesinde 2010'lu yıllarda ortaya çıkmıştır (Schmidhuber 2015).

Derin öğrenmenin tarihi, yapay zekanın evrimiyle birlikte şekillenmiş. İlk büyük adım, 1965'te Ivakhnenko ve Lapa'nın ortaya attığı denetimli derin beslemeli perceptron mimarisiydi. Bu çalışma, derin öğrenme yöntemlerinin temellerini atmış ve aslında bu alandaki gelişimin önemli bir parçası haline gelmiş. Yani, o dönemden itibaren derin öğrenme ile ilgili pek çok kapı açılmış oldu. (Schmidhuber 2015).

1979 yılında Fukushima, denetimsiz öğrenme prensiplerinden yararlanarak Neokognitron adını verdiği bir mimari geliştirmiştir. Bu yaklaşım, omurgalıların görsel sinir sisteminden esinlenmiş olup, modern derin ağlara benzer şekilde çok katmanlı bir yapıya sahiptir. Böylece, görsel verilerin hiyerarşik biçimde işlenmesine olanak tanımış ve günümüzdeki evrişimli sinir ağlarının öncüsü olarak kabul edilmiştir. (Fukushima 1980). Bu mimari, omurgalıların görsel sinir sisteminden esinlenerek tasarlanmıştır. Çok katmanlı yapısı sayesinde görsel bilgiyi hiyerarşik biçimde işleyebilmiş ve böylece modern derin öğrenme ağlarının temel özelliklerini önceden ortaya koymuştur. Bu yaklaşım, günümüzde evrişimli sinir ağlarının gelişiminde önemli bir dönüm noktası olarak kabul edilmektedir.

1988 yılında, Yann LeCun tarafından LeNet adlı ilk başarılı CNN mimarisi geliştirilmiştir (LeCun 1989).

LeNet, el yazısı rakam tanıma görevinde başarılı sonuçlar elde etmiş ve pratik uygulamalarda kullanılmıştır. 1997 yılında, Hochreiter ve Schmidhuber tarafından Uzun Kısa Vadeli Bellek (LSTM) mimarisi önerilmiştir. LSTM, tekrarlayan sinir ağlarının uzun vadeli bağımlılıkları öğrenme sorununu çözmüştür (Hochreiter ve Schmidhuber 1997).

2006 yılında Geoffrey Hinton ve çalışma arkadaşları, derin sinir ağlarının daha etkin biçimde eğitilebilmesi için ön-eğitim (pre-training) yöntemini ortaya koymuştur (Hinton vd. 2006).

Bu yaklaşım, her katmanın ayrı eğitilmesi sayesinde derin ağların öğrenme sürecini kolaylaştırmıştır. Ardından, 2012’de GPU teknolojisinin kullanımı ve dropout regularizasyon tekniğinin uygulanmasıyla derin öğrenme, ImageNet yarışmasında dikkat çekici başarılar elde etmiştir (Krizhevsky vd. 2012).

Bu gelişmeler, derin öğrenmeye yönelik ilgiyi küresel ölçekte hızla artırmış ve alanın dönüm noktalarından biri olarak kabul edilmiştir.

Bu yöntem, her katmanı ayrı eğiterek, derin ağların eğitimini daha verimli hale getirmiştir. 2012 yılında, GPU teknolojisinin kullanılması ve dropout regularizasyon tekniğinin uygulanmasıyla, derin öğrenme ImageNet yarışmasında önemli başarılar elde etmiştir (Krizhevsky vd. 2012).

Bu başarı, derin öğrenmeye olan ilgiyi önemli ölçüde artırmıştır

3.1 Derin Öğrenme Süreçleri

Çok katmanlı yapay sinir ağı mimarilerine dayanan derin öğrenme paradigması, geniş hacimli veri kümeleri üzerinde çok boyutlu temsil öğrenimi gerçekleştirerek, makine öğrenimi literatüründe ayrı bir uzmanlık dalı olarak konumlanmaktadır. Söz konusu yaklaşım, veri içindeki doğrusal olmayan ve yüksek düzeyli bağıntıları modelleme kapasitesiyle karmaşık örüntülerin keşfedilmesine olanak tanımaktadır. (Akın vd. 2024)

Derin öğrenme süreçleri, karmaşık verileri daha derinlemesine anlamlandırmak için güçlü bir yöntem sunar. Veri toplama, uygun modelin seçilmesi, eğitim, değerlendirme ve dağıtım gibi aşamalar, bu yöntemlerin başarıyla uygulanmasında kritik rol oynar. Gelecekte bu süreçlerin daha da geliştirilmesi, yenilikçi çözümlerin ortaya çıkmasına ve derin öğrenmenin farklı alanlarda daha etkin kullanılmasına olanak sağlayacaktır (Ünsal vd. 2024).

Derin öğrenme süreçleri;

- Veri Toplama ve Ön İşleme
- Model Seçimi ve Tasarımı
- Model Eğitimi
- Model Değerlendirmesi
- Modelin Dağıtım ve Uygulama,

Olarak tanımlayabiliriz.

3.1.1 Veri Toplama ve Ön İşleme

Derin öğrenme modellerinin uygulanmasında en kritik adım, doğru verinin toplanmasıdır. Veriler elde edildikten sonra, bunların işlenmesi gerekir. Bu aşamada yapılan veri temizliği, normalizasyon ve özellik mühendisliği gibi işlemler, modelin performansını doğrudan belirler ve sonuçların güvenilirliğini artırır (Krawczyk 2016).

3.1.2 Model Seçimi ve Tasarımı

Derin öğrenmede kullanılacak modelin seçimi, ele alınan problemin niteliğine bağlıdır. Örneğin, konvolüsyonel sinir ağları (CNN) özellikle görüntü işleme görevlerinde öne çıkarken; tekrarlayan sinir ağları (RNN) ise zaman serisi verilerinin analizinde güçlü bir performans sergiler (LeCun vd.2015).

Model tasarımında, katmanların sayısı, her katmandaki nöronların miktarı ve kullanılacak aktivasyon fonksiyonları gibi temel unsurların dikkatle belirlenmesi gerekir. Bu seçimler, modelin öğrenme kapasitesini ve elde edilecek sonuçların doğruluğunu doğrudan etkiler.

3.1.3 Model Eğitimi

Model eğitimi, veri kümesi üzerinden öğrenmenin gerçekleştiği süreçtir. Bu aşamada, geriye yayılım algoritması kullanılarak ağırlıklar güncellenir (Rumelhart vd. 1986).

Aşırı öğrenmeyi önlemek için ise farklı stratejiler devreye girer; örneğin erken durdurma veya düzenleme teknikleri, modelin genelleme yeteneğini korumada önemli rol oynar (Srivastava vd. 2014).

3.1.4 Model Değerlendirmesi

Bir modelin başarımını değerlendirmek için test verisi kullanılır. Bu aşamada doğruluk, kesinlik ve hatırlama gibi metrikler aracılığıyla performans ölçülür (Sokolova vd. 2009).

Hangi metriklerin tercih edileceği ise, hedeflenen uygulamanın özelliklerine ve ihtiyaçlarına bağlıdır.

3.1.5 Modelin Dağıtımı ve Uygulama

Model eğitimi tamamlandı ve test sonuçları başarılı. Bundan sonraki aşama, modeli gerçek kullanım ortamlarına aktarmaktır. Ancak bu süreç, yalnızca bilgisayarda çalıştırmaktan ibaret değildir. Sahada, örneğin bir drone üzerinde veya bir sunucu altyapısında çalıştırmak, farklı gereksinimler ve uyarlamalar gerektirir. Biz çalışmamızda Python kodları ile ağaç tespiti yaptık. Basit bir arayüz üzerinden görüntü yükleniyor ve sistem ağaç sayısını veriyor.

Ayrıca unutulmamalıdır ki modeller statik değildir. Dünya sürekli değişir: mevsimler döner, ağaçlar büyür, yeni yapılar inşa edilir. Bu nedenle model zamanla güncelliğini yitirebilir. Etkin bir güncelleme mekanizması, modelin uzun vadede güvenilirliğini koruması için şarttır.

3.2 Nesne Tanıma Algoritmaları

Zeytin bahçelerinde hastalık tespiti, ağaç sayımı veya verim tahmini gibi işlemlerin otomatikleştirilebilmesi için öncelikle İHA görüntülerindeki her bir ağacın konumunun bilinmesi gerekir. Nesne tespiti tam olarak bu ihtiyacı karşılar; model görüntüdeki nesnenin sınırlarını çizen bir kutu üretirken, aynı anda bunun zeytin ağacı olduğunu da etiketler. Bilgisayarlı görme literatüründe bu ikili görev yerleştirme ve sınıflandırma otonom sistemlerden tarımsal sayıma kadar geniş bir yelpazede uygulanmaktadır (Trigka vd. 2025).

3.2.1 Derin Öğrenme Tabanlı Yöntemler

Bilgisayarla görme, görüntü ve video verilerinden anlamlı bilgiler elde etmeyi amaçlayan bir araştırma alanıdır. Uzun yıllar boyunca SIFT, SURF ve HOG gibi klasik yöntemler nesne tanıma ve görüntü eşleştirme görevlerinde yaygın olarak kullanılmıştır. Bu yöntemler ölçek, dönüş ve aydınlatma farklılıklarına karşı belirli bir dayanıklılık gösterse

de, yüksek hesaplama maliyetleri ve sınırlı doğrulukları nedeniyle günümüzde derin öğrenme tabanlı yaklaşımların gerisinde kalmıştır.

Derin öğrenme; makine öğrenmesi, yapay zekâ ve büyük veri disiplinlerinin kesişiminde ortaya çıkan bir paradigmadır. Çok katmanlı mimariler, ham veriyi katmanlar halinde dönüştürerek soyut temsiller oluşturma kapasitesine sahiptir. Paralel işlem birimlerindeki verimlilik artışı ve dijital veri hacmindeki katlanmalı büyüme, bu mimarilerin pratikte devreye girmesini hızlandırmıştır. Örneğin evrimsel ağlar görüntü analizinde, tekrarlayan yapılar zaman dizilerinde etkinlik gösterir; her iki mimari de otonom karar sistemlerine entegre edilmiştir. Geleneksel yöntemlerin ulaşamadığı doğruluk düzeylerine erişen bu teknoloji, tıbbi görüntülemeye doğal dil anlamaya kadar geniş bir yelpazede kullanılmaktadır (LeCun vd. 2015).

Çok katmanlı ağ mimarileri pratikte etkin sonuçlar verse de, eğitim için devasa etiketli veri gereksinimi, modelin karar süreçlerinin izlenebilirliği, GPU saat maliyetleri ve veri merkezi enerji harcamaları gibi engeller ön plana çıkmaktadır. Bu sorunların üstesinden gelmeye yönelik çalışmalar; açıklanabilirliği artırılan modeller, cihaz üzerinde çalışan hafif mimariler ve merkezi olmayan eğitim protokolleri gibi yönelimleri beraberinde getirmektedir. Söz konusu ilerlemeler, derin öğrenmenin sadece büyük teknoloji şirketlerinin kaynaklarına değil, daha dar bütçeli araştırma ortamlarına da açılmasını mümkün kılacaktır. (LeCun vd. 2015).

Derin öğrenme, dördüncü endüstriyel devrim (Endüstri 4.0) çağında akıllı ve otonom sistemlerin geliştirilmesinde temel bir yapı taşı olarak öne çıkmaktadır. Bu teknolojinin gelecekte daha da gelişmesi ve farklı disiplinlere uygulanması, bilim ve teknoloji dünyasında yeni olanaklar ve fırsatlar doğuracaktır (Mazzei ve Ramjattan 2022).

Derin öğrenme tabanlı yöntemler şunlardır;

- R-CNN
- Fast R-CNN
- Faster R-CNN

- Mask R-CNN
- YOLO (You Only Look Once)
- SSD (Single Shot MultiBox Detector)
- Transformers (DETR)

3.2.1.1 YOLO (You Only Look Once)

Nesne algılama, bilgisayarla görme alanının temel araştırma problemlerinden biri olarak öne çıkmaktadır. Bu yöntem, otonom sistemler ve akıllı uygulamalarda yaygın biçimde kullanılmakta olup, çevresel verilerin anlamlandırılmasında kritik bir rol üstlenmektedir (Girshick 2015).

Geleneksel nesne algılama modelleri, örneğin SSD veya Faster R-CNN, bölge önerisi ve sınıflandırma aşamalarını içeren çok adımlı bir süreçle çalışmaktadır. Buna karşılık Detection Transformer (DETR), transformer mimarisini kullanarak bu süreci sadeleştirmekte ve nesne algılamayı uçtan uca bir öğrenme problemine dönüştürmektedir (Carion vd. 2020).

You Only Look Once (YOLO) serisi, 2015 yılında tanıtılmasının ardından gerçek zamanlı nesne tespiti alanında önemli bir dönüm noktası olmuştur. Tek aşamalı (one-stage) mimarisi sayesinde nesne tespitini tek bir regresyon problemi olarak ele alan YOLO, hız ve doğruluk arasında dikkat çekici bir denge kurmuştur. YOLOv1'den başlayarak en güncel sürüm olan YOLOv26'ya kadar uzanan tarihsel gelişim süreci, her bir versiyonun getirdiği mimari yenilikler ve bilgisayarla görme alanındaki dönüştürücü etkileriyle incelenmiştir.

Nesne tespiti, otonom sistemler, video gözetimi ve tıbbi görüntüleme gibi pek çok uygulama için kritik bir öneme sahiptir (Sapkota vd. 2025).

Geleneksel olarak nesne tespit algoritmaları, R-CNN serisi gibi iki aşamalı yaklaşımlar aracılığıyla yüksek doğruluk elde etmeye çalışmış, ancak bu yöntemler genellikle yavaş işlem süreleriyle sınırlı kalmıştır. YOLO ise bu paradigmaya meydan okuyarak, bölge

önerisi adını ortadan kaldıran ve tüm tespit sürecini tek bir sinir ağı geçişinde gerçekleştiren ilk tek aşamalı dedektör olarak literatürde yerini almıştır (Redmon vd. 2016).

YOLO'nun bu yenilikçi yaklaşımı, gerçek zamanlı uygulamaların gelişmesine önemli ölçüde katkı sağlamıştır. Serinin on yılı aşkın evrimi, hız, doğruluk (mAP) ve hesaplama verimliliğini sürekli artırma arayışıyla şekillenmiştir. Her yeni sürüm, önceki versiyonların sınırlamalarını aşmayı hedefleyen mimari iyileştirmeler sunmuş ve nesne tespiti alanında kayda değer ilerlemeler ortaya koymuştur (Sapkota vd. 2025).

3.2.1.1.1 RT-DETR

Nesne tespiti, bilgisayarlı görü çalışmalarında görüntülerdeki ilgili nesneleri sınırlayıcı kutular ve kategori etiketleriyle konumlandırma işlemi olarak tanımlanmaktadır (Zhao vd. 2019).

Derin öğrenme tabanlı yöntemler, kendiliğinden özellik çıkarımı ve uçtan uca eğitim olanağı sunarak geleneksel yaklaşımlara göre temel bir dönüşüm yaratmıştır. Mimari yapılarına bakıldığında, nesne tespit modelleri genel olarak iki sınıfa ayrılmaktadır: iki evreli (two-stage) ve tek evreli (single-stage) dedektörler (Girshick vd. 2014).

R-CNN ailesi, iki evreli yöntemin temsilcisi olup; öncelikle olası bölgeleri önermekte, akabinde bu alanları sınıflandırmaktadır (Ren vd. 2015).

Buna karşın YOLO (You Only Look Once) ailesi, görüntüyü tek seferde işleyerek hem yer tahminleri hem de sınıf olasılıklarını eşzamanlı üreten tek evreli bir yapıya sahiptir (Redmon vd. 2016).

Günümüzde gerçek zamanlı çalışan dedektörler çoğunlukla Evrişimsel Sinir Ağı tabanlı YOLO mimarilerine dayanmaktadır; ancak bu sistemler çıkarım aşamasında Non-Maximum Suppression (NMS) işlemine muhtaçtır. NMS, yalnızca işlem hızını

düşürmekle kalmayıp, doğruluk ve hız üzerinde dalgalanmalara neden olan ayarlanabilir parametreler barındırmaktadır (Zhao vd. 2024).

Son dönemde, uçtan uca Transformer mimarili dedektörler (DETRs), elle tasarlanmış anchor ve NMS bileşenlerini devre dışı bırakarak ilgi görmüştür (Carion vd. 2020).

Fakat bu modellerin ağır hesaplama yükü, onları gerçek zamanlı kullanım için uygun kılmamaktadır. Bu açığı kapatmak üzere Zhao vd. (2024), RT-DETR (Real-Time Detection Transformer) mimarisini önermiş; bu model, bilinen ilk gerçek zamanlı uçtan uca nesne tespit çözümü olarak öne çıkmaktadır.

RT-DETR, verimli hibrit kodlayıcı (Efficient Hybrid Encoder) ve belirsizliği en aza indiren sorgu seçimi (Uncertainty-Minimal Query Selection) gibi bileşenleri sayesinde NMS kullanımını ortadan kaldırmakta; böylece hem çalışma hızı hem de doğruluk bakımından YOLO serisini geçmektedir. Hibrit kodlayıcı, farklı ölçeklerdeki özelliklerin içsel etkileşimi ile ölçekler arası birleştirmeyi ayrı aşamalarda gerçekleştirerek hızlı çok ölçekli işlemeyi sağlamaktadır. AIFI (Attention-based Intra-scale Feature Interaction) birimi, üst düzey özellikler üzerinde dikkat mekanizması işletirken; CCFF (CNN-based Cross-scale Feature Fusion) birimi, çok ölçekli temsilleri verimli şekilde kaynaştırmaktadır (İnt. Kyn. 1).

Belirsizliği minimal sorgu seçimi ise, kod çözücüye nitelikli başlangıç sorguları sunarak tahmin isabetini yükseltmektedir. Esnek hız denetimi özelliği, kod çözücü katman adedinin değiştirilmesine imkân tanıyarak çeşitli donanım ortamlarına ve kullanım senaryolarına adapte olmayı mümkün kılmaktadır (Zhao vd. 2024).

3.2.1.1.2 YOLOv3

Nesne tespiti, bilgisayarlı görü alanında görüntülerdeki ilgili nesnelerin konumlarını sınırlayıcı kutular (bounding boxes) ve sınıf etiketleri ile belirleme süreci olarak tanımlanmaktadır (Zhao vd. 2019).

Derin öğrenme tabanlı yaklaşımlar, otomatik özellik çıkarımı ve uçtan uca eğitim imkânı sunarak geleneksel yöntemlere kıyasla köklü bir paradigma değişikliği yaratmıştır. Nesne tespiti modelleri, mimari yapılarına göre iki ana kategori altında incelenmektedir: iki aşamalı (two-stage) ve tek aşamalı (single-stage) dedektörler (Girshick vd. 2014).

R-CNN ailesi; iki aşamalı yaklaşımın temsilcisi olup, önce bölge önerileri oluşturmakta ardından sınıflandırma gerçekleştirmektedir (Ren vd. 2015).

Buna karşın, YOLO (You Only Look Once) ailesi, görüntüyü tek bir geçişte işleyerek hem bölgesel tahminler hem de sınıf olasılıkları üreten tek aşamalı bir paradigma benimsemektedir (Redmon vd. 2016).

YOLOv3 mimarisi üç temel bileşenden oluşmaktadır

Darknet-53 özellik çıkarıcı omurga ağı

Çok ölçekli tespit başlıkları (detection heads)

Önceden tanımlı anchor box'lar üzerinden regresyon ve sınıflandırma mekanizması

YOLOv3'ü modern uygulama ekosistemine entegre etmek üzere üç varyant sunmaktadır:

YOLOv3u, YOLOv3-Tinyu ve YOLOv3-SPPu. İsimdeki "u" ifadesi, bu modellerin YOLOv8'deki anchor-free ve objectness-free ayrık başlık (split head) yapısını kullandığını belirtmektedir. YOLOv3u, orijinal Darknet-53 omurga ve neck mimarisini korurken, tespit başlığını YOLOv8'den alınan modern tasarımla güncellemektedir. Bu güncelleme, önceden tanımlanmış anchor box'lara ve nesnelik skorlarına olan ihtiyacı ortadan kaldırarak farklı boyut ve şekillerdeki nesneleri daha hassas tespit etme yeteneğini artırmaktadır. YOLOv3-Tinyu, kaynak kısıtlı ortamlar için optimize edilmiş hafif bir varyant olup, düşük hesaplama gücüne sahip cihazlarda dağıtım imkânı sunmaktadır. Ultralytics ekosistemi, bu modeller için çıkarım, eğitim, doğrulama ve dışa aktarma modlarıyla kapsamlı bir model yaşam döngüsü yönetimi sağlamaktadır (İnt. Kyn. 2).

3.2.1.1.3 YOLOv5

Nesne tespiti, görüntülerdeki nesnelerin konumlarını ve sınıflarını belirleme görevi olarak tanımlanmaktadır (Zhao vd. 2019).

Son yıllarda derin öğrenme tekniklerindeki gelişmeler, bu alanda kayda değer ilerlemeler sağlamıştır. Özellikle tek aşamalı dedektörler arasında yer alan YOLO ailesi, gerçek zamanlı uygulamalarda yüksek hız ve kabul edilebilir doğruluk sunması nedeniyle yaygın biçimde tercih edilmektedir (Redmon vd. 2016).

Derin öğrenme tabanlı nesne algılama sistemleri, otonom araçlardan akıllı gözetim teknolojilerine kadar geniş bir uygulama alanına sahiptir. Bu alanda tek aşamalı (one-stage) dedektörler, hesaplama verimliliği ve gerçek zamanlı işleme kapasitesi nedeniyle öne çıkmaktadır. "You Only Look Once" (YOLO) mimarisi, bu paradigmanın en temsilcisi örneklerinden biri olup, Ultralytics tarafından PyTorch framework üzerinde geliştirilen YOLOv5 versiyonu, yüksek hız ve doğruluk oranları sunan modern bir nesne algılama modelidir (İnt. Kyn. 17).

YOLOv5, CSPDarknet53 omurga (backbone) mimarisi, Path Aggregation Network (PANet) özellik çıkarım katmanları ve dinamik öngörü başlığı üzerine kuruludur. Model, çok ölçekli nesne algılama yeteneği sunar ve AutoAnchor algoritması ile veri setine özgü optimum çapa kutularını otomatik olarak hesaplar. Ayrıca Mosaic veri artırma teknikleri ve karma (mixup) stratejileri ile genelleme kapasitesini artırır (Jaiswal ve Agrawal 2024).

YOLOv5 ailesi; nano (n), small (s), medium (m), large (l) ve extra large (x) olmak üzere beş farklı kapasitede model sunar. Bu varyant sayesinde uçtan uca uygulamalardan gömülü sistemlere kadar geniş bir donanım yelpazesine uyum sağlanabilir (İnt. Kyn. 17).

YOLOv5, farklı alanlarda kendini kanıtlamıştır. Örneğin, otonom sürüş sistemlerinde küçük nesnelerin algılanması için optimize edilmiş versiyonlar geliştirilmiş ve yüksek başarımlar elde edilmiştir (Mahaur ve Mishra 2023).

Benzer şekilde, insansız hava araçlarından (drone) elde edilen görüntülerde, çeşitli çevresel koşullar altında verimli nesne algılama için model iyileştirmeleri yapılmıştır (Jung ve Choi 2022).

Kızılötesi görüntüleme gibi özel spektral alanlarda da YOLOv5 tabanlı geliştirmeler, düşük ışık koşullarında güvenilir nesne tespiti sağlamaktadır (Li vd. 2021).

3.2.1.1.4 YOLOv6

2022’de Meituan Inc.’in görüntü işleme birimi tarafından geliştirilen YOLOv6, tek aşamalı nesne algılama mimarisiyle endüstriyel senaryolar için özel optimizasyonlar sunuyor. YOLO (You Only Look Once) ailesinin en yeni üyelerinden biri olan bu model, gerçek zamanlı işleme gerektiren ortamlarda doğruluk ve çıkarım hızı arasında mükemmel bir denge sağlamayı amaçlıyor. Kısıtlı hesaplama gücünün olduğu ve düşük gecikmenin hayati öneme sahip olduğu endüstriyel ekosistemler düşünülerek tasarlanan bu yapı, yenilikçi mimari ve eğitim protokolleri ile literatürde kendine has bir yer edinmiş durumda. COCO veri kümesindeki başarıları ve NVIDIA T4 grafik işlemci üzerindeki yüksek kare başına işlem hızı (FPS) ile nesne algılama alanında önemli bir referans noktası haline gelmiş. Bu model, akademik literatürdeki en güncel teknik gelişmeleri endüstriyel uygulamaların ihtiyaçlarıyla harmanlayarak hem yüksek doğruluk hem de düşük gecikme süresi sunan bir algılama altyapısı oluşturmayı hedefliyor. Bu özellikler de onu otonom sürüş sistemlerinden akıllı görüntüleme platformlarına, perakende analitik uygulamalarından üretim hatlarındaki kalite kontrol süreçlerine kadar pek çok alanda tercih edilen bir seçenek haline getiriyor (İnt. Kyn. 3).

Mimari açıdan bakıldığında, YOLOv6; Omurga (Backbone), Boyun (Neck) ve Algılama Başı (Head) olarak adlandırılan üç ana katmandan oluşuyor. Ancak her bir bileşendeki özgün tasarım tercihleri, bu versiyonu diğer aile üyelerinden ayıran belirleyici unsurlar olarak dikkat çekiyor.

Omurga (Backbone): YOLOv6, özellikle küçük modeller için RepBlock (Reparameterized Block) kullanan EfficientRep adı verilen yeniden parametrelenebilir

bir omurga yapısı kullanmaktadır. Eğitim aşamasında çok dallı yapıya sahip olan bu bloklar, çıkarım (inference) aşamasında basit 3x3 konvolüsyon katmanlarına (RepConv) dönüştürülmektedir. Bu teknik, eğitim sırasında daha zengin özellik temsilleri öğrenilmesini sağlarken, çıkarım sırasında hesaplama maliyetini önemli ölçüde azaltmaktadır. Orta ve büyük boyutlu modellerde ise CSPStackRep adı verilen CSP (Cross Stage Partial) tabanlı yeniden parametrelenebilir omurga kullanılmaktadır. Bu yapı, özellik çıkarım kapasitesini artırırken hesaplama verimliliğini korumaktadır (İnt. Kyn. 4).

Boyun (Neck): Modelin boyun kısmında, çok ölçekli özellik haritalarını birleştirmek için Rep-PAN (Reparameterized Path Aggregation Network) kullanılmaktadır. Bu yapı, farklı ölçeklerdeki özelliklerin etkili bir şekilde birleştirilmesini sağlamaktadır. YOLOv6'nın en dikkat çekici yeniliklerinden biri olan BiC (Bi-directional Concatenation) modülü de bu bölgede yer almaktadır. BiC modülü, yerelleştirme sinyallerini güçlendirerek modelin nesnelerin konumlarını daha doğru bir şekilde belirlemesine yardımcı olmakta ve bunu yaparken hız kaybını minimum düzeyde tutmaktadır. Ayrıca, SimCSPSPF (Simplified CSP Spatial Pyramid Pooling Fast) bloğu, farklı alıcı alan boyutlarından bilgi toplayarak özellik temsili zenginleştirmektedir (İnt. Kyn. 4).

Algılama Başı (Head): YOLOv4 ve YOLOv5'te kullanılan bağlı (coupled) baş yapısının aksine, YOLOv6 Efficient Decoupled Head kullanılmaktadır. Bu yapıda sınıflandırma ve regresyon (konum belirleme) dalları birbirinden ayrılmakta ve omurgadan bağımsız olarak dallanmaktadır. Bu ayırım, hesaplama yükünü azaltmakta ve her iki görev için daha optimize edilmiş özellik temsilleri öğrenilmesini sağlamaktadır (İnt. Kyn. 4).

YOLOv6, endüstriyel nesne algılama alanında önemli bir kilometre taşı olarak değerlendirilebilir. Model, yeniden parametrelenebilir omurga yapısı, BiC modülü, AAT stratejisi ve kendi kendine damıtma teknikleriyle hem hız hem de doğruluk açısından güçlü bir performans sergilemektedir. Özellikle TensorRT optimizasyonu ile NVIDIA donanımlarında yüksek verimlilik sunması, endüstriyel uygulamalarda tercih edilmesini sağlamaktadır. Ancak modelin geleneksel NMS (Non-Maximum Suppression) son işleme adımına ihtiyaç duyması, bazı kısıtlı donanım ortamlarında potansiyel bir darboğaz

oluşturabilmektedir. Bununla birlikte, sunduğu çeşitli model varyantları, kuantizasyon desteği ve mobil optimizasyonlarıyla YOLOv6, gerçek zamanlı nesne algılama görevleri için kapsamlı ve esnek bir çözüm sunmaktadır. Geliştiriciler tarafından sürekli olarak güncellenen ve iyileştirilen bu model, nesne algılama alanında endüstriyel uygulamalar için güvenilir bir tercih olmaya devam etmektedir (İnt. Kyn. 3).

3.2.1.1.5 YOLOv8

Nesne algılama teknolojileri, otonom sistemlerden uzaktan algılamaya kadar modern bilgisayarlı görü uygulamalarının temelini oluşturmaktadır. Bu alanda evrimleşen YOLO (You Only Look Once) ailesinin son temsilcisi olan YOLOv8, Ultralytics tarafından geliştirilen ve önceki versiyonlara kıyasla hem hız hem de doğruluk açısından önemli iyileştirmeler sunan modern bir tek aşamalı (one-stage) dedektördür (İnt. Kyn. 19).

YOLOv8, özellikle gerçek zamanlı uygulamalarda çıkarım hızı ile ortalama kesinlik (mAP) arasındaki dengenin optimize edilmesi hedeflenerek tasarlanmıştır (Varghese ve Sambath 2024).

YOLOv8, mimari olarak kökten yeniden tasarlanmış bir yapıya sahiptir. Model, anlamsal segmentasyon (instance segmentation) yeteneklerini de bünyesinde barındıran evrensel bir çerçeve sunar ve nesne algılama görevlerinde çok ölçekli özellik çıkarımı için optimize edilmiştir (Varghese ve Sambath 2024).

YOLOv8'in omurga (backbone) yapısında yer alan C2f modülü, önceki versiyonlardaki C3 birimine kıyasla gradyan akışını iyileştiren ve daha zengin bir özellik temsili sunan bir tasarıma sahiptir. Bu mimari tercih, modelin parametre verimliliğini artırırken algılama başarımını olumlu yönde etkilemektedir. Diğer yandan, YOLOv8 anchor-free (çapasız) bir dedektör mimarisi benimsemektedir. Söz konusu bu yaklaşım, önceden tanımlanmış çapa (anchor) kutularına dayalı yöntemlerin veri setine özgü ayar gereksinimi ve genelleme kapasitesindeki sınırlılıklar gibi dezavantajlarını minimize ederek, modelin farklı veri dağılımlarına ve görsel senaryolara daha etkin adapte olmasını sağlamaktadır (Rasheed ve Zarkoosh 2025).

AutoAnchor gibi mekanizmalar yerine, doğrudan nesne merkezlerini tahmin eden bir başlık yapısı kullanır.

YOLOv8'in temel mimarisi, çeşitli uygulama alanlarına özgü zorlukların üstesinden gelmek amacıyla birçok araştırmacı tarafından iyileştirilmiştir. Uzaktan algılama görüntülerinde küçük ve çok ölçekli nesnelerin tespiti için YOLO-SE ağı geliştirilmiş ve mevcut yöntemlere kıyasla üstün performans sergilemiştir (Wu ve Dong 2023).

Benzer şekilde, kamera sensörleri üzerinden yapılan küçük nesne algılamada DC-YOLOv8 algoritması, uzak mesafedeki nesnelerin doğru tespiti için özel optimizasyonlar içermektedir (Lou vd. 2023).

Otonom araçlar için geliştirilen YOLOv8-QSD ise küçük nesne algılama yeteneğini artırarak karmaşık trafik senaryolarında daha güvenilir sonuçlar sunmaktadır (Wang vd. 2024c).

3.2.1.1.6 YOLOv9

Nesne algılama, bilgisayarlı görü alanında en temel ve en yoğun araştırılan konulardan biridir. Gerçek zamanlı uygulamalarda kullanılan YOLO (You Only Look Once) ailesi, tek aşamalı algılama yaklaşımıyla endüstride yaygın olarak benimsenmiştir (Redmon ve Farhadi 2018).

YOLO serisinin gelişimi boyunca, mimari iyileştirmeler ve optimizasyon teknikleriyle model performansı artırılmaya çalışılmıştır. Ancak derin sinir ağlarının katman derinliği arttıkça gradyan bilgisinin zayıflaması ve giriş verisine ait bilginin bozulması (information bottleneck) gibi yapısal sorunlar süreklilik arz etmektedir (Wang ve Liao 2024b).

YOLOv9, bu temel sorunlara kökten bir çözüm getirmek üzere tasarlanmıştır. Model, PGI ve GELAN olmak üzere iki temel yenilikçi bileşen üzerine kuruludur. PGI, gradyan akışını programlanabilir kılarak derin katmanlarda bilgi kaybını engellerken; GELAN,

hafifletilmiş ve ölçeklenebilir bir omurga yapısı sunarak hesaplama verimliliğini artırmaktadır.

YOLOv9'un mimarisi üç ana bileşenden oluşmaktadır:

GELAN omurga ağı,

PGI modülü

Ve çok ölçekli tespit başlığı.

GELAN, CSPNet (Cross Stage Partial Network) prensiplerini genelleştirerek farklı donanım kaynaklarına uygun esnek bir yapı sunar (Wang ve Liao 2024b).

Bu tasarım, gereksiz hesaplama yükünü azaltırken çok ölçekli özellik temsilini etkin bir şekilde gerçekleştirir.

PGI mekanizması ise ana dal (main branch), yardımcı dal (auxiliary branch) ve çok ölçekli gradyan entegrasyonu olmak üzere üç alt bileşene ayrılır. Ana dal standart ileri beslemeli ağ üzerinden tahmin üretirken; yardımcı dal, tersinir (reversible) mimari özellikleriyle gradyanları doğrudan ilk katmanlara iletir. Bu yapı, derin ağlarda yaşanan gradyan kaybı sorununu kökten çözmektedir (Wang ve Liao 2024b).

3.2.1.1.7 YOLOv10

YOLO serisi, gerçek zamanlı nesne algılama alanında hesaplama maliyeti ile algılama performansı arasındaki dengeyi kurmasıyla öne çıkmaktadır. Ancak önceki sürümlerin çıkarım sonrası aşamasında kullandığı Non-Maximum Suppression (NMS), uçtan uca (end-to-end) dağıtımı engellemekte ve gecikmeyi öngörülemez hale getirmektedir. Bu sorunu kökten çözerek hem çıkarım hızını hem de model kapasitesini artıran YOLOv10'u ortaya koymuştur (Wang vd. 2024a).

YOLOv10'un en belirleyici özelliği, eğitim sırasında çoklu atama (one-to-many, O2M) ve tekil atama (one-to-one, O2O) mekanizmalarını birlikte kullanan tutarlı çift atama stratejisidir. O2M başlığı eğitimde daha yoğun gradyan sağlarken; O2O başlığı çıkarım

sırasında doğrudan eşsiz tahminler üreterek NMS adımını tamamen ortadan kaldırır. Bu sayede CPU üzerinde %43'e varan hız artışı sağlanır (Wang vd. 2024a).

Modelin omurga, boyun ve başlık bileşenleri; verimlilik ve doğruluk perspektiflerinden kapsamlı bir denetimden geçirilmiştir. Omurgada derece-kılavuzlu bloklar (rank-guided blocks), kanalları önem metriğine göre bölerek gereksiz hesaplamayı azaltır. Uzamsal-kanal ayrıştırılmış alt örnekleme (spatial-channel decoupled downsampling), bilgi darboğazlarını önleyerek yaklaşık %20 FLOP azaltımı sağlar. Başlıkta ise ayrıştırılmış (decoupled) çift dal yapısı, sınıflandırma ve regresyon görevlerini ayırarak konumlandırma doğruluğunu dengelemektedir (İnt. Kyn.5).

YOLOv10'un NMS-free yapısı ve düşük gecikmesi, otonom araçlar, akıllı ulaşım sistemleri ve kaynak kısıtlı kenar birimler (edge devices) için elverişli bir zemin oluşturmaktadır. Trafik işareti algılama gibi küçük nesne odaklı alanlarda, ODConv ve EMA-BiFPN gibi modüllerle iyileştirilmiş varyantlar (örn. LTS-YOLOv10) %3,8'e varan mAP artışları elde etmiştir (Zou ve Liu 2025).

3.2.1.1.8 YOLOv11

YOLO serisi, tek aşamalı (one-stage) dedektörler alanında paradigma değiştiren modeller olarak 2016'dan bu yana sürekli evrim geçirmiştir. Ultralytics'in 10 Eylül 2024'te yayınladığı YOLOv11, bu mirası; daha az parametreyle daha yüksek doğruluk, genişletilmiş görev yelpazesi ve kenar birimlerden (edge) bulut ortamlarına kadar uzanan esnek dağıtım olanaklarıyla ileriye taşımaktadır (İnt. Kyn.6).

YOLOv11 mimarisinde, omurga katmanında C2f modülünün yerini C3k2 (Cross Stage Partial with kernel size 2) bloğu almaktadır. C3k2 yapısında, büyük çekirdekli tek evrişim yerine ardışık olarak uygulanan iki küçük çekirdekli evrişim katmanı tercih edilmektedir. Bu yaklaşım, hesaplama yükünü azaltırken temsil gücünü korumayı başarmakta; dolayısıyla modelin işlem süresi optimize edilirken özellik temsili çıkarım yeteneği zedelenmemektedir (İnt. Kyn. 18).

Omurgaya eklenen C2PSA (Cross Stage Partial with Parallel Spatial Attention) bloğu ise uzamsal dikkat mekanizmasıyla özellik haritalarındaki kritik bölgelere odaklanarak, özellikle küçük ve kısmen tıkalı nesnelerin algılanmasını güçlendirir (İnt. Kyn. 18).

YOLOv11, önceki nesillerdeki çapa (anchor) tabanlı sınırlayıcı kutu tahmininden vazgeçerek çapa-bağımsız (anchor-free) paradigmayı benimser. Bu değişiklik, özel veri kümeleri için çapa ayarının getirdiği manuel yükü ortadan kaldırır ve genelleme yeteneğini artırır. Ayrıca sınıflandırma ile sınırlayıcı kutu regresyonu görevlerinin ayrık dallarda işlendiği decoupled-head yapısı, yakınsama hızını ve ortalama kesinlik (mAP) değerlerini iyileştirir (He vd. 2025a).

COCO veri kümesi üzerindeki karşılaştırmalar, YOLOv11'in parametre verimliliği açısından belirgin bir sıçrama yaptığını göstermektedir. Örneğin orta ölçekli YOLOv11m varyantı, YOLOv8m'e göre %22 daha az parametre kullanmasına rağmen daha yüksek mAP değerleri elde etmektedir (İnt. Kyn.6).

Ultralytics tarafından sunulan YOLOv11 ailesi; Nano, Small, Medium, Large ve Extra Large olmak üzere beş farklı model boyutundan oluşmaktadır. Söz konusu bu ölçeklendirme yaklaşımı, 2 ila 13 milisaniyelik çıkarım süreleri aralığında konumlanan varyantlar aracılığıyla, farklı hesaplama kaynaklarına sahip sistemler için hız-doğruluk dengesinde optimal bir referans çerçevesi sunmaktadır. Bu yapılandırma, uygulama geliştiricilerinin donanım kısıtlarına uygun model seçimi yapmasına olanak tanıyan bir Pareto sınırı oluşturmaktadır (İnt. Kyn. 18).

YOLOv11 yalnızca klasik nesne algılama ile sınırlı kalmaz; aynı mimari üzerinden örnek bölütleme (instance segmentation), görüntü sınıflandırma, poz tahmini (pose estimation) ve yönelimli sınırlayıcı kutu (OBB) algılama gibi görevleri de destekler. Bu çok yönlülük, modeli otonom sistemlerden uzaktan algılamaya, tıbbi görüntülemeye endüstriyel kalite kontrole kadar geniş bir uygulama yelpazesine uygun hale getirmektedir (İnt. Kyn.6).

3.2.1.1.9 YOLOv12

YOLOv12'nin temel tasarım felsefesi, attention bloklarını ana yapı taşı olarak kullanmak ve bunu yaparken attention mekanizmasının kuadratik hesaplama karmaşıklığını azaltarak gerçek zamanlı hız gereksinimleriyle uzlaştırmaktır. Bu amaçla üç temel bileşen öne çıkmaktadır: Area Attention (A2), R-ELAN ve FlashAttention entegrasyonu (Tian vd. 2026).

Geleneksel self-attention mekanizmaları, özellik haritasındaki her bir tokenin diğer tüm tokenlerle etkileşime girmesi nedeniyle $O(n^2)$ karmaşıklığına sahiptir. Bu durum, yüksek çözünürlüklü özellik haritalarında hesaplama maliyetini katlanarak artırır. YOLOv12'de önerilen Area Attention (A2), özellik haritasını belirli bölgelere (areas) ayırarak attention hesaplamasını her bölge içinde sınırlı tutar. Bu bölütleme stratejisi, geniş etkili alan (effective receptive field) oluşturmayı sürdürürken, kuadratik maliyeti önemli ölçüde azaltır (Tian vd. 2026).

YOLOv12'nin attention merkezli olmasını sağlayan en kritik mimari bileşendir.

R-ELAN (Residual Efficient Layer Aggregation Networks).

Attention bloklarının derin ağlarda eğitilmesi, gradyan kaybolması (vanishing gradients) ve bellek tüketimi gibi sorunlar barındırır. YOLOv12, bu sorunları aşmak için R-ELAN yapısını kullanır. R-ELAN, residual bağlantılar (artık bağlantılar) ve verimli katman birleştirme stratejileri ile attention bloklarının büyük ölçekli eğitimini stabilize eder; aynı zamanda bellek kullanımını kısar (Tian vd. 2026).

Bu tasarım, YOLOv12'nin N'dan X'e kadar farklı ölçeklerde (N, S, M, L, X) tutarlı bir şekilde eğitilebilmesini sağlar.

FlashAttention ve Pozisyonel Kodlamanın Kaldırılması.

YOLOv12, Ampere ve Hopper mimarili GPU’larda FlashAttention çekirdeklerini kullanarak attention hesaplamasının bellek verimliliğini ve hızını artırır. Ayrıca, mimari karmaşıklığını azaltmak amacıyla geleneksel pozisyonel kodlama (positional encoding) tamamen kaldırılmıştır (Tian vd. 2026).

Bu ikili strateji, modelin donanım seviyesinde optimize edilmiş çıkarım (inference) performansı elde etmesine olanak tanır.

3.2.1.1.10 YOLOv26

Modelin temel tasarım felsefesi, mimariyi basitleştirerek ve post-processing adımlarını ortadan kaldırarak hız ve dağıtım kolaylığı sağlamaktır (İnt. Kyn.7).

YOLOv26’nın en dikkat çekici mimari özelliği, NMS-Free (Non-Maximum Suppression’sız) çıkarım yeteneğidir. YOLOv10’da öncülüğü yapılan bu uçtan uca (end-to-end) yaklaşım, çıkarım boru hattından NMS adımını kaldırarak gecikmeyi önemli ölçüde azaltmakta ve CPU üzerinde %43’e kadar hız artışı sağlamaktadır. Bu özellik, GPU’su olmayan kaynak kısıtlı cihazlarda gerçek zamanlı performansı mümkün kılmaktadır.

Bir diğer yenilik ise MuSGD Optimizer’dır. Bu hibrit optimizasyon yöntemi, geleneksel SGD’nin kararlılığını büyük dil modellerinin (LLM) eğitiminden ilham alan Muon’un hızlı yakınsama özellikleriyle birleştirerek eğitim sürecini hem daha kararlı hem de daha hızlı hale getirmektedir. Ayrıca, DFL (Distribution Focal Loss) modülünün kaldırılması, modelin ONNX ve TensorRT gibi formatlara dışa aktarılmasını basitleştirerek donanım uyumluluğunu artırmıştır.

YOLOv26, küçük nesne algılamada doğruluğu artıran ProgLoss + STAL gibi kayıp fonksiyonu iyileştirmeleriyle de öne çıkmaktadır (İnt. Kyn.7).

4 MATERYAL VE METOT

4.1 Çalışma Alanları

Bu çalışmada SWISSIMAGE Sitesinden alınan ücretsiz erişilebilir veri kaynakları ile elde edilen görüntüler yardımıyla çalışma alanları belirlenmiştir. Çalışma alanı olarak İsviçre'nin farklı şehirlerine ait ortofotolar 50 m x 50 m olacak şekilde indirgenerek veri seti oluşturulmuştur.

Birinci çalışma alanı Bern kantonu Meiringen kasabasına ait 2024 yılı 10 cm çözünürlüklü swissimage-dop10_2024_2657-1175_0.1_2056.tif ortofotosu 200 m x 200 m ye indirgenmiştir (Resim 4.1) (İnt. Kyn.8).

İkinci çalışma alanı Vaud kantonu Vevey şehri Cenevre Gölü (Lac Léman) kuzey kıyısına ait 2023 yılı 10 cm çözünürlüklü swissimage-dop10_2023_2555-1145_0.1_2056.tif ortofotosu 200 m x 200 m ye indirgenmiştir (Resim 4.2) (İnt. Kyn.8).

Görüntü dosyalarının isimlendirilmesi, örnek olarak swissimage-dop10_2024_2657-1175_0.1_2056.tif, İsviçre Federal Topografya Ofisi (swisstopo) tarafından tanımlanan standart bir isimlendirme yapısı vardır. Bu yapı; swissimage verisinin SWISSIMAGE platformundan temin edildiğini, dop10 10 cm mekânsal çözünürlüğünün olduğunu, Dijital Ortofoto ürününün 2024 üretim yılına ait olduğunu, 2657-1175 LV95 koordinat sistemindeki tile numarasını, 0.1 0.1 metre 10 cm piksel boyutunu ve 2056 EPSG:2056 (LV95) koordinat referans sistemini ifade etmektedir.

Seçilen örneklemeler, eğitim veri setindeki verilerden zamansal ve mekânsal olarak farklı olması ile birlikte, aynı veri üreticisi tarafından elde edilen verilerdir. Bu sayede, modelin genelleme yeteneği farklı zaman dilimlerinde ve coğrafi bölgelerde çekilmiş görüntülere karşı test edilmiştir.

SWISSIMAGE 10 cm ortofoto mozaigi, İsviçre'nin tamamını kapsayan yüksek çözünürlüklü dijital renkli hava fotoğraflarının bir araya getirilmesiyle oluşturulmuştur.


Leica ADS100 sensörleriyle elde edilen RGB görüntüler 3 spektral bant içermektedir. Düzlük alanlarda ve ana Alp vadilerinde 10 cm, Alp bölgelerinde ise 25 cm çözünürlük sunan bu veri seti, ülke genelinde ayrıntılı mekânsal analizlere olanak tanımaktadır. SWISSIMAGE, üç yıllık bir döngüyle güncellenerek güncel coğrafi bilgi ihtiyaçlarını karşılamaktadır (İnt. Kyn.8).



Resim 4. 1 Çalışma alanı 1



Resim 4. 2 Çalışma alanı 2



Resim 4. 3 Çalışma alanlarının Dünya üzerindeki konumu

4.2 Veri Seti

Veri seti hazırlamanın ilk adımı, modelin kullanılacağı senaryoya uygun görüntülerin toplanmasıdır. Farklı ışık koşulları, açılar ve ortamları içeren çeşitlilik, modelin genelleme yeteneğini artırarak daha sağlam sonuçlar elde edilmesini sağlar.

Hazırlanan veri seti genellikle üç alt bölüme ayrılır:

Eğitim (%70–80),

Doğrulama (%10–15)

Test (%10–15).

Bu ayrım, modelin hem öğrenme sürecini hem de genelleme performansını değerlendirmek için kritik öneme sahiptir.

Veri seti oluşturmak için SWISSIMAGE sitesinden farklı dilimlerde ortofotolar alınarak bölünmüş ve veri seti oluşturulmuştur. 400 parçaya bölünen resimlerden veri etiketlemek için kullanışlı olanlar tercih edilmiştir.

4.3 Verinin Etiketlenmesi

YOLO formatında etiketleme, her nesne için sınıf kimliğinin ve normalize edilmiş koordinatların belirtilmesini gerektirmektedir. Bu süreçte LabelImg, CVAT, MakeSense ve Roboflow gibi araçlar yaygın olarak kullanılmaktadır.

Çalışmada, görüntülerden oluşan eğitim veri seti ile YOLO formatına uygun şekilde Şekil 4.4 de gösterildiği gibi etiketlemek için Roboflow tercih edilmiştir (İnt. Kyn. 9).



Resim 4. 4 Roboflow ile etiketleme işlemi.

Modellerin performansını değerlendirmek için kullanılan parametreler;

Train (eğitim): %70)

Valid (Doğrulama): %15

Test: %15

4.4 Eğitim İçin Model Seçimi

Kentsel ağaç tespiti için on farklı derin öğrenme modelinin birlikte değerlendirilmesinin temel gerekçesi, nesne tespiti literatüründeki farklı mimari paradigmaların aynı deneysel koşullar altında karşılaştırılabilir olmasıdır. Tüm modeller Google Colab ortamında

Ultralytics framework'ü üzerinden eğitilmiş olup; task=detect mode=train komutuyla çağrılan her bir mimari için epochs=200, imgsz=640, batch=64, lr0=0.004, optimizer=SGD, cos_lr=True ve patience=0 parametreleri sabit tutularak eğitim süreçleri standartlaştırılmıştır. Bu yaklaşım, veri artırımı, öğrenme oranı programlaması ve optimizasyon algoritması gibi dışsal değişkenleri kontrol altında tutarak sadece omurga, boyun ve başlık mimarilerinin ağaç tespiti performansına etkisini izole etmemizi sağlar.

Seçilen modeller nesne tespitindeki teknolojik evrimin farklı aşamalarını temsil eder. RT-DETR L, Vision Transformer tabanlı kodlayıcı ve DETR kod çözücü ile dikkat mekanizmalarının uygulamasını; YOLOv3m, çok ölçekli tespit başlıkları ve önceden tanımlı anchor box'larla klasik tek aşamalı dedektör mimarisini; YOLOv5m, CSPNet omurga yapısıyla kararlı ve geniş kabul görmüş bir referans çizgisini; YOLOv6m, endüstriyel dağıtım odaklı hesaplama verimliliğini temsil eder. YOLOv8m, anchor-free ve ayırık başlık yapısıyla önemli bir mimari dönüm noktası olup; YOLOv9m, programlanabilir gradyan bilgisi (PGI) ile öğrenme sürecindeki bilgi kaybını azaltan bir yapı sunar. YOLOv10m, tutarlı çift atama ve NMS-free çıkarım ile uçtan uca gerçek zamanlı performansı; YOLOv11m, C3k2 ve C2PSA bloklarıyla optimize edilmiş özellik çıkarımını; YOLOv12m, Area Attention (A2) ve R-ELAN ile attention merkezli mimariyi temsil eder. YOLOv26m ise NMS-free çıkarım, MuSGD optimizasyonu ve kenar cihaz odaklı hafifletilmiş tasarımıyla en güncel evrim basamağını oluşturur.

Bu onlu set, Transformer-tabanlı yaklaşımlardan klasik CNN omurgalarına, anchor-tabanlı tasarımlardan NMS-free uçtan uca mimarilere kadar geniş bir teknolojik yelpazeyi kapsar. Tüm modellerin aynı veri kümesi, aynı çözünürlük (640×640) ve aynı hiperparametre seti ile eğitilmiş olması, mimari farklılıkların kentsel ağaç envanterleme performansına etkisinin nesnel ve tekrarlanabilir bir çerçevede incelenmesine olanak tanır. Sonuç olarak bu seçim, doğruluk ile hesaplama verimliliği arasında denge kurmayı hedefleyen araştırmacılar ve uygulayıcılar için; eğitim süresi, çıkarım hızı, bellek kullanımı ve farklı kentsel senaryolardaki genelleme yetenekleri açısından güvenilir bir karşılaştırma zemin sunmayı amaçlamaktadır.

4.5 Değerlendirme Kriterleri

Nesne algılama modellerinin performansını değerlendirmek için bilgisayarla görme topluluğu tarafından kabul görmüş üç temel metrik kullanılmaktadır: mAP, Precision ve Recall (İnt. Kyn. 10).

Ortalama Hassasiyet (Mean Average Precision – mAP): Nesne algılama modellerinin performansını özetleyen tek bir değerdir ve hem algılama doğruluğunu hem de nesne yerelleştirmesini yakalar (İnt. Kyn. 11).

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i \quad (4.1)$$

Roboflow, mAP’yi genellikle Intersection-over-Union (IoU) eşiklerinin bir aralığında (örneğin 0.50–0.95) hassasiyet–geri çağırma eğrisi altındaki alanı hesaplayarak değerlendirir. “mAP, birden fazla IoU eşiği üzerinden hassasiyeti hesaplayarak hem algılama doğruluğunu hem de nesne yerelleştirmesini yakaladığı için önde gelen bir metriktir.” (İnt. Kyn. 12).

$$AP = \int_0^1 Pr(Re) \cdot dPr \quad (4.2)$$

Roboflow’un Doğrulanmış Model Metrikleri özelliği, COCO Değerlendirme Çerçevesi metodolojisine uygun olarak açık kaynaklı Supervision kütüphanesiyle şeffaf ve tekrarlanabilir değerlendirmeler yapılmasını sağlar. Bu standartlaştırma, farklı modeller arasındaki karşılaştırmaların güvenilirliğini artırır (İnt. Kyn. 13).

Precision (Hassasiyet): Model tarafından pozitif sınıfa atanmış tahminler içinde gerçekten pozitif olanların oranını yansıtan bir başarımlı ölçütüdür. Bu metriğin yüksek değer alması, yanlış pozitif (False Positive, FP) hata sayısının düşük düzeyde olduğunu gösterir (Sokolova vd. 2009).

$$\text{Precision} = \frac{TP}{TP+FP} \quad (4.3)$$

Recall (Geri Çaęırma): Pozitif sınıfa ait gerek rnekler iinde modelin doęru bir ekilde tespit edebildięi bireylerin oranını ifade eden metriktir. Bu deęerin yksek olması, gzden kaırılan pozitif rnek sayısının (False Negative, FN) az olduęuna iřaret eder (İnt. Kyn. 14).

$$\text{Recall} = \frac{TP}{TP+FN} \quad (4.4)$$

Roboflow, tm sınıflar arasında en iyi gven dzeyinde (F1'i optimize eden) makro Precision, Recall ve F1 skorlarını da sunarak, zellikle dengesiz veri kmeleri iin ek igrler saęlamaktadır (İnt. Kyn. 13).

$$F1 = \frac{2.(Precision*Recall)}{Precision+Recall} \quad (4.5)$$

Karıřıklık Matrisi (Confusion Matrix): Modelin sınıflandırma veya algılama performansını derinlemesine anlamamızı saęlayan grsel bir tablodur. İindeki Doęru Pozitif (TP), Yanlıř Pozitif (FP), Doęru Negatif (TN) ve Yanlıř Negatif (FN) hcreleri sayesinde, modelin hangi sınıfları birbiriyle karıřtırdıęı net bir ekilde grlebilir. Roboflow platformunda bu matris, eęitilmiş modelin test ve doęrulama grntlerine uygulanarak oluřturulur; bylece modelin zayıf kaldıęı noktalar kolayca tespit edilebilir (İnt. Kyn. 15).

Model deęerlendirmesinin gvenilirlięi, veri kmesinin eęitim, doęrulama ve test kmelerine nasıl blndęne baęlıdır (İnt. Kyn. 16).

Roboflow, ařırı uyumun (overfitting) nlenmesi ve genelleme yeteneęinin doęru ekilde llmesi iin bu ayrımı vurgulamaktadır.

Eęitim (Train): Modelin ęrenmesi iin kullanılır; veri kmesinin byk oęunluęu (%80) bu amala ayrılır (İnt. Kyn. 16).


Doęrulama (Validation): Eęitim sırasında hiperparametre ayarlamaları ve performans izleme iin kullanılır.

Test (Test): Modelin görmediği veriler üzerinde bağımsız performansını ölçmek için kullanılır.

5 UYGULAMA

Bu bölümde çalışma kapsamında öncelikle verilerin toplanması, ön işlenmesi ve etiketlenmesi gerçekleştirilmiştir. Hazırlanan veri seti kullanılarak YOLO tabanlı derin öğrenme modelleri eğitilerek, eğitim sonuçları analiz edilecek ve modellerin doğruluk analizi yapılacaktır. Modellerin performansları çalışma alanı 1 ve çalışma alanı 2 verileri ile test edilerek sistematik olarak değerlendirilecektir.

Şekil 5.1'de, bu çalışmanın YOLO algoritması çerçevesindeki aşama aşama ilerleyişi görselleştirilmektedir.



Şekil 5. 1 Çalışmada Kullanılan YOLO Algoritmasının İş Akış Diyagramı

5.1 Ağaç Tespit Modelleri ve Doğruluk Analizleri


5.1.1 RT-DETR Ağaç Tespit Modeli

Bu bölümde eğitim veri seti hazırlandıktan sonra bulut depolama hizmetine yükleme yapılmıştır. RT-DETR L modeli seçilmiştir. Eğitim için Ultralytics kodları kullanılarak


Google Colab ortamında NVIDIA A100 SXM4 GPU kullanılarak eğitim işlemi ve Python kodları ile test işlemleri gerçekleştirilmiştir. Model için eğitimlerde epoch sayısı 200, batch = 64, lr0 = 0.004 ve optimizer SGD seçilmiştir.

5.1.2 RT-DETR Doğruluk Analizi


Google Colab ile eğitilen RT-DETR L modeli 0 ile 1 arasındaki doğruluğu verilmiştir. Bu değerlerin 1'e yaklaşması, modelin performansının arttığını gösterir. Şekil 5.2'de Precision, Şekil 5.3'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. 2 RT-DETR L modelinin kesinlik analizi




Şekil 5. 3 RT-DETR L modelinin duyarlılık eğrisi




Şekil 5. 4 RT-DETR L modelinin kesinlik-duyarlılık eğrisi

Şekil 5.4’de Precision-Recall eğrisi yer almaktadır. Bu eğride ağaç için 0.935 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. 5 RT-DETR L modelinin F1-Güven eğrisi


Şekil 5.5’de F1-Güven eğrisi yer almaktadır. Bu eğride ağaç için 0.91 F1 değeri olarak ifade edilmiştir.



Şekil 5. 6 RT-DETR L modeli performans grafikleri

Şekil 5.6 da sunulan bulgular, eğitim sürecindeki kayıp değerlerinin (soldaki üç grafik) istikrarlı bir biçimde gerilediğini göstermektedir. Bu gelişme, modelin konum belirleme, sınıflandırma ve sınırlayıcı kutu regresyonu görevlerindeki isabetliliğinin giderek yükseldiğine işaret etmektedir. Diğer taraftan, doğrulama kayıpları (sol alt üç grafik) dalgalanma sergilemekle birlikte büyük ölçüde düşük seviyelerde seyretmiş ve bu durum modelin genelleme yeteneğini muhafaza ettiğini kanıtlamıştır. Precision metriğinde gözlemlenen artış, yanlış pozitif sayısının düştüğünü; recall metriğindeki yükseliş ise nesne tespit oranının geliştiğini göstermektedir. Son olarak, mAP50 ve mAP50-95 skorlarındaki devamlı ilerleme, modelin bütünsel başarımı hakkında değerli çıkarımlar sunmaktadır.

Ayrıca, Precision ve Recall grafiklerinde de modelin doğruluğunda artış kaydedilmiştir. Eğitim sürecinin sonunda, precision 0.921 ve recall 0.892, F1 0.910 olarak elde edilmiştir. Precision, Recall ve F1 skoru modelin genel performansı hakkında önemli bilgiler sunmaktadır.




Şekil 5. 7 RT-DETR L modeli karışıklık matrisi

Şekil 5.7’de ifade edilen eğitilen model için karışıklık matrisi değerleridir. 2697, 1363, 146 sayıları sırasıyla TP, FP, FN değerlerini ifade eder. Çizelge 5.1’de RT-DETR L modelinin eğitimi sonrası elde edilen performansları verilmiştir.

Çizelge 5. 1 RT-DETR L modeli eğitim değerleri

Model	mAP50	mAP50-95	Precision (Pr)	Recall(Re)	F1 Score	Eğitim Süresi (Saat)
RT-DETR L	93.5%	70.3%	92.1%	89.2%	91.0%	1.844

RT-DETR L modeli 2 ortofoto üzerinde test edilmiştir. Çalışma alanı 1 de 60 adet ağaç etiketlemiştir (Resim 5.1). Çalışma alanı 2 de 54 adet ağaç etiketlemiştir (Resim 5.2). Test işlemi Python kodları ile yapılmıştır. RT-DETR L modeliyle test edilen Çalışma alanı 1 65 ağaç içinden 60 ağaç etiketleyerek %92,31 tespit oranı elde edilmiştir. RT-DETR L modeliyle test edilen Çalışma alanı 2’de 51 referans ağaçtan 54 tespit yapılmış; bu %105,88 oranında tespit oranı değerine karşılık gelmektedir. Ayrıca 3 adet nesne ağaç olarak yanlış pozitif etiketlenmiştir.



Resim 5. 1 RT-DETR L modeli ağaç tespiti çalışma alanı 1




Resim 5. 2 RT-DETR L modeli ağaç tespiti çalışma alanı 2

5.1.3 YOLOv3 Ağaç Tespit Modeli


Bu bölümde eğitim veri seti hazırlandıktan sonra bulut depolama hizmetine yükleme yapılmıştır. YOLOv3 m modeli seçilmiştir. Eğitim için Ultralytics kodları kullanılarak Google Colab ortamında NVIDIA A100 SXM4 GPU kullanılarak eğitim işlemi ve Python kodları ile test işlemleri gerçekleştirilmiştir. Model için eğitimlerde epoch sayısı 200, batch = 64, lr0 = 0.004 ve optimizer SGD seçilmiştir.

5.1.4 YOLOv3 Doğruluk Analizi


Google Colab ile eğitilen YOLOv3 m modeli 0 ile 1 arasındaki doğruluğu verilmiştir. Bu değerlerin 1'e yaklaşması, modelin performansının arttığını gösterir. Şekil 5.8'de Precision, Şekil 5.9'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. 8 YOLOv3 m modelinin kesinlik analizi




Şekil 5. 9 YOLOv3 m modelinin duyarlılık eğrisi




Şekil 5. 10 YOLOv3 m modelinin kesinlik-duyarlılık eğrisi

Şekil 5.10’da Precision-Recall eğrisi yer almaktadır. Bu eğride ağaç için 0.929 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. 11 YOLOv3 m modelinin F1-Güven eğrisi


Şekil 5.11’de F1-Güven eğrisi yer almaktadır. Bu eğride ağaç için 0.91 F1 değeri olarak ifade edilmiştir.



Şekil 5. 12 YOLOv3 m modeli performans grafikleri

Şekil 5.12 de sunulan bulgular, eğitim sürecindeki kayıp değerlerinin (soldaki üç grafik) istikrarlı bir biçimde gerilediğini göstermektedir. Bu gelişme, modelin konum belirleme, sınıflandırma ve sınırlayıcı kutu regresyonu görevlerindeki isabetliliğinin giderek yükseldiğine işaret etmektedir. Diğer taraftan, doğrulama kayıpları (sol alt üç grafik) dalgalanma sergilemekle birlikte büyük ölçüde düşük seviyelerde seyretmiş ve bu durum modelin genelleme yeteneğini muhafaza ettiğini kanıtlamıştır. Precision metriğinde gözlemlenen artış, yanlış pozitif sayısının düştüğünü; recall metriğindeki yükseliş ise nesne tespit oranının geliştiğini göstermektedir. Son olarak, mAP50 ve mAP50-95 skorlarındaki devamlı ilerleme, modelin bütünsel başarımı hakkında değerli çıkarımlar sunmaktadır.

Ayrıca, Precision ve Recall grafiklerinde de modelin doğruluğunda artış kaydedilmiştir. Eğitim sürecinin sonunda, precision 0.936 ve recall 0.891, F1 0.910 olarak elde edilmiştir. Precision, Recall ve F1 skoru modelin genel performansı hakkında önemli bilgiler sunmaktadır.



Şekil 5. 13 YOLOv3 modeli karışıklık matrisi

Şekil 5.13’de ifade edilen eğitilen model için karışıklık matrisi değerleridir. 2635, 366, 208 sayıları sırasıyla TP, FP, FN değerlerini ifade eder. Çizelge 5.2’de YOLOv3 m modelinin eğitimi sonrası elde edilen performansları verilmiştir.

Çizelge 5. 2 YOLOv3 modeli eğitim değerleri

Model	mAP50	mAP50-95	Precision (Pr)	Recall(Re)	F1 Score	Eğitim Süresi (Saat)
YOLOv3m	92.9%	70.1%	93.6%	89.1%	91.0%	0.461

YOLOv3 m modeli 2 ortofoto üzerinde test edilmiştir. Çalışma alanı 1 de 41 adet ağaç etiketlemiştir (Resim 5.3). Çalışma alanı 2 de 34 adet ağaç etiketlemiştir (Resim 5.4). Test işlemi Python kodları ile yapılmıştır. YOLOv3 m modeliyle test edilen Çalışma alanı 1 65 ağaç içinden 41 ağaç etiketleyerek %63.08 tespit oranı elde edilmiştir. YOLOv3 m

modeliyle test edilen Çalışma alanı 2 51 ağaç içinden 34 ağaç etiketleyerek %66,67 tespit oranı elde edilmiştir.



Resim 5. 3 YOLOv3 m modeli ağaç tespiti çalışma alanı 1




Resim 5. 4 YOLOv3 m modeli ağaç tespiti çalışma alanı 2

5.1.5 YOLOv5 Ağaç Tespit Modeli


Bu bölümde eğitim veri seti hazırlandıktan sonra bulut depolama hizmetine yükleme yapılmıştır. YOLOv5 m modeli seçilmiştir. Eğitim için Ultralytics kodları kullanılarak Google Colab ortamında NVIDIA A100 SXM4 GPU kullanılarak eğitim işlemi ve Python kodları ile test işlemleri gerçekleştirilmiştir. Model için eğitimlerde epoch sayısı 200, batch = 64, lr0 = 0.004 ve optimizer SGD seçilmiştir.

5.1.6 YOLOv5 Doğruluk Analizi


Google Colab ile eğitilen YOLOv5 m modeli 0 ile 1 arasındaki doğruluğu verilmiştir. Bu değerlerin 1'e yaklaşması, modelin performansının arttığını gösterir. Şekil 5.14'de Precision, Şekil 5.15'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. 14 YOLOv5 m modelinin kesinlik analizi




Şekil 5. 15 YOLOv5 m modelinin duyarlılık eğrisi




Şekil 5. 16 YOLOv5 m modelinin kesinlik-duyarlılık eğrisi

Şekil 5.16’da Precision-Recall eğrisi yer almaktadır. Bu eğride ağaç için 0.940 mAP değeri olarak ifade edilmiştir.



Şekil 5. 17 YOLOv5 m modelinin F1-Güven eğrisi


Şekil 5.17’de F1-Güven eğrisi yer almaktadır. Bu eğride ağaç için 0.93 F1 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. 18 YOLOv5 m modeli performans grafikleri

Şekil 5.18 de sunulan bulgular, eğitim sürecindeki kayıp değerlerinin (soldaki üç grafik) istikrarlı bir biçimde gerilediğini göstermektedir. Bu gelişme, modelin konum belirleme, sınıflandırma ve sınırlayıcı kutu regresyonu görevlerindeki isabetliliğinin giderek yükseldiğine işaret etmektedir. Diğer taraftan, doğrulama kayıpları (sol alt üç grafik) dalgalanma sergilemekle birlikte büyük ölçüde düşük seviyelerde seyretmiş ve bu durum modelin genelleme yeteneğini muhafaza ettiğini kanıtlamıştır. Precision metriğinde gözlemlenen artış, yanlış pozitif sayısının düştüğünü; recall metriğindeki yükseliş ise nesne tespit oranının geliştiğini göstermektedir. Son olarak, mAP50 ve mAP50-95 skorlarındaki devamlı ilerleme, modelin bütünsel başarımı hakkında değerli çıkarımlar sunmaktadır.

Ayrıca, Precision ve Recall grafiklerinde de modelin doğruluğunda artış kaydedilmiştir. Eğitim sürecinin sonunda, precision 0.954 ve recall 0.903, F1 0.930 olarak elde edilmiştir. Precision, Recall ve F1 skoru modelin genel performansı hakkında önemli bilgiler sunmaktadır.




Şekil 5. 19 YOLOv5 m modeli karışıklık matrisi

Şekil 5.19’da ifade edilen eğitilen model için karışıklık matrisi değerleridir. 2607, 166, 236 sayıları sırasıyla TP, FP, FN değerlerini ifade eder. Çizelge 5.3’de YOLOv5 m modelinin eğitimi sonrası elde edilen performansları verilmiştir.

Çizelge 5. 3 YOLOv5 m modeli eğitim değerleri

Model	mAP50	mAP50-95	Precision (Pr)	Recall(Re)	F1 Score	Eğitim Süresi (Saat)
YOLOv5 m	94.0%	79.7%	95.4%	90.3%	93.0%	0.713

YOLOv5 m modeli 2 ortofoto üzerinde test edilmiştir. Çalışma alanı 1 de 46 adet ağaç etiketlemiştir (Resim 5.5). Çalışma alanı 2 de 35 adet ağaç etiketlemiştir (Resim 5.6). Test işlemi Python kodları ile yapılmıştır. YOLOv5 m modeliyle test edilen Çalışma alanı 1 65 ağaç içinden 46 ağaç etiketleyerek %70,77 tespit oranı elde edilmiştir. YOLOv5 m modeliyle test edilen Çalışma alanı 2 51 ağaç içinden 35 ağaç etiketleyerek %68,63 tespit oranı elde edilmiştir.



Resim 5. 5 YOLOv5 m modeli ağaç tespiti çalışma alanı 1




Resim 5. 6 YOLOv5 m modeli ağaç tespiti çalışma alanı 2

5.1.7 YOLOv6 Ağaç Tespit Modeli


Bu bölümde eğitim veri seti hazırlandıktan sonra bulut depolama hizmetine yükleme yapılmıştır. YOLOv6 m modeli seçilmiştir. Eğitim için Ultralytics kodları kullanılarak Google Colab ortamında NVIDIA A100 SXM4 GPU kullanılarak eğitim işlemi ve Python kodları ile test işlemleri gerçekleştirilmiştir. Model için eğitimlerde epoch sayısı 200, batch = 64, lr0 = 0.004 ve optimizör SGD seçilmiştir.

5.1.8 YOLOv6 Doğruluk Analizi


Google Colab ile eğitilen YOLOv6 m modeli 0 ile 1 arasındaki doğruluğu verilmiştir. Bu değerlerin 1'e yaklaşması, modelin performansının arttığını gösterir. Şekil 5.20'de Precision, Şekil 5.21'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. 20 YOLOv6 m modelinin kesinlik analizi




Şekil 5. 21 YOLOv6 m modelinin duyarlılık eğrisi




Şekil 5. 22 YOLOv6 m modelinin kesinlik-duyarlılık eğrisi

Şekil 5.22’de Precision-Recall eğrisi yer almaktadır. Bu eğride ağaç için 0.937 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. 23 YOLOv6 m modelinin F1-Güven eğrisi


Şekil 5.23’de F1-Güven eğrisi yer almaktadır. Bu eğride ağaç için 0.90 F1 değeri olarak ifade edilmiştir.



Şekil 5. 24 YOLOv6 m modeli performans grafikleri

Şekil 5.24 de sunulan bulgular, eğitim sürecindeki kayıp değerlerinin (soldaki üç grafik) istikrarlı bir biçimde gerilediğini göstermektedir. Bu gelişme, modelin konum belirleme, sınıflandırma ve sınırlayıcı kutu regresyonu görevlerindeki isabetliliğinin giderek yükseldiğine işaret etmektedir. Diğer taraftan, doğrulama kayıpları (sol alt üç grafik) dalgalanma sergilemekle birlikte büyük ölçüde düşük seviyelerde seyretmiş ve bu durum modelin genelleme yeteneğini muhafaza ettiğini kanıtlamıştır. Precision metriğinde gözlemlenen artış, yanlış pozitif sayısının düştüğünü; recall metriğindeki yükseliş ise nesne tespit oranının geliştiğini göstermektedir. Son olarak, mAP50 ve mAP50-95 skorlarındaki devamlı ilerleme, modelin bütünsel başarımı hakkında değerli çıkarımlar sunmaktadır.

Ayrıca, Precision ve Recall grafiklerinde de modelin doğruluğunda artış kaydedilmiştir. Eğitim sürecinin sonunda, precision 0.927 ve recall 0.877, F1 0.900 olarak elde edilmiştir. Precision, Recall ve F1 skoru modelin genel performansı hakkında önemli bilgiler sunmaktadır.



Şekil 5. 25 YOLOv6 m modeli karışıklık matrisi


Şekil 5.25’de ifade edilen eğitilen model için karışıklık matrisi değerleridir. 2629, 465, 214 sayıları sırasıyla TP, FP, FN değerlerini ifade eder. Çizelge 5.4’de YOLOv6 m modelinin eğitimi sonrası elde edilen performansları verilmiştir.

Çizelge 5. 4 YOLOv6 m modeli eğitim değerleri

Model	mAP50	mAP50-95	Precision (Pr)	Recall(Re)	F1 Score	Eğitim Süresi (Saat)
YOLOv6 m	93.7%	69.4%	92.7%	87.7%	90.0%	0.810

YOLOv6 m modeli 2 ortofoto üzerinde test edilmiştir. Çalışma alanı 1 de 43 adet ağaç etiketlemiştir (Resim 5.7). Çalışma alanı 2 de 38 adet ağaç etiketlemiştir (Resim 5.8). Test işlemi Python kodları ile yapılmıştır. YOLOv6 m modeliyle test edilen Çalışma alanı 1 65 ağaç içinden 43 ağaç etiketleyerek %66,15 tespit oranı elde edilmiştir. YOLOv6 m

modeliyle test edilen Çalışma alanı 2 51 ağaç içinden 34 ağaç etiketleyerek %74,51 tespit oranı elde edilmiştir.



Resim 5. 7 YOLOv6 m modeli ağaç tespiti çalışma alanı 1




Resim 5. 8 YOLOv6 m modeli ağaç tespiti çalışma alanı 2

5.1.9 YOLOv8 Ağaç Tespit Modeli


Bu bölümde eğitim veri seti hazırlandıktan sonra bulut depolama hizmetine yükleme yapılmıştır. YOLOv8 m modeli seçilmiştir. Eğitim için Ultralytics kodları kullanılarak Google Colab ortamında NVIDIA A100 SXM4 GPU kullanılarak eğitim işlemi ve Python kodları ile test işlemleri gerçekleştirilmiştir. Model için eğitimlerde epoch sayısı 200, batch = 64, lr0 = 0.004 ve optimizer SGD seçilmiştir.

5.1.10 YOLOv8 Doğruluk Analizi


Google Colab ile eğitilen YOLOv8 m modeli 0 ile 1 arasındaki doğruluğu verilmiştir. Bu değerlerin 1'e yaklaşması, modelin performansının arttığını gösterir. Şekil 5.26'da Precision, Şekil 5.27'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. 26 YOLOv8 m modelinin kesinlik analizi




Şekil 5. 27 YOLOv8 m modelinin duyarlılık eğrisi




Şekil 5. 28 YOLOv8 m modelinin kesinlik-duyarlılık eğrisi

Şekil 5.28’de Precision-Recall eğrisi yer almaktadır. Bu eğride ağaç için 0.935 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. 29 YOLOv8 m modelinin F1-Güven eğrisi


Şekil 5.29’da F1-Güven eğrisi yer almaktadır. Bu eğride ağaç için 0.93 F1 değeri olarak ifade edilmiştir.



Şekil 5. 30 YOLOv8 m modeli performans grafikleri

Şekil 5.30 da sunulan bulgular, eğitim sürecindeki kayıp değerlerinin (soldaki üç grafik) istikrarlı bir biçimde gerilediğini göstermektedir. Bu gelişme, modelin konum belirleme, sınıflandırma ve sınırlayıcı kutu regresyonu görevlerindeki isabetliliğinin giderek yükseldiğine işaret etmektedir. Diğer taraftan, doğrulama kayıpları (sol alt üç grafik) dalgalanma sergilemekle birlikte büyük ölçüde düşük seviyelerde seyretmiş ve bu durum modelin genelleme yeteneğini muhafaza ettiğini kanıtlamıştır. Precision metriğinde gözlemlenen artış, yanlış pozitif sayısının düştüğünü; recall metriğindeki yükseliş ise nesne tespit oranının geliştiğini göstermektedir. Son olarak, mAP50 ve mAP50-95 skorlarındaki devamlı ilerleme, modelin bütünsel başarımı hakkında değerli çıkarımlar sunmaktadır.

Ayrıca, Precision ve Recall grafiklerinde de modelin doğruluğunda artış kaydedilmiştir. Eğitim sürecinin sonunda, precision 0.955 ve recall 0.906, F1 0.930 olarak elde edilmiştir. Precision, Recall ve F1 skoru modelin genel performansı hakkında önemli bilgiler sunmaktadır.




Şekil 5. 31 YOLOv8 m modeli karışıklık matrisi

Şekil 5.31’de ifade edilen eğitilen model için karışıklık matrisi değerleridir. 2601, 140, 242 sayıları sırasıyla TP, FP, FN değerlerini ifade eder. Çizelge 5.5’de YOLOv8 m modelinin eğitimi sonrası elde edilen performansları verilmiştir.

Çizelge 5. 5 YOLOv8 m modeli eğitim değerleri

Model	mAP50	mAP50-95	Precision (Pr)	Recall(Re)	F1 Score	Eğitim Süresi (Saat)
YOLOv8 m	93.5%	80.3%	95.5%	90.6%	93.0%	0.717

YOLOv8 m modeli 2 ortofoto üzerinde test edilmiştir. Çalışma alanı 1 de 35 adet ağaç etiketlemiştir (Resim 5.9). Çalışma alanı 2 de 46 adet ağaç etiketlemiştir (Resim 5.10) Test işlemi Python kodları ile yapılmıştır. YOLOv8 m modeliyle test edilen Çalışma alanı 1 65 ağaç içinden 35 ağaç etiketleyerek %53,85 tespit oranı elde edilmiştir. YOLOv8 m modeliyle test edilen Çalışma alanı 2 51 ağaç içinden 46 ağaç etiketleyerek %90,20 tespit oranı elde edilmiştir.



Resim 5. 9 YOLOv8 m modeli ağaç tespiti çalışma alanı 1




Resim 5. 10 YOLOv8 m modeli ağaç tespiti çalışma alanı 2

5.1.11 YOLOv9 Ağaç Tespit Modeli


Bu bölümde eğitim veri seti hazırlandıktan sonra bulut depolama hizmetine yükleme yapılmıştır. YOLOv9 m modeli seçilmiştir. Eğitim için Ultralytics kodları kullanılarak Google Colab ortamında NVIDIA A100 SXM4 GPU kullanılarak eğitim işlemi ve Python kodları ile test işlemleri gerçekleştirilmiştir. Model için eğitimlerde epoch sayısı 200, batch = 64, lr0 = 0.004 ve optimizier SGD seçilmiştir.

5.1.12 YOLOv9 Doğruluk Analizi


Google Colab ile eğitilen YOLOv9 m modeli 0 ile 1 arasındaki doğruluğu verilmiştir. Bu değerlerin 1'e yaklaşması, modelin performansının arttığını gösterir. Şekil 5.32'de Precision, Şekil 5.33'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. 32 YOLOv9 m modelinin kesinlik analizi




Şekil 5. 33 YOLOv9 m modelinin duyarlılık eğrisi




Şekil 5. 34 YOLOv9 m modelinin kesinlik-duyarlılık eğrisi

Şekil 5.34’de Precision-Recall eğrisi yer almaktadır. Bu eğride ağaç için 0.942 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. 35 YOLOv9 m modelinin F1-Güven eğrisi


Şekil 5.35’de F1-Güven eğrisi yer almaktadır. Bu eğride ağaç için 0.93 F1 değeri olarak ifade edilmiştir.



Şekil 5. 36 YOLOv9 m modeli performans grafikleri

Şekil 5.36 da sunulan bulgular, eğitim sürecindeki kayıp değerlerinin (soldaki üç grafik) istikrarlı bir biçimde gerilediğini göstermektedir. Bu gelişme, modelin konum belirleme, sınıflandırma ve sınırlayıcı kutu regresyonu görevlerindeki isabetliliğinin giderek yükseldiğine işaret etmektedir. Diğer taraftan, doğrulama kayıpları (sol alt üç grafik) dalgalanma sergilemekle birlikte büyük ölçüde düşük seviyelerde seyretmiş ve bu durum modelin genelleme yeteneğini muhafaza ettiğini kanıtlamıştır. Precision metriğinde gözlemlenen artış, yanlış pozitif sayısının düştüğünü; recall metriğindeki yükseliş ise nesne tespit oranının geliştiğini göstermektedir. Son olarak, mAP50 ve mAP50-95 skorlarındaki devamlı ilerleme, modelin bütünsel başarımı hakkında değerli çıkarımlar sunmaktadır.

Ayrıca, Precision ve Recall grafiklerinde de modelin doğruluğunda artış kaydedilmiştir. Eğitim sürecinin sonunda, precision 0.963 ve recall 0.899, F1 0.930 olarak elde edilmiştir. Precision, Recall ve F1 skoru modelin genel performansı hakkında önemli bilgiler sunmaktadır.



Şekil 5. 37 YOLOv9 m modeli karışıklık matrisi

Şekil 5.37’de ifade edilen eğitilen model için karışıklık matrisi değerleridir. 2616, 144, 227 sayıları sırasıyla TP, FP, FN değerlerini ifade eder. Çizelge 5.6’de YOLOv9 m modelinin eğitimi sonrası elde edilen performansları verilmiştir.

Çizelge 5. 6 YOLOv9 m modeli eğitim değerleri

Model	mAP50	mAP50-95	Precision (Pr)	Recall(Re)	F1 Score	Eğitim Süresi (Saat)
YOLOv9 m	94.2%	79.5%	96.3%	89.9%	93.0%	0.940

YOLOv9 m modeli 2 ortofoto üzerinde test edilmiştir. Çalışma alanı 1 de 46 adet ağaç etiketlemiştir (Resim 5.11). Çalışma alanı 2 de 50 adet ağaç etiketlemiştir (Resim 5.12). Test işlemi Python kodları ile yapılmıştır. YOLOv9 m modeliyle test edilen Çalışma alanı 1 65 ağaç içinden 46 ağaç etiketleyerek %70,77 tespit oranı elde edilmiştir. YOLOv9 m

modeliyle test edilen Çalışma alanı 2 51 ağaç içinden 50 ağaç etiketleyerek %98.04 tespit oranı elde edilmiştir.



Resim 5. 11 YOLOv9 m modeli ağaç tespiti çalışma alanı 1




Resim 5. 12 YOLOv9 m modeli ağaç tespiti çalışma alanı 2

5.1.13 YOLOv10 Ağaç Tespit Modeli


Bu bölümde eğitim veri seti hazırlandıktan sonra bulut depolama hizmetine yükleme yapılmıştır. YOLOv10 m modeli seçilmiştir. Eğitim için Ultralytics kodları kullanılarak Google Colab ortamında NVIDIA A100 SXM4 GPU kullanılarak eğitim işlemi ve Python kodları ile test işlemleri gerçekleştirilmiştir. Model için eğitimlerde epoch sayısı 200, batch = 64, lr0 = 0.004 ve optimizer SGD seçilmiştir.

5.1.14 YOLOv10 Doğruluk Analizi


Google Colab ile eğitilen YOLOv10 m modeli 0 ile 1 arasındaki doğruluğu verilmiştir. Bu değerlerin 1'e yaklaşması, modelin performansının arttığını gösterir. Şekil 5.38'de Precision, Şekil 5.39'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. 38 YOLOv10 m modelinin kesinlik analizi




Şekil 5. 39 YOLOv10 m modelinin duyarlılık eğrisi




Şekil 5. 40 YOLOv10 m modelinin kesinlik-duyarlılık eğrisi

Şekil 5.40’da Precision-Recall eğrisi yer almaktadır. Bu eğride ağaç için 0.937 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. 41 YOLOv10 m modelinin F1-Güven eğrisi


Şekil 5.41’de F1-Güven eğrisi yer almaktadır. Bu eğride ağaç için 0.93 F1 değeri olarak ifade edilmiştir.



Şekil 5. 42 YOLOv10 m modeli performans grafikleri

Şekil 5.42 de sunulan bulgular, eğitim sürecindeki kayıp değerlerinin (soldaki üç grafik) istikrarlı bir biçimde gerilediğini göstermektedir. Bu gelişme, modelin konum belirleme, sınıflandırma ve sınırlayıcı kutu regresyonu görevlerindeki isabetliliğinin giderek yükseldiğine işaret etmektedir. Diğer taraftan, doğrulama kayıpları (sol alt üç grafik) dalgalanma sergilemekle birlikte büyük ölçüde düşük seviyelerde seyretmiş ve bu durum modelin genelleme yeteneğini muhafaza ettiğini kanıtlamıştır. Precision metriğinde gözlemlenen artış, yanlış pozitif sayısının düştüğünü; recall metriğindeki yükseliş ise nesne tespit oranının geliştiğini göstermektedir. Son olarak, mAP50 ve mAP50-95 skorlarındaki devamlı ilerleme, modelin bütünsel başarımı hakkında değerli çıkarımlar sunmaktadır.

Ayrıca, Precision ve Recall grafiklerinde de modelin doğruluğunda artış kaydedilmiştir. Eğitim sürecinin sonunda, precision 0.957 ve recall 0.900, F1 0.930 olarak elde edilmiştir. Precision, Recall ve F1 skoru modelin genel performansı hakkında önemli bilgiler sunmaktadır.




Şekil 5. 43 YOLOv10 m modeli karışıklık matrisi

Şekil 5.43’de ifade edilen eğitilen model için karışıklık matrisi değerleridir. 2574, 110, 269 sayıları sırasıyla TP, FP, FN değerlerini ifade eder. Çizelge 5.7’de YOLOv10 m modelinin eğitimi sonrası elde edilen performansları verilmiştir.

Çizelge 5. 7 YOLOv10 m modeli eğitim değerleri

Model	mAP50	mAP50-95	Precision (Pr)	Recall(Re)	F1 Score	Eğitim Süresi (Saat)
YOLOv10 m	93.7%	80.5%	95.7%	90.0%	93.0%	0.838

YOLOv10 m modeli 2 ortofoto üzerinde test edilmiştir. Çalışma alanı 1 de 44 adet ağaç etiketlemiştir (Resim 5.13) Çalışma alanı 2 de 42 adet ağaç etiketlemiştir (Resim 5.14) Test işlemi Python kodları ile yapılmıştır. YOLOv10 m modeliyle test edilen Çalışma alanı 1 65 ağaç içinden 44 ağaç etiketleyerek %67,69 tespit oranı elde edilmiştir. YOLOv10 m modeliyle test edilen Çalışma alanı 2 51 ağaç içinden 42 ağaç etiketleyerek %82,35 tespit oranı elde edilmiştir.



Resim 5. 13 YOLOv10 m modeli ağaç tespiti çalışma alanı 1




Resim 5. 14 YOLOv10 m modeli ağaç tespiti çalışma alanı 2

5.1.15 YOLOv11 Ağaç Tespit Modeli


Bu bölümde eğitim veri seti hazırlandıktan sonra bulut depolama hizmetine yükleme yapılmıştır. YOLOv11 m modeli seçilmiştir. Eğitim için Ultralytics kodları kullanılarak Google Colab ortamında NVIDIA A100 SXM4 GPU kullanılarak eğitim işlemi ve Python kodları ile test işlemleri gerçekleştirilmiştir. Model için eğitimlerde epoch sayısı 200, batch = 64, lr0 = 0.004 ve optimizer SGD seçilmiştir.

5.1.16 YOLOv11 Doğruluk Analizi


Google Colab ile eğitilen YOLOv11 m modeli 0 ile 1 arasındaki doğruluğu verilmiştir. Bu değerlerin 1'e yaklaşması, modelin performansının arttığını gösterir. Şekil 5.44'de Precision, Şekil 5.45'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. 44 YOLOv11 m modelinin kesinlik analizi




Şekil 5. 45 YOLOv11 m modelinin duyarlılık eğrisi




Şekil 5. 46 YOLOv11 m modelinin kesinlik-duyarlılık eğrisi

Şekil 5.46’da Precision-Recall eğrisi yer almaktadır. Bu eğride ağaç için 0.937 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. 47 YOLOv11 m modelinin F1-Güven eğrisi


Şekil 5.47’de F1-Güven eğrisi yer almaktadır. Bu eğride ağaç için 0.93 F1 değeri olarak ifade edilmiştir.



Şekil 5. 48 YOLOv11 m modeli performans grafikleri

Şekil 5.48 de sunulan bulgular, eğitim sürecindeki kayıp değerlerinin (soldaki üç grafik) istikrarlı bir biçimde gerilediğini göstermektedir. Bu gelişme, modelin konum belirleme, sınıflandırma ve sınırlayıcı kutu regresyonu görevlerindeki isabetliliğinin giderek yükseldiğine işaret etmektedir. Diğer taraftan, doğrulama kayıpları (sol alt üç grafik) dalgalanma sergilemekle birlikte büyük ölçüde düşük seviyelerde seyretmiş ve bu durum modelin genelleme yeteneğini muhafaza ettiğini kanıtlamıştır. Precision metriğinde gözlemlenen artış, yanlış pozitif sayısının düştüğünü; recall metriğindeki yükseliş ise nesne tespit oranının geliştiğini göstermektedir. Son olarak, mAP50 ve mAP50-95 skorlarındaki devamlı ilerleme, modelin bütünsel başarımı hakkında değerli çıkarımlar sunmaktadır.

Ayrıca, Precision ve Recall grafiklerinde de modelin doğruluğunda artış kaydedilmiştir. Eğitim sürecinin sonunda, precision 0.955 ve recall 0.906, F1 0.930 olarak elde edilmiştir. Precision, Recall ve F1 skoru modelin genel performansı hakkında önemli bilgiler sunmaktadır.



Şekil 5. 49 YOLOv11 m modeli karışıklık matrisi

Şekil 5.49’da ifade edilen eğitilen model için karışıklık matrisi değerleridir. 2587, 124, 256 sayıları sırasıyla TP, FP, FN değerlerini ifade eder. Çizelge 5.8’de YOLOv11 m modelinin eğitimi sonrası elde edilen performansları verilmiştir.


Çizelge 5. 8 YOLOv11 m modeli eğitim değerleri

Model	mAP50	mAP50-95	Precision (Pr)	Recall(Re)	F1 Score	Eğitim Süresi (Saat)
YOLOv11 m	93.7%	80.4%	96.3%	90.6%	93.0%	0.766

YOLOv11 m modeli 2 ortofoto üzerinde test edilmiştir.

Çalışma alanı 1 de 38 adet ağaç etiketlemiştir (Resim 5.15). Çalışma alanı 2 de 36 adet ağaç etiketlemiştir (Resim 5.16). Test işlemi Python kodları ile yapılmıştır. YOLOv11 m modeliyle test edilen Çalışma alanı 1 65 ağaç içinden 38 ağaç etiketleyerek %58,46 tespit

oranı elde edilmiştir. YOLOv11 m modeliyle test edilen Çalışma alanı 2 51 ağaç içinden 36 ağaç etiketleyerek %70,59 tespit oranı elde edilmiştir.



Resim 5. 15 YOLOv11 m modeli ağaç tespiti çalışma alanı 1




Resim 5. 16 YOLOv11 m modeli ağaç tespiti çalışma alanı 2

5.1.17 YOLOv12 Ağaç Tespit Modeli


Bu bölümde eğitim veri seti hazırlandıktan sonra bulut depolama hizmetine yükleme yapılmıştır. YOLOv12 m modeli seçilmiştir. Eğitim için Ultralytics kodları kullanılarak Google Colab ortamında NVIDIA A100 SXM4 GPU kullanılarak eğitim işlemi ve Python kodları ile test işlemleri gerçekleştirilmiştir. Model için eğitimlerde epoch sayısı 200, batch = 64, lr0 = 0.004 ve optimizer SGD seçilmiştir.

5.1.18 YOLOv12 Doğruluk Analizi


Google Colab ile eğitilen YOLOv12 m modeli 0 ile 1 arasındaki doğruluğu verilmiştir. Bu değerlerin 1'e yaklaşması, modelin performansının arttığını gösterir. Şekil 5.50'de Precision, Şekil 5.51'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. 50 YOLOv12 m modelinin kesinlik analizi




Şekil 5. 51 YOLOv12 m modelinin duyarlılık eğrisi




Şekil 5. 52 YOLOv12 m modelinin kesinlik-duyarlılık eğrisi

Şekil 5.52’da Precision-Recall eğrisi yer almaktadır. Bu eğride ağaç için 0.937 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. 53 YOLOv12 m modelinin F1-Güven eğrisi


Şekil 5.53’de F1-Güven eğrisi yer almaktadır. Bu eğride ağaç için 0.93 F1 değeri olarak ifade edilmiştir.



Şekil 5. 54 YOLOv12 m modeli performans grafikleri

Şekil 5.54 da sunulan bulgular, eğitim sürecindeki kayıp değerlerinin (soldaki üç grafik) istikrarlı bir biçimde gerilediğini göstermektedir. Bu gelişme, modelin konum belirleme, sınıflandırma ve sınırlayıcı kutu regresyonu görevlerindeki isabetliliğinin giderek yükseldiğine işaret etmektedir. Diğer taraftan, doğrulama kayıpları (sol alt üç grafik) dalgalanma sergilemekle birlikte büyük ölçüde düşük seviyelerde seyretmiş ve bu durum modelin genelleme yeteneğini muhafaza ettiğini kanıtlamıştır. Precision metriğinde gözlemlenen artış, yanlış pozitif sayısının düştüğünü; recall metriğindeki yükseliş ise nesne tespit oranının geliştiğini göstermektedir. Son olarak, mAP50 ve mAP50-95 skorlarındaki devamlı ilerleme, modelin bütünsel başarımı hakkında değerli çıkarımlar sunmaktadır.

Ayrıca, Precision ve Recall grafiklerinde de modelin doğruluğunda artış kaydedilmiştir. Eğitim sürecinin sonunda, precision 0.950 ve recall 0.908, F1 0.930 olarak elde edilmiştir. Precision, Recall ve F1 skoru modelin genel performansı hakkında önemli bilgiler sunmaktadır.




Şekil 5. 55 YOLOv12 m modeli karışıklık matrisi

Şekil 5.55’de ifade edilen eğitilen model için karışıklık matrisi değerleridir. 2600, 121, 243 sayıları sırasıyla TP, FP, FN değerlerini ifade eder. Çizelge 5.9’de YOLOv12 m modelinin eğitimi sonrası elde edilen performansları verilmiştir.

Çizelge 5. 9 YOLOv12 m modeli eğitim değerleri

Model	mAP50	mAP50-95	Precision (Pr)	Recall(Re)	F1 Score	Eğitim Süresi (Saat)
YOLOv12 m	93.7%	80.2%	95.0%	90.8%	93.0%	1.042

YOLOv12 m modeli 2 ortofoto üzerinde test edilmiştir. Çalışma alanı 1 de 43 adet ağaç etiketlemiştir (Resim 5.17). Çalışma alanı 2 de 40 adet ağaç etiketlemiştir (Resim 5.18) Test işlemi Python kodları ile yapılmıştır. YOLOv12 m modeliyle test edilen Çalışma alanı 1 65 ağaç içinden 43 ağaç etiketleyerek %66,15 tespit oranı elde edilmiştir. YOLOv12 m modeliyle test edilen Çalışma alanı 2 51 ağaç içinden 40 ağaç etiketleyerek %78,43 tespit oranı elde edilmiştir.



Resim 5. 17 YOLOv12 m modeli ağaç tespiti çalışma alanı 1




Resim 5.18 YOLOv12 m modeli ağaç tespiti çalışma alanı 2

5.1.19 YOLOv26 Ağaç Tespit Modeli


Bu bölümde eğitim veri seti hazırlandıktan sonra bulut depolama hizmetine yükleme yapılmıştır. YOLOv26 m modeli seçilmiştir. Eğitim için Ultralytics kodları kullanılarak Google Colab ortamında NVIDIA A100 SXM4 GPU kullanılarak eğitim işlemi ve Python kodları ile test işlemleri gerçekleştirilmiştir. Model için eğitimlerde epoch sayısı 200, batch = 64, lr0 = 0.004 ve optimizör SGD seçilmiştir.

5.1.20 YOLOv26 Doğruluk Analizi


Google Colab ile eğitilen YOLOv26 m modeli 0 ile 1 arasındaki doğruluğu verilmiştir. Bu değerlerin 1'e yaklaşması, modelin performansının arttığını gösterir. Şekil 5.56'da Precision, Şekil 5.57'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. 56 YOLOv26 m modelinin kesinlik analizi




Şekil 5. 57 YOLOv26 m modelinin duyarlılık eğrisi




Şekil 5. 58 YOLOv26 m modelinin kesinlik-duyarlılık eğrisi

Şekil 5.58’da Precision-Recall eğrisi yer almaktadır. Bu eğride ağaç için 0.941 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. 59 YOLOv26 m modelinin F1-Güven eğrisi


Şekil 5.59’da F1-Güven eğrisi yer almaktadır. Bu eğride ağaç için 0.93 F1 değeri olarak ifade edilmiştir.



Şekil 5. 60 YOLOv26 m modeli performans grafikleri

Şekil 5.60 da sunulan bulgular, eğitim sürecindeki kayıp değerlerinin (soldaki üç grafik) istikrarlı bir biçimde gerilediğini göstermektedir. Bu gelişme, modelin konum belirleme, sınıflandırma ve sınırlayıcı kutu regresyonu görevlerindeki isabetliliğinin giderek yükseldiğine işaret etmektedir. Diğer taraftan, doğrulama kayıpları (sol alt üç grafik) dalgalanma sergilemekle birlikte büyük ölçüde düşük seviyelerde seyretmiş ve bu durum modelin genelleme yeteneğini muhafaza ettiğini kanıtlamıştır. Precision metriğinde gözlemlenen artış, yanlış pozitif sayısının düştüğünü; recall metriğindeki yükseliş ise nesne tespit oranının geliştiğini göstermektedir. Son olarak, mAP50 ve mAP50-95 skorlarındaki devamlı ilerleme, modelin bütünsel başarımı hakkında değerli çıkarımlar sunmaktadır.

Ayrıca, Precision ve Recall grafiklerinde de modelin doğruluğunda artış kaydedilmiştir. Eğitim sürecinin sonunda, precision 0.954 ve recall 0.903, F1 0.930 olarak elde edilmiştir. Precision, Recall ve F1 skoru modelin genel performansı hakkında önemli bilgiler sunmaktadır.



Şekil 5. 61 YOLOv26 m modeli karışıklık matrisi


Şekil 5.61’da ifade edilen eğitilen model için karışıklık matrisi değerleridir. 2617, 173, 226 sayıları sırasıyla TP, FP, FN değerlerini ifade eder. Çizelge 5.10’de YOLOv26 m modelinin eğitimi sonrası elde edilen performansları verilmiştir.

Çizelge 5. 10 YOLOv26 m modeli eğitim değerleri

Model	mAP50	mAP50-95	Precision (Pr)	Recall(Re)	F1 Score	Eğitim Süresi (Saat)
YOLOv26 m	94.1%	77.1%	95.4%	90.3%	93.0%	0.871

YOLOv26 m modeli 2 ortofoto üzerinde test edilmiştir. Çalışma alanı 1 de 47 adet ağaç etiketlemiştir (Resim 5.19). Çalışma alanı 2 de 40 adet ağaç etiketlemiştir (Resim 5.20). Test işlemi Python kodları ile yapılmıştır. YOLOv26 m modeliyle test edilen Çalışma alanı 1 65 ağaç içinden 47 ağaç etiketleyerek %72,31 tespit oranı elde edilmiştir.

YOLOv26 m modeliyle test edilen Çalışma alanı 2 51 ağaç içinden 40 ağaç etiketleyerek %78,43 tespit oranı elde edilmiştir.



Resim 5. 19 YOLOv26 m modeli ağaç tespiti çalışma alanı 1



Resim 5. 20 YOLOv26 m modeli ağaç tespiti çalışma alanı

6 BULGULAR

Bu bölümde, RT-DETR L, YOLOv3 m, YOLOv5, YOLOv6, YOLOv8, YOLOv9, YOLOv10, YOLOv11, YOLOv12 ve YOLOv26 algoritmalarının eğitim performansları incelenmiş ve elde edilen sonuçlar tablo halinde sunulmuştur. Değerlendirmeler, Ultralytics kodları ile eğitilen modellerin eğitim çıktılarına göre değerlendirilmiştir (Çizelge 6.1).

YOLOv9, %94,20 mAP50 değeriyle eğitilen modeller arasında en yüksek başarımlarına ulaşmıştır. YOLOv26 (%94,10 mAP50) ve YOLOv5 (%94,00 mAP50) modelleri ise YOLOv9'u yakından takip ederek yüksek doğruluk sergilemiştir. YOLOv9 aynı zamanda %96,30 Precision değeriyle en yüksek kesinliğe sahip olmuştur.

YOLOv3 m, 0,461 saatlik en kısa eğitim süresine karşın %92,90 mAP50 başarımlarıyla etkili bir performans ortaya koymuştur. YOLOv11, 0,766 saatlik eğitim süresiyle hızlı eğitim avantajı sunarken %93,70 mAP50 ve %95,50 Precision değerleriyle dengeli sonuçlar elde etmiştir. YOLOv8 (%93,50 mAP50, %95,50 Precision, %90,60 Recall) ve YOLOv11 (%93,70 mAP50, %95,50 Precision, %90,60 Recall) modelleri birbirine yakın metriklerle benzer performans göstermiştir.

YOLOv10, %95,70 Precision ile yüksek kesinlik sağlarken; YOLOv12, %90,80 Recall değeriyle en yüksek geri çağırma oranına ulaşmıştır. RT-DETR L, 1,844 saatlik en uzun eğitim süresine rağmen %93,50 mAP50 değeriyle ortalama bir performans sergilemiştir. YOLOv6 ise %87,70 Recall değeriyle geri çağırma metriğinde diğer modellerin gerisinde kalmıştır.

Tüm modeller 200 epok üzerinden eğitilmiş olup; YOLOv5, YOLOv8, YOLOv9, YOLOv10, YOLOv11, YOLOv12 ve YOLOv26 modelleri %93,00 F1 Score ile en yüksek F1 değerine ulaşmıştır. (Çizelge 6.1).

Çizelge 6. 1 YOLO modellerinin eğitim değerlendirmeleri

Model	EPOK	mAP50	Precision (Pr)	Recall(Re)	F1 Score	Eğitim Süresi(Saat)
RT-DETR L	200	93.50%	92.10%	89.20%	91.00%	1.844
YOLOv3 m	200	92.90%	93.60%	89.10%	91.00%	0.461
YOLOv5 m	200	94.00%	95.40%	90.30%	93.00%	0.713
YOLOv6 m	200	93.70%	92.70%	87.70%	90.00%	0.810
YOLOv8 m	200	93.50%	95.50%	90.60%	93.00%	0.717
YOLOv9 m	200	94.20%	96.30%	89.90%	93.00%	0.940
YOLOv10 m	200	93.70%	95.70%	90.00%	93.00%	0.838
YOLOv11 m	200	93.70%	95.50%	90.60%	93.00%	0.766
YOLOv12 m	200	93.70%	95.00%	90.80%	93.00%	1.042
YOLOv26 m	200	94.10%	95.40%	90.30%	93.00%	0.871

Çizelge'deki sonuçlara göre, Çalışma alanı 1'de 65 ve Çalışma alanı 2'de 51 mevcut ağaç referans alınarak yapılan değerlendirmede; RT-DETR L modeli Çalışma alanı 1'de 60 ağaç tespiti (%92,31 doğruluk) ve Çalışma alanı 2'de 54 ağaç tespiti (%5,88 over-detection) ile toplam 114 nesne tespit edilmiştir. Çalışma alanı 2'deki %105,88 tespit oranı, mevcut ağaç sayısından (51) daha fazla tespit (54) yapıldığını göstererek modelin aşırı tespit (over-detection) eğiliminde olduğunu ortaya koymaktadır.

YOLOv9 m, Çalışma alanı 1'de 46 tespit (%70,77) ve Çalışma alanı 2'de 50 tespit (%98,04) ile toplam 96 ağaç tespiti ve %84,40 ortalama doğruluk oranıyla ikinci en yüksek başarıyı elde etmiştir. YOLOv26 m ise her iki çalışma alanında dengeli sonuçlar vererek (Çalışma alanı 1: 47 tespit, %72,31; Çalışma alanı 2: 40 tespit, %78,43) toplam 87 tespit ve %75,37 ortalama doğruluk oranına ulaşmıştır. YOLOv10 m (toplam 86 tespit, %75,02 ortalama doğruluk) ve YOLOv12 m (toplam 83 tespit, %72,29 ortalama doğruluk) modelleri orta düzeyde performans sergilemiştir.

YOLOv8 m, Çalışma alanı 1’de 35 tespit (%53,85) ile en düşük doğruluk oranına sahip olmasına karşın Çalışma alanı 2’de 46 tespit (%90,20) ile önemli bir iyileşme göstererek toplam 81 tespit ve %72,02 ortalama doğruluk oranı elde etmiştir. Benzer şekilde YOLOv5 m ve YOLOv6 m modelleri de toplamda 81’er ağaç tespitiyle aynı sayıya ulaşmış ancak farklı alansal dağılımlar sergilemiştir (YOLOv5 m: %69,70; YOLOv6 m: %70,33 ortalama doğruluk).

YOLOv3 m (toplam 75 tespit, %64,87 ortalama doğruluk) ve YOLOv11 m (toplam 74 tespit, %64,52 ortalama doğruluk) modelleri birbirine yakın ve en düşük performans grubunda yer almıştır. Çalışma alanı 2’de genel olarak daha yüksek doğruluk oranları elde edilmiş olup, bu durum alanların farklı zorluk derecelerine, görsel karmaşıklığına veya veri dağılımına işaret etmektedir. Tüm modeller 640×640 piksel çözünürlükte çalışmış olup; aynı giriş boyutuna rağmen farklı tespit ve doğruluk performansları sergileyen bu modeller, mimari yapının, özellik çıkarım kapasitesinin ve sınırlayıcı kutu (bounding box) stratejilerinin sonuçlar üzerinde belirleyici olduğunu ortaya koymaktadır. (Çizelge 6.2).

Çizelge 6. 2 Çalışma alanı 1 ve Çalışma alanı 2 için tespit edilen ağaç sayıları

Model	Çalışma alanı 1 (Ağaç sayısı)	Çalışma alanı 2 (Ağaç sayısı)	Toplam
RT-DETR L	60	54	114
YOLOv3 m	41	34	75
YOLOv5 m	46	35	81
YOLOv6 m	43	38	81
YOLOv8 m	35	46	81
YOLOv9 m	46	50	96
YOLOv10 m	44	42	86
YOLOv11 m	38	36	74
YOLOv12 m	43	40	83
YOLOv26 m	47	40	87

7 TARTIŞMA ve SONUÇ

Bu çalışmada, derin öğrenme tabanlı nesne tespit algoritmalarından olan RT-DETR L, YOLOv3 m, YOLOv5, YOLOv6, YOLOv8, YOLOv9, YOLOv10, YOLOv11, YOLOv12 ve YOLOv26 modellerinin ağaç tespiti performansları detaylı bir şekilde incelenmiştir. Bulgular, her bir modelin kendine özgü güçlü ve zayıf yönlerini ortaya koyarak, uzaktan algılama verileri üzerinden ağaç tespiti konusundaki mevcut durumu ve gelecekteki potansiyeli hakkında önemli çıkarımlar sunmaktadır.

Tespit performansları incelendiğinde; RT-DETR L modeli Çalışma alanı 1'de 60 ağaç tespiti (%92,31 doğruluk) ve Çalışma alanı 2'de 54 ağaç tespiti (%5,88 over-detection) ile toplam 114 nesne tespit edilmiştir. YOLOv9, Çalışma alanı 1'de 46 tespit (%70,77) ve Çalışma alanı 2'de 50 tespit (%98,04) ile toplam 96 ağaç tespiti ve %84,40 ortalama doğruluk oranıyla ikinci en yüksek başarıyı elde etmiş, bu durum modelin hem yüksek doğruluk hem de dengeli tespit kapasitesine sahip olduğunu göstermektedir. YOLOv26 ise her iki çalışma alanında dengeli sonuçlar vererek (Çalışma alanı 1: 47 tespit, %72,31; Çalışma alanı 2: 40 tespit, %78,43) toplam 87 tespit ve %75,37 ortalama doğruluk oranına ulaşmıştır. YOLOv10 (toplam 86 tespit, %75,02 ortalama doğruluk) ve YOLOv12 (toplam 83 tespit, %72,29 ortalama doğruluk) modelleri orta düzeyde performans sergilemiştir.

YOLOv8, Çalışma alanı 1'de 35 tespit (%53,85) ile en düşük doğruluk oranına sahip olmasına karşın Çalışma alanı 2'de 46 tespit (%90,20) ile önemli bir iyileşme göstererek toplam 81 tespit ve %72,02 ortalama doğruluk oranı elde etmiştir. Benzer şekilde YOLOv5 ve YOLOv6 modelleri de toplamda 81'er ağaç tespitiyle aynı sayıya ulaşmış ancak farklı alansal dağılımlar sergilemiştir (YOLOv5: %69,70; YOLOv6: %70,33 ortalama doğruluk). YOLOv6 ayrıca %87,70 Recall değeriyle geri çağırma metriğinde diğer modellerin gerisinde kalmıştır. YOLOv3 (toplam 75 tespit, %64,87 ortalama doğruluk) ve YOLOv11 (toplam 74 tespit, %64,52 ortalama doğruluk) modelleri birbirine yakın ve en düşük performans grubunda yer almıştır. Çalışma alanı 2'de genel olarak daha yüksek doğruluk oranları elde edilmiş olup, bu durum alanların farklı zorluk derecelerine, görsel karmaşıklığına veya veri dağılımına işaret etmektedir. Tüm modeller 640×640

piksel çözünürlükte çalışmasına rağmen farklı tespit performansları sergilemiş, bu durum mimari yapının ve özellik çıkarım kapasitesinin sonuçlar üzerinde belirleyici olduğunu ortaya koymaktadır.

Uzaktan algılama tabanlı ağaç envanterlenmesi, morfolojik çeşitlilik, taç örtüsü örtüşmeleri, mevsimsel değişkenlik ve çevresel faktörlerin neden olduğu belirsizlikler nedeniyle kesin sayısal değerler sunmakta sınırlı kalmaktadır (Liang vd. 2016). Bu kısıtlılıklar doğrultusunda, dijital platformlardan elde edilen bulgular tahmin niteliği taşımakta olup, doğrulama amacıyla saha ölçümleri ve çok kaynaklı veri bütünleştirme yaklaşımlarının kullanılması gerekmektedir.

Sonuç olarak, bu çalışma, farklı derin öğrenme mimarilerinin ağaç tespiti görevlerinde sunduğu olanakları ve sınırlılıkları ortaya koymuştur. Yüksek başarımlı oranı sağlayan YOLOv9 modeli hem eğitim metriklerinde hem de tespit doğruluğunda üstün performans sergileyerek genel ağaç tespiti görevleri için en güvenilir seçenek olarak öne çıkmaktadır. Hızlı eğitim süresi sunan YOLOv3, zaman kısıtlı pratik uygulamalar için ideal bir alternatif oluştururken; RT-DETR L yüksek tespit kapasitesine sahip olmakla birlikte aşırı tespit riski nedeniyle hassasiyet-kesinlik dengesi açısından dikkatle değerlendirilmelidir. YOLOv26 dengeli performansı ile güvenilir sonuçlar üretirken; YOLOv11 ve YOLOv3 düşük tespit performanslarıyla sınırlı kullanım alanlarına işaret etmektedir. Dolayısıyla istenilen hassasiyetli modellerin oluşturulması sürecinde zaman, kaynak, doğru yöntem ve disiplinli çalışmaya bağlı olduğu gözükmemektedir. Gelecek çalışmaların, küçük nesne tespitinde iyileştirmeler, veri çeşitliliğinin artırılması ve arazi doğrulamalarıyla desteklenmesi, bu alandaki başarıyı daha da ileriye taşıyacaktır.

Bu çalışmada, YOLO ve RT-DETR tabanlı derin öğrenme mimarileri kullanılarak ortofoto görüntülerinden ağaç tespiti gerçekleştirilmiştir. Mevcut literatür imkanları çerçevesinde yürütülen bu araştırma, gelecek dönemlerde uzaktan algılama teknikleri ve veri işleme detaylarına odaklanılarak, çalışmanın Geomatik Mühendisliği disiplinine yönlendirilmesi hedeflenmektedir. YOLO algoritmasının literatürde yoğun biçimde incelenen alanlardan biri olması nedeniyle, ileriki çalışmalarda literatür taramasının daha kapsamlı bir şekilde genişletilmesi planlanmaktadır.

Sonraki arařtırmalarda, özünürlük etkisi, mevsimsel deęiřkenlik, veri artırma stratejilerinin performansa etkisi, farklı yer örnekleme mesafesi (GSD) deęerleri ve eřitli ağa türlerinin tespit başarımına olan katkısı gibi parametreler araştırma konusu olarak ele alınması öngörülmektedir. Bu doęrultuda; özünürlük etkisi, mevsim etkisi, veri eřitlilięinin artırılması etkisi, farklı GSD etkisi, farklı ağa türü etkisi alanlarındaki rizikolar ele alınarak alıřmalar yürütölmek istenmektedir.

8 KAYNAKLAR

- Akın E, Şahin M E, 2024, Derin Öğrenme ve Yapay Sinir Ağı Modelleri Üzerine Bir İnceleme. EMO Bilimsel Dergi, 14(1), 27-38.
- Atik M E, Arkali M, 2026, Benchmarking YOLO and Transformer-Based Detectors for Olive Tree Crown Identification in UAV Imagery. Geomatics, 6(2), 22.
- Carion N, Massa F, Synnaeve G, Usunier N, Kirillov A, Zagoruyko S, 2020, End-to-end Object Detection with Transformers, In *European Conference on Computer Vision*, Cham: Springer International Publishing, pp. 213-229.
- Cazzolla Gatti R, Reich P B, Gamarra J G, Crowther T, Hui C, Morera A, Liang J, 2022, The Number of Tree Species on Earth, *Proceedings of the National Academy of Sciences*, 119(6).
- Fetzer J H, 1990, What is Artificial Intelligence?, In *Artificial Intelligence: Its Scope and Limits*, Dordrecht: Springer Netherlands, pp. 3-27.
- Sarre A, 2020, Global Forest Resources Assessment, 2020: Main Report, Food and Agriculture Organization of the United Nations.
- Fukushima K, 1980, Neocognitron: A Self-Organizing Neural Network Model for a Mechanism of Pattern Recognition Unaffected by Shift in Position, *Biological cybernetics*, 36(4), 193-202.
- G Braga J R, Peripato V, Dalagnol R, P Ferreira M, Tarabalka Y, OC Aragão L E, Wagner F H, 2020, Tree Crown Delineation Algorithm Based on a Convolutional Neural Network, *Remote Sensing*, 12(8), 1288.
- Girshick R, 2015, Fast r-cnn. In *Proceedings of the IEEE International Conference on Computer Vision*, pp. 1440-1448.
- Girshick R, Donahue J, Darrell T, Malik J, 2014, Rich Feature Hierarchies for accurate Object Detection and Semantic Segmentation, *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 580–587.
- Goodfellow I, Bengio Y, Courville A, Bengio Y, 2016, *Deep Learning* (Vol. 1, No. 2), Cambridge: MIT press, pp. 1-800.

- Grondin V, Fortin J M, Pomerleau F, Giguère P, 2023, Tree Detection and Diameter Estimation Based on Deep Learning, *Forestry*, 96(2), 264-276.
- He L, Zhou Y, Liu L, Cao W, Ma J, 2025, Research on Object Detection and Recognition in Remote Sensing Images Based on YOLOv11, *Scientific Reports*, 15(1), 96314.
- Hinton G E, Osindero S, Teh Y W, 2006, A Fast Learning Algorithm for Deep Belief Nets, *Neural computation*, 18(7), 1527-1554.
- Hochreiter S, Schmidhuber J, 1997, Long Short-Term Memory, *Neural Computation*, 9(8), 1735-1780.
- Huang Y, Ou B, Meng K, Yang B, Carpenter J, Jung J, Fei S, 2024, Tree Species Classification from UAV Canopy Images with Deep Learning Models, *Remote Sensing*, 16(20), 3836.
- Jaiswal S K, Agrawal R, 2024, A Comprehensive Review of YOLOv5: Advances in Real-time Object Detection, *International Journal of Innovative Research in Computer Science and Technology*, 12(3), 75-80.
- Jung H K, Choi G S, 2022, Improved YOLOv5: Efficient Object Detection Using Drone Images Under Various Conditions, *Applied Sciences*, 12(14), 7255.
- Krawczyk B, 2016, Learning from Imbalanced Data: Open Challenges and Future Directions, *Progress in Artificial Intelligence*, 5(4), 221-232.
- Krizhevsky A, Sutskever I, Hinton G E, 2012, Imagenet Classification with Deep Convolutional Neural Networks, *Advances in Neural Information Processing Systems*, 25.
- LeCun Y, Bengio Y, Hinton G, 2015, Deep learning, *Nature*, 521(7553), 436-444.
- LeCun Y, Boser B, Denker J S, Henderson D, Howard R E, Hubbard W, Jackel L D, 1989, Backpropagation Applied to Handwritten Zip Code Recognition, *Neural Computation*, 1(4), 541-551.
- Li S, Li Y, Li Y, Li M, Xu X, 2021, YOLO-FIRI: Improved YOLOv5 for Infrared Image Object Detection, *IEEE Access*, 9, 141482-141495.

- Liang X, Kankare V, Hyypä J, Wang Y, Kukko A, Haggrén H, Vastaranta M, 2016, Terrestrial Laser Scanning in Forest Inventories, *ISPRS Journal of Photogrammetry and Remote Sensing*, 115, 63-77.
- Liu Y, Zhao Q, Wang X, Sheng Y, Tian W, Ren Y, 2024, A Tree Species Classification Model Based on Improved YOLOv7 for Shelterbelts, *Frontiers in Plant Science*, 14, 1265025.
- Lou H, Duan X, Guo J, Liu H, Gu J, Bi L, Chen H, 2023, DC-YOLOv8: Small-size Object Detection Algorithm Based on Camera Sensor, *Electronics*, 12(10), 2323.
- Mahaur B, Mishra K K, 2023, Small-object Detection Based on YOLOv5 in Autonomous Driving Systems, *Pattern Recognition Letters*, 168, 123-130.
- Mazzei D, Ramjattan R, 2022, Machine Learning for Industry 4.0: A Systematic Review Using Deep Learning-Based Topic Modelling, *Sensors*, 22(22), 8641.
- Mo J, Lan Y, Yang D, Wen F, Qiu H, Chen X, Deng X, 2021, Deep Learning-based Instance Segmentation Method of Litchi Canopy from UAV-acquired Images, *Remote Sensing*, 13(19), 3919.
- Moraes A M, Pugliese L F, Santos R F D, Vitor G B, Braga R A D S, Silva F R D, 2025, Effectiveness of YOLO Architectures in Tree Detection: Impact of hyperparameter Tuning and SGD, Adam and AdamW Optimizers, *Standards*, 5(1), 9.
- Nowak D J, Crane D E, 2002, Carbon Storage and Sequestration by Urban Trees in the USA, *Environmental Pollution*, 116(3), 381-389.
- Nowak D J, Dwyer J F, 2007, Understanding the Benefits and Costs of Urban Forest Ecosystems, In *Urban and Community Forestry in the Northeast*, Dordrecht: Springer Netherlands, pp. 25-46.
- Rasheed A F, Zarkoosh M, 2025, Optimized YOLOv8 for Multi-scale Object Detection, *Journal of Real-Time Image Processing*, 22(1), 15.
- Redmon J, Farhadi A, 2018, YOLOv3: An incremental improvement.

- Redmon J, Divvala S, Girshick R, Farhadi A, 2016, You Only Look Once: Unified, Real-time Object Detection, In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, pp. 779-788.
- Ren S, He K, Girshick R, Sun J, 2015, Faster r-cnn: Towards Real-time Object Detection with Region Proposal Networks, *Advances in Neural Information Processing Systems*, 28.
- Rumelhart D E, Hinton G E, Williams R J, 1986, Learning Representations by Back-Propagating Errors, *Nature*, 323(6088), 533-536.
- Sapkota R, Flores-Calero M, Qureshi R, Badgujar C, Nepal U, Poulouse A, Karkee M, 2025, YOLO Advances to its Genesis: A Decadal and Comprehensive Review of the You Only Look Once (YOLO) Series, *Artificial Intelligence Review*, 58(9), 274.
- Säumel I, Weber F, Kowarik I, 2016, Toward Livable and Healthy Urban Streets: Roadside Vegetation Provides Ecosystem Services Where People Live and Move, *Environmental Science & Policy*, 62, 24-29.
- Schmidhuber J, 2015, Deep Learning in Neural Networks: An Overview, *Neural Networks*, 61, 85-117.
- Sokolova M, Lapalme G, 2009, A Systematic Analysis of Performance Measures for Classification Tasks, *Information Processing & Management*, 45(4), 427-437.
- Srivastava N, Hinton G, Krizhevsky A, Sutskever I, Salakhutdinov R, 2014, Dropout: a simple Way to Prevent Neural Networks from Overfitting, *The Journal of Machine Learning Research*, 15(1), 1929-1958.
- Stark T, Pardo J, Wurm M, Leichtle T, Martin K, Taubenböck H, 2025, Urban Tree Detection: Comparing YOLOv8 and DeepForest for Accurate Single-Tree Identification from Aerial Imagery, In 2025 Joint Urban Remote Sensing Event (JURSE), pp. 1-4.
- Tian Y, Ye Q, Doermann D, 2026, Yolov12: Attention-centric Real-time object Detectors, *Advances in Neural Information Processing Systems*, 38, 78433-78457.

- Trigka M, Dritsas E, 2025, A Comprehensive Survey of Machine Learning Techniques and Models for Object Detection, *Sensors*, 25(1), 214.
- Ünsal G, Yılmaz F G K, 2024, Eğitimde Yapay Zekâ ve Derin Öğrenme Alanında 2019-2023 Yıllar Arasında Yayınlanan Makalelerin Betimsel Analizi, *Mehmet Akif Ersoy Üniversitesi Uygulamalı Bilimler Dergisi*, 8(2), 177-197.
- Varghese R, Sambath M, 2024, YOLOv8: A Novel Object Detection Algorithm with Enhanced Performance and Robustness, 2024 International Conference on Computer Communication and Informatics (ICCCI), 1–6.
- Velasquez-Camacho, L., Etxegarai, M., & de-Miguel, S. (2023). Implementing Deep Learning algorithms for urban tree detection and geolocation with high-resolution aerial, satellite, and ground-level images. *Computers, Environment and Urban Systems*, 105, 102025.
- Wang A, Chen H, Liu L, Chen K, Lin Z, Han J, Ding G, 2024a, YOLOv10: Real-time End-to-end Object Detection, *Advances in Neural Information Processing Systems*, 37, 107984-108011.
- Wang C Y, Yeh I H, Mark Liao H Y, 2024b, YOLOv9: Learning What You Want to learn Using Programmable Gradient Information, In *European Conference on Computer Vision*, Springer Nature Switzerland, pp. 1-21.
- Wang H, Liu C, Cai Y, Chen L, Li Y, 2024c, YOLOv8-QSD: An Improved Small Object Detection Algorithm for Autonomous Vehicles Based on YOLOv8, *IEEE Transactions on Instrumentation and Measurement*, 73, 1-16.
- Wang Y, Zhang W, Gao R, Jin Z, Wang X, 2021, Recent Advances in the Application of Deep Learning Methods to Forestry, *Wood Science and Technology*, 55(5), 1171-1202.
- Wibowo H, Sitanggang I S, Mushthofa M, Adrianto H A, 2022, Large-scale Oil Palm Trees Detection from High-resolution Remote Sensing Images Using Deep Learning, *Big Data and Cognitive Computing*, 6(3), 89.
- Wu T, Dong Y, 2023, YOLO-SE: Improved YOLOv8 for Remote Sensing Object Detection and Recognition, *Applied Sciences*, 13(24), 12977.

- Wu Z, Zhen H, Zhang X, Bai X, Li X, 2025, SEMA-YOLO: Lightweight Small Object Detection in Remote Sensing Image via Shallow-layer Enhancement and Multi-scale Adaptation, *Remote Sensing*, 17(11), 1917.
- Xu J, Chen H, Xiao X, Zhao M, Liu B, 2025, Gesture Object Detection and Recognition Based on YOLOv11, *Applied and Computational Engineering*.
- Zhao H, Morgenroth J, Pearse G, Schindler J, 2023, A Systematic Review of Individual Tree Crown Detection and Delineation with Convolutional Neural Networks (CNN), *Current Forestry Reports*, 9(3), 149-170.
- Zhao Y, Lv W, Xu S, Wei J, Wang G, Dang Q, Chen J, 2024, Detrs Beat Yolos on Real-time Object Detection, In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, pp. 16965-16974.
- Zhao Z Q, Zheng P, Xu S T, Wu X, 2019, Object Detection with Deep Learning: A Review, *IEEE Transactions on Neural Networks and Learning Systems*, 30(11), 3212-3232.
- Zou Y, Liu S, 2025, Small Object Detection Algorithm Based on Improved YOLOv10 for Traffic Sign, *Transportation Research Interdisciplinary Perspectives*, 32, 101501.

İnternet Kaynakları

1. <https://github.com/lyuwenyu/RT-DETR>, 01.06.2026
2. <https://docs.ultralytics.com/tr/models/yolov3>, 14.05.2026
3. <https://viso.ai/deep-learning/yolov6/>, 14.05.2026
4. <https://learnopencv.com/yolov6-object-detection/>, 14.05.2026
5. <https://www.emergentmind.com/topics/yolov10>, 17.05.2026
6. <https://docs.ultralytics.com/models/yolo11>, 17.05.2026
7. <https://docs.ultralytics.com/models/yolo26/>, 03.01.2026
8. <https://www.swisstopo.admin.ch/en/orthoimage-swissimage-10>, 03.01.2026
9. <https://roboflow.com/>, 04.01.2026
10. <https://docs.roboflow.com/train/evaluate-trained-models>, 04.01.2026
11. <https://www.ultralytics.com/tr/blog/mean-average-precision-map-in-object-detection>, 04.01.2026
12. <https://blog.roboflow.com/mean-average-precision/>, 04.01.2026
13. <https://blog.roboflow.com/roboflow-verified-model-metrics/>, 04.01.2026
14. <https://www.ultralytics.com/tr/blog/mean-average-precision-map-in-object-detection>, 04.01.2026
15. <http://blog.roboflow.com/what-is-a-confusion-matrix/>, 04.01.2026
16. <http://blog.roboflow.com/train-test-split/>, 05.01.2026
17. <https://arxiv.org/abs/2407.20892>, 17.06.2026
18. <https://arxiv.org/abs/2410.17725>, 17.06.2026
19. <https://arxiv.org/abs/2305.09972>, 17.06.2026

ÖZGEÇMİŞ

Adı Soyadı : Hamdi Görkem KAYMAK
Doğum Yeri ve Tarihi : Tokat / 1997
Yabancı Dili : İngilizce / Almanca
İletişim (Telefon / e-posta) : +90 552 575 88 96 / mapengineer.gorkem@gmail.com

Eğitim Durumu (Kurum ve Yıl)

Lise : Tokat Atatürk Anadolu Lisesi (2011-2015)
Lisans : Tokat Gaziosmanpaşa Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Harita Mühendisliği (2015-2021)
Yüksek Lisans : Afyon Kocatepe Üniversitesi, Fen Bilimleri Enstitüsü, Harita Mühendisliği Yüksek Lisans (2023-2026)