

**KARAMANOĐLU MEHMETBEY ÜNİVERSİTESİ**  
**FEN BİLİMLERİ ENSTİTÜSÜ**

**YAPAY ZEKA KULLANILARAK DEPREM BÖLGELERİNDE DRONE İLE  
ALINAN GÖRÜNTÜLERDEN ENKAZ TESPİTİNİN  
GERÇEKLEŐTİRİLMESİ**

**YÜKSEK LİSANS TEZİ**

**Ömer Faruk PİCAK**

**Elektrik-Elektronik Mühendisliđi Anabilim Dalı**

**TEMMUZ 2025**



**KARAMANOĐLU MEHMETBEY ÜNİVERSİTESİ**  
**FEN BİLİMLERİ ENSTİTÜSÜ**

**YAPAY ZEKA KULLANILARAK DEPREM BÖLGELERİNDE DRONE İLE  
ALINAN GÖRÜNTÜLERDEN ENKAZ TESPİTİNİN  
GERÇEKLEŐTİRİLMESİ**



**YÜKSEK LİSANS TEZİ**

**Ömer Faruk PİCAK**

**220801112**

**Elektrik-Elektronik Mühendisliđi Anabilim Dalı**

**Tez DanıŐmanı: Doç. Dr. Kadir SABANCI**

**TEMMUZ 2025**



## TEZ ONAYI

Ömer Faruk PİCAK tarafından hazırlanan Yapay Zeka Kullanılarak Deprem Bölgelerinde Drone ile Alınan Görüntülerden Enkaz Tespitinin Gerçekleştirilmesi adlı tez çalışması aşağıdaki jüri tarafından oy birliği ile Karamanoğlu Mehmetbey Üniversitesi Fen Bilimleri Enstitüsü Elektrik Elektronik Mühendisliği Ana Bilim Dalı'nda **Yüksek Lisans Tezi** olarak kabul edilmiştir.

Danışman:

*(Doç. Dr. Kadir SABANCI)*

Jüri Üyeleri

İmza:

*Doç. Dr. Muhammed Fahri ÜNLERŞEN*

*Doç. Dr. Kadir SABANCI*

*Doç. Dr. Muhammet Fatih ASLAN*

Tez Savunma Tarihi: 25/07/2025

**Yukarıdaki sonucu onaylarım**

**Doç. Dr. Kadir SABANCI**

**Enstitü Müdürü**



## **BİLİMSEL ETİĞE UYGUNLUK**

Bu çalışmadaki tüm bilgilerin, akademik ve etik kurallara uygun bir şekilde elde edildiğini beyan ederim. Aynı zamanda bu kural ve davranışların gerektirdiği gibi, bu çalışmanın özünde olmayan tüm materyal ve sonuçları tam olarak aktardığımı ve referans gösterdiğimi belirtirim.

**İmza**  
**Ömer Faruk PİCAK**







*Enkaz altında kalan ve sesi duyulamayan tüm insanlara,*



## ÖNSÖZ

Tez çalışmam süresince engin bilgisi, yol göstericiliği ve desteğiyle bana her zaman rehber olan, akademik duruşu ve çalışmalarıyla örnek aldığım değerli danışmanım Doç. Dr. Kadir SABANCI'ya teşekkür ederim. Her zaman yanımda olan, sevgileri ve sabırlarıyla bana güç veren annem ve babama, desteğini her zaman hissettiren kıymetli ablam ve abime, fikirlerine güvendiğim, desteği ve anlayışıyla bu süreci benim için daha kolay kılan değerli arkadaşlarıma da içten teşekkürlerimi sunarım. Bu çalışmanın ortaya çıkmasında emeği geçen herkese şükranlarımı iletirim.

Temmuz 2025

Ömer Faruk PİCAK





# İÇİNDEKİLER

## Sayfa

<b>ÖNSÖZ</b> .....	<b>xi</b>
<b>İÇİNDEKİLER</b> .....	<b>xiii</b>
<b>KISALTMALAR</b> .....	<b>xv</b>
<b>TABLO LİSTESİ</b> .....	<b>xvii</b>
<b>ŞEKİL LİSTESİ</b> .....	<b>xix</b>
<b>ÖZET</b> .....	<b>xxi</b>
<b>ABSTRACT</b> .....	<b>xxiii</b>
<b>1. GİRİŞ</b> .....	<b>1</b>
1.1. Çalışmanın Amacı ve Önemi .....	2
<b>2. LİTERATÜR TARAMASI</b> .....	<b>3</b>
<b>3. KURAMSAL TEMELLER</b> .....	<b>9</b>
3.1. Yapay Zeka .....	9
3.2. Makine Öğrenmesi .....	10
3.3. Derin Öğrenme .....	12
3.4. Yapay Sinir Ağları .....	13
3.5. Evrişimsel Sinir Ağları .....	17
3.6. Nesne Tanıma.....	19
3.7. YOLO Algoritması.....	20
3.8. YOLOv8 Mimarisinin Temelleri .....	22
3.8.1. YOLOv8 performans değerleri .....	24
<b>4. MATERYAL VE METOT</b> .....	<b>27</b>
4.1. Çalışmanın Tasarımı .....	27
4.2. Veri Seti Hazırlığı .....	27
4.3. Veri Etiketleme Süreci .....	28
4.4. YOLOv8 Modeli ve Model Eğitimi .....	32
4.5. Test Ortamı ve Simülasyon Sahası.....	33
4.5.1. Kullanılan drone donanımı.....	33
4.5.2. Simülasyon sahasının oluşturulması .....	35
4.5.3. Görüntü toplama süreci .....	36
<b>5. BULGULAR</b> .....	<b>37</b>
5.1. Model Performans Değerlendirmesi .....	37
5.1.1. YOLOv8 nano .....	37

5.1.2. YOLOv8 small .....	38
5.1.3. YOLOv8 medium.....	39
5.1.4. YOLOv8 large .....	40
5.2. Model Performans Karşılaştırması .....	41
5.3. Görsel Çıktılar ve Örnek Tespitler .....	44
5.3.1. Gerçek afet saha tespiti.....	44
5.3.2. Simülasyon ortamda enkaz tespiti .....	55
5.4. Sonuçların Genel Değerlendirmesi.....	57
<b>6. SONUÇLAR VE TARTIŞMA.....</b>	<b>59</b>
<b>KAYNAKLAR.....</b>	<b>61</b>
<b>ÖZGEÇMİŞ.....</b>	<b>67</b>

## KISALTMALAR

<b>AI</b>	: Artificial Intelligence (Yapay Zekâ , YZ)
<b>AP</b>	: Average Precision (Ortalama Doğruluk)
<b>BiFPN</b>	: Bi-Directional Feature Pyramid Network (Çift Yönlü Özellik Hiyerarşisi Ağı)
<b>CBS</b>	: Coğrafi Bilgi Sistemi
<b>CIOU</b>	: Complete Intersection over Union (Tam Kesişim Üzerinden Birlik)
<b>CNN</b>	: Convolutional Neural Networks (Evrışimli Sinir Ağları)
<b>ÇKA</b>	: Çok Katmanlı Algılayıcı
<b>DCNv2</b>	: Deformable Convolutional Network v2 (Deforme Edilebilir Evrişimli Ağ v2)
<b>FN</b>	: False-Negative (Yanlış-Negatif Değer)
<b>Focal-EIOU</b>	: Focal Enhanced Intersection over Union (Fokal Geliştirilmiş Kesişim Üzerinden Birlik)
<b>FP</b>	: False-Positive (Yanlış-Pozitif Değer)
<b>FPS</b>	: Frame Per Second (Birim Saniyedeki Çerçeve Tarama Hızı)
<b>GIoU</b>	: Generalized Intersection over Union (Genelleştirilmiş Kesişim Üzerinden Birlik)
<b>İHA</b>	: İnsansız Hava Aracı
<b>KSA</b>	: Konvolüsyonel Sinir Ağı (CNN)
<b>mAP</b>	: Mean Average Precision (Ortalama Kesinlik Değerlerinin Ortalaması)
<b>NDMI</b>	: National Disaster Management Institute (Ulusal Afet Yönetimi Enstitüsü)

<b>OBIA</b>	: Object-Based Image Analysis (Nesne Tabanlı Görüntü Analizi)
<b>PR</b>	: Precision-Recall (Hassasiyet-Gerçeklik Eğrisi)
<b>R-CNN</b>	: Region-based Convolutional Neural Network (Bölge Tabanlı Konvolüsyonel Sinir Ağı)
<b>SAR</b>	: Synthetic Aperture Radar (Sentetik Açıklıklı Radar)
<b>SE</b>	: Squeeze-and-Excitation (Sıkıştırma ve Uyarım Katmanı)
<b>SPDConv</b>	: Spatially-Adaptive Convolution (Uzamsal Olarak Uyarlanabilir Konvolüsyon)
<b>SSD</b>	: Single Shot Detector (Tek Aşamalı Tespitçi)
<b>TKA</b>	: Tek Katmanlı Algılayıcı
<b>TN</b>	: True-Negative (Doğru-Negatif Değer)
<b>TP</b>	: True-Positive (Doğru-Pozitif Değer)
<b>VHR</b>	: Very High Resolution (Çok Yüksek Çözünürlüklü Uydu Görüntüsü)
<b>ViT</b>	: Vision Transformer (Görsel Dönüştürücü)
<b>YSA</b>	: Yapay Sinir Ağı (ANN)
<b>YZ</b>	: Yapay Zekâ (AI)

## TABLO LİSTESİ

### Sayfa

<b>Çizelge 3.1</b> : Biyolojik ve yapay sinir hücresi bileşenlerinin karşılaştırılması.....	14
<b>Çizelge 3.2</b> : YOLOv8 modellerinin mAP, hız, parametre sayısı ve FLOP değerlerine göre karşılaştırılması. ....	25
<b>Çizelge 5.1</b> : YOLOv8 nano model performans metrikleri. ....	38
<b>Çizelge 5.2</b> : YOLOv8 small model performans metrikleri. ....	39
<b>Çizelge 5.3</b> : YOLOv8 medium model performans metrikleri.....	40
<b>Çizelge 5.4</b> : YOLOv8 large model performans metrikleri. ....	41
<b>Çizelge 5.5</b> : Kullanılan modellerin performans metriklerinin karşılaştırılması. ....	41
<b>Çizelge 5.6</b> : Karışıklık matrislerinin karşılaştırılması. ....	44
<b>Çizelge 5.7</b> : Gerçek zamanlı performans karşılaştırması. ....	57



## ŞEKİL LİSTESİ

### Sayfa

Şekil 3.1 : Yapay zekâ, makine öğrenmesi ve derin öğrenmenin hiyerarşik ilişkisi. 10	10
Şekil 3.2 : Makine öğrenmesi türleri ve ilgili yaklaşımlar. .... 11	11
Şekil 3.3 : Makine öğrenmesi ve derin öğrenmede sınıflandırma süreci. .... 13	13
Şekil 3.4 : Biyolojik ve yapay nöron yapılarının karşılaştırılması. .... 14	14
Şekil 3.5 : Tek katmanlı algılayıcılar..... 15	15
Şekil 3.6 : Çok katmanlı algılayıcılar. .... 15	15
Şekil 3.7 : İleri beslemeli ağ yapısı..... 16	16
Şekil 3.8 : Geri beslemeli ağ yapısı. .... 16	16
Şekil 3.9 : Evrimsel sinir ağ yapısı. .... 18	18
Şekil 3.10 : Görüntüde sınırlayıcı kutularla nesne belirleme. .... 21	21
Şekil 3.11 : YOLO algoritmalarının evrimi..... 22	22
Şekil 3.12 : YOLOv8 mimarisi..... 23	23
Şekil 3.13 : YOLOv8 modelin gecikme–doğruluk dengesi. .... 24	24
Şekil 4.1 : Çalışmanın genel tasarımı. .... 27	27
Şekil 4.2 : Enkaz görüntülerinin veri kümesindeki dağılımı. .... 28	28
Şekil 4.3 : Etiketleme yapılmamış örnek görseller. .... 30	30
Şekil 4.4 : Etiketleme yapılmış örnek görseller..... 31	31
Şekil 4.5 : YOLOv8 eğitim süreci. .... 32	32
Şekil 4.6 : DJI mavic 2 drone görseli. .... 34	34
Şekil 4.7 : Enkaz görüntüsü yerleştirilmiş görsel. .... 35	35
Şekil 5.1 : YOLOv8 nano modeli eğitim grafikleri; (a) eğitim kutu kaybı, (b) eğitim nesne kaybı, (c) eğitim sınıf kaybı, (d) kesinlik, (e) duyarlılık, (f) doğrulama kutu kaybı, (g) doğrulama nesne kaybı, (h) doğrulama sınıf kaybı, (i) mAP_0.5, (j) mAP_0.95. .... 37	37
Şekil 5.2 : YOLOv8 small modeli eğitim grafikleri; (a) eğitim kutu kaybı, (b) eğitim nesne kaybı, (c) eğitim sınıf kaybı, (d) kesinlik, (e) duyarlılık, (f) doğrulama kutu kaybı, (g) doğrulama nesne kaybı, (h) doğrulama sınıf kaybı, (i) mAP_0.5, (j) mAP_0.95. .... 38	38
Şekil 5.3 : YOLOv8 medium modeli eğitim grafikleri; (a) eğitim kutu kaybı, (b) eğitim nesne kaybı, (c) eğitim sınıf kaybı, (d) kesinlik, (e) duyarlılık, (f) doğrulama kutu	

kayı, (g) doğrulama nesne kaybı, (h) doğrulama sınıf kaybı, (i) mAP_0.5, (j) mAP_0.95.....	39
<b>Şekil 5.4</b> : YOLOv8 large modeli eğitim grafikleri; (a) eğitim kutu kaybı, (b) eğitim nesne kaybı, (c) eğitim sınıf kaybı, (d) kesinlik, (e) duyarlılık, (f) doğrulama kutu kaybı, (g) doğrulama nesne kaybı, (h) doğrulama sınıf kaybı, (i) mAP_0.5, (j) mAP_0.95.....	40
<b>Şekil 5.5</b> : Karışıklık matrisin yapısı. ....	42
<b>Şekil 5.6</b> : Karışıklık matrisleri ; (a) Nano, (b) Small, (c) Medium, (d) Large.....	43
<b>Şekil 5.7</b> : Birinci test görüntüsüne ait sonuçlar; (a) Nano, (b) Small, (c) Medium, (d) Large.....	45
<b>Şekil 5.8</b> : İkinci test görüntüsüne ait sonuçlar; (a) Nano, (b) Small, (c) Medium, (d) Large.....	46
<b>Şekil 5.9</b> : Üçüncü test görüntüsüne ait sonuçlar; (a) Nano, (b) Small, (c) Medium, (d) Large.....	48
<b>Şekil 5.10</b> : Dördüncü test görüntüsüne ait sonuçlar; (a) Nano, (b) Small, (c) Medium, (d) Large.....	49
<b>Şekil 5.11</b> : Beşinci test görüntüsüne ait sonuçlar; (a) Nano, (b) Small, (c) Medium, (d) Large.....	50
<b>Şekil 5.12</b> : Altıncı test görüntüsüne ait sonuçlar; (a) Nano, (b) Small, (c) Medium, (d) Large.....	51
<b>Şekil 5.13</b> : Yedinci test görüntüsüne ait sonuçlar; (a) Nano, (b) Small, (c) Medium, (d) Large.....	52
<b>Şekil 5.14</b> : Sekizinci test görüntüsüne ait sonuçlar; (a) Nano, (b) Small, (c) Medium, (d) Large.....	53
<b>Şekil 5.15</b> : Dokuzuncu test görüntüsüne ait sonuçlar; (a) Nano, (b) Small, (c) Medium, (d) Large. ....	54
<b>Şekil 5.16</b> : Birinci simülasyon görüntüsüne ait sonuçlar; (a) Nano, (b) Small, (c) Medium, (d) Large. ....	55
<b>Şekil 5.17</b> : Birinci simülasyon görüntüsüne ait sonuçlar; (a) Nano, (b) Small, (c) Medium, (d) Large. ....	56

## ÖZET

Yüksek Lisans Tezi

### YAPAY ZEKA KULLANILARAK DEPREM BÖLGELERİNDE DRONE İLE ALINAN GÖRÜNTÜLERDEN ENKAZ TESPİTİNİN GERÇEKLEŞTİRİLMESİ

Ömer Faruk PİCAK

Karamanoğlu Mehmetbey Üniversitesi  
Fen Bilimleri Enstitüsü  
Elektrik-Elektronik Mühendisliği Ana Bilim Dalı

Danışman: Doç. Dr. Kadir SABANCI

Temmuz, 2025, 91 Sayfa

Bu çalışmada, YOLOv8 algoritmasının Nano, Small, Medium ve Large olmak üzere dört farklı versiyonu kullanılarak, afet bölgelerinde drone ile elde edilen görüntüler üzerinden enkaz tespiti gerçekleştirilmiştir. 2023 yılında meydana gelen Hatay-Maraş depreminin ardından kamuya açık bir kaynaktan temin edilen drone görüntüleriyle özel bir veri seti oluşturulmuştur. Görseller, Roboflow platformu aracılığıyla tek sınıflı (enkaz) olarak etiketlenmiş; veri artırma amacıyla döndürme (rotation) ve yansıma (flip) gibi teknikler uygulanmıştır. 2099 görüntüden oluşan veri seti %89 eğitim ve %11 doğrulama şeklinde bölünmüş, her model ayrı ayrı eğitilmiştir. Eğitim süreci sonunda mAP@0.5, kesinlik (precision), duyarlılık (recall), F1 skoru gibi metrikler ile karışıklık matrisleri üzerinden karşılaştırmalar yapılmıştır. YOLOv8 Medium modeli %75.9 mAP ve %93 Recall ile en başarılı sonuçları vermiştir. Ayrıca fiziksel test ortamında, zemine yerleştirilen enkaz görsellerinden drone aracılığıyla elde edilen görüntüler üzerinde yapılan tespitlerde modelin başarılı sonuçlar verdiği gözlemlenmiştir. Bu bulgular, geliştirilen sistemin afet sonrası arama-kurtarma süreçlerinde kullanılabilirliğini ortaya koymaktadır.

**Anahtar Kelimeler:** Enkaz Tespiti, YOLOv8, Drone Görüntüleri, Afet Yönetimi, Arama-Kurtarma



## **ABSTRACT**

**MS Thesis**

### **DEBRIS DETECTION FROM DRONE IMAGERY IN EARTHQUAKE ZONES USING ARTIFICIAL INTELLIGENCE**

**Ömer Faruk PİCAK**

**Karamanoğlu Mehmetbey University  
Graduate School of Natural and Applied Sciences  
Department of Electrical and Electronics Engineering**

**Supervisor: Assoc. Prof. Kadir SABANCI**

**July, 2025, 91 Pages**

In this study, debris detection was performed in disaster-stricken areas using four different versions of the YOLOv8 algorithm: Nano, Small, Medium, and Large. Following the 2023 Hatay-Maraş earthquake, a custom dataset was created using drone images obtained from a publicly available source. The images were annotated as a single class (debris) via the Roboflow platform, and data augmentation techniques such as rotation and flipping were applied. The dataset, consisting of 2,099 images, was split into 89% for training and 11% for validation, and each model was trained separately. At the end of the training process, performance comparisons were conducted using metrics such as mAP@0.5, Precision, Recall, and F1-score, along with confusion matrices. The YOLOv8 Medium model yielded the best results with 75.9% mAP and 93% Recall. Furthermore, in a physical testing environment, the model demonstrated successful detection on drone images captured over debris visuals placed on the ground. These findings indicate the potential applicability of the developed system in post-disaster search and rescue operations.

**Keywords:** Debris Detection, YOLOv8, Drone Imagery, Disaster Management, Search and Rescue



## 1. GİRİŞ

Doğal afetler, tarih boyunca toplumlar üzerinde ciddi sosyal, ekonomik ve çevresel etkiler yaratan, ani gelişen ve yıkıcı sonuçlar doğuran olağanüstü olaylar olarak tanımlanmaktadır (Cüce, 2023). Sel, heyelan, yangın, fırtına ve deprem gibi afetler, yalnızca can ve mal kaybına neden olmakla kalmaz; aynı zamanda altyapının tahrip olması, ekonomik istikrarsızlık, üretim ve hizmet süreçlerinin sekteye uğraması, toplumsal dayanışma ağlarının zayıflaması ve uzun süreli psikolojik travmalar gibi kalıcı sonuçlar doğurabilmektedir (Cüce, 2023). Bu afetler arasında depremler, etkilediği alanın genişliği, öngörülemez oluşu ve yıkım gücünün yüksekliği nedeniyle en tehlikeli ve en fazla can kaybına yol açan afet türlerinden biri olarak öne çıkmaktadır.

Depremler yalnızca fiziksel hasarla sınırlı kalmayıp, bireyler ve toplumlar üzerinde derin sosyo-psikolojik etkiler bırakmaktadır. Özellikle büyük şehirlerde ve yoğun nüfuslu bölgelerde meydana gelen depremler, hem müdahale hem de iyileştirme süreçlerini çok boyutlu bir kriz haline dönüştürmektedir. Kriz yönetiminde müdahale ekiplerinin hızlı şekilde organize edilmesi, hasarın doğru haritalanması ve kurtarma çalışmalarının etkin biçimde yürütülmesi, deprem sonrası süreçlerin en kritik aşamalarını oluşturmaktadır.

Türkiye gibi aktif fay hatları üzerinde yer alan ve tarihsel olarak yıkıcı depremler yaşamış ülkelerde, deprem riskine karşı dayanıklılığın artırılması, afet öncesi hazırlıkların sistematik biçimde planlanması ve afet sonrası hızlı toparlanma stratejilerinin geliştirilmesi hayati öneme sahiptir. Bununla birlikte, teknolojik gelişmelerin afet yönetimine entegrasyonu, son yıllarda hem risk azaltma hem de müdahale kapasitesini artırma açısından önemli bir dönüşüm yaratmıştır. Özellikle drone'lar ve yapay zekâ tabanlı görüntü işleme teknikleri, kriz bölgelerinde hasarın hızlı ve objektif bir şekilde tespit edilmesine olanak tanımakta (Ahmed ve ark. 2024); böylece arama-kurtarma faaliyetlerinin etkinliğini önemli ölçüde artırmaktadır.

Bu çerçevede, afet yönetiminde dijital teknolojilerin kullanımı, yalnızca operasyonel süreçlerin hızlandırılmasına değil, aynı zamanda karar vericilere güvenilir veri sunarak

müdahale planlarının doğruluğunu artırmaya da katkı sağlamaktadır. Depremlerin yol açtığı yıkıcı etkilerin azaltılması için ileri düzey görüntüleme, veri analitiği ve otomatik tespit sistemlerine duyulan ihtiyaç her geçen gün artmakta, bu alandaki yenilikçi çözümler literatürde önemli bir araştırma alanı olarak öne çıkmaktadır.

### **1.1. Çalışmanın Amacı ve Önemi**

Deprem sonrasında gerçekleştirilen arama ve kurtarma faaliyetleri, doğrudan zamanla ilişkilidir. Bu nedenle, yıkımın tespiti sürecinin en kısa sürede ve minimum insan gücüyle tamamlanması büyük önem taşımaktadır. Geleneksel yöntemlerde bu tür tespitler genellikle saha gözlemlerine ve insan gücüne dayalı olarak yürütülmektedir. Ancak bu yaklaşımlar; yüksek iş gücü maliyeti, zaman kaybı ve saha güvenliği riskleri gibi ciddi dezavantajlar barındırmaktadır (Ünlü ve Kiriş, 2022). Bu doğrultuda, teknolojik gelişmelerin afet yönetimi süreçlerine entegre edilmesi; hem bilgiye hızlı erişim hem de müdahale verimliliğinin artırılması açısından kritik bir fırsat sunmaktadır.

Özellikle son yıllarda İnsansız Hava Araçları (İHA) teknolojilerinde yaşanan ilerlemeler, afet sonrası görüntüleme ve veri toplama konularında önemli avantajlar sağlamıştır. Drone'lar; yüksek çözünürlüklü kamera sistemleri, stabil uçuş kabiliyeti ve zorlu coğrafi koşullara erişim yetenekleri sayesinde, deprem sonrası yıkım bölgelerinde hızlı ve güvenli gözlem yapma imkânı tanımaktadır (Abdi ve Jabari, 2021). Elde edilen bu görüntüler, yalnızca görsel belgeleme amacıyla değil; aynı zamanda Yapay Zekâ (YZ) ve Derin Öğrenme algoritmalarıyla analiz edilerek otomatik enkaz tespiti gibi kritik işlevlerde de kullanılabilir.

Bu çalışma, deprem sonrası drone görüntülerinden elde edilen veriler aracılığıyla yapay zekâ destekli bir enkaz tespit sistemi geliştirmeyi amaçlamaktadır. Model, yalnızca yapı ölçeğinde değil, geniş alanlı bölgesel analiz yapmaya da olanak tanıyarak arama-kurtarma operasyonlarının önceliklendirilmesine, kaynakların etkili kullanılmasına ve müdahale sürelerinin kısaltılmasına katkı sağlamayı hedeflemektedir. Bu yönüyle, çalışma afet yönetimi literatürüne hem teknolojik hem de operasyonel düzeyde yenilikçi bir yaklaşım sunmaktadır.

## 2. LİTERATÜR TARAMASI

Deprem sonrası hasar tespitine yönelik çalışmalarda, geleneksel olarak uzaktan algılama teknikleri önemli bir yer tutmaktadır. Literatürde, bu kapsamda uydu ve hava görüntüleri kullanılarak gerçekleştirilen çok sayıda araştırma mevcuttur (Rao ve ark. 2023; Zhang ve Gong 2013). Gerçekleştirilen çalışmalar, genellikle afet öncesi ve sonrası elde edilen görüntüler arasında değişim tespiti (change detection) yöntemlerine dayanmakta ve yapısal farklılıkları analiz etmeye çalışmaktadır (Khodaverdi ve Rastiveis 2017; Joshi ve ark. 2017). Ancak bu yaklaşım, çoğu zaman afet öncesi görüntülerin temin edilmesini zorunlu kılmakta ve bulut örtüsü, düşük mekânsal çözünürlük gibi etkenler nedeniyle istenen doğruluk düzeyine ulaşmakta çeşitli sınırlılıklar barındırmaktadır (Hasanlou ve ark. 2021).

Bu sınırlamaların aşılması amacıyla, son yıllarda drone kullanılarak toplanan yüksek çözünürlüklü görüntüler üzerinde derin öğrenme algoritmalarının uygulanmasına yönelik yöntemler geliştirilmiştir. Örneğin, Xiong ve arkadaşları (2020), drone ile elde edilen görüntüler üzerinde Evrişimsel Sinir Ağı (CNN) tabanlı bir sınıflandırma modeli geliştirerek, binaların sismik hasar düzeylerini otomatik olarak dört kategoriye (hafif, orta, ağır, çökme) ayırmayı başarmıştır. Model, yüksek çözünürlüklü görüntülerden binaları tespit edip kırparak analiz etmiş ve %89'un üzerinde doğruluk oranı ile etkili sonuçlar elde etmiştir. Gerçekleştirilen çalışma, derin öğrenme yöntemlerinin afet sonrası hasar tespitinde yüksek potansiyele sahip olduğunu ortaya koymaktadır. Benzer şekilde, Fernandez Galarreta ve ark. (2015), bina hasar tespiti amacıyla drone ile elde edilen 3B nokta bulutu verilerini Nesne Tabanlı Görüntü Analizi (OBIA) yöntemiyle birleştirerek, çatı ve cephe düzeyinde detaylı bir analiz gerçekleştirmiştir. Sınıflandırma sonucunda cephe düzeyinde yaklaşık %91 doğruluk elde edilmiş, özellikle yoğun hasarlı bölgelerin güvenilir şekilde ayrıştırılabildiği gösterilmiştir. İlgili araştırmalar, drone görüntülerinin sahip olduğu yüksek mekânsal çözünürlük ve farklı açılardan görüntü elde etme kapasitesinin, deprem hasarlarının daha ayrıntılı ve güvenilir şekilde değerlendirilmesine katkı sağladığını göstermektedir.

Ancak literatürdeki mevcut çalışmaların önemli bir bölümü, hâlâ uydu ya da genel hava fotoğraflarına dayanan açık veri kümeleri üzerinde yürütülmekte olup, drone görüntülerine özgü ihtiyaçlara yeterince cevap verememektedir. Örneğin, Fujita ve

ark. (2017) tarafından kullanılan veri setleri, genellikle drone kameralarının sunduğu detay seviyesini içermemekte; bu da modelin hassasiyetini sınırlamaktadır. Ayrıca ışık koşulları, görüntüleme açıları, çözünürlük ve çerçeveleme gibi parametrelerdeki farklılıklar, mevcut derin öğrenme modellerinin drone görüntülerine doğrudan uyarlanmasını zorlaştırmaktadır (Hong ve ark. 2022; Kalantar ve ark. 2020). Bu durum, drone görüntülerine özgü veri setleri ve algoritmalara duyulan ihtiyacı açıkça ortaya koymaktadır.

Ayrıca, Güney Kore’de yürütülen kapsamlı bir araştırmada, Ulusal Afet Yönetimi Enstitüsü (NDMI) tarafından gerçekleştirilen uygulamalarla, drone teknolojisinin geleneksel saha gözlemlerinin yerini alabileceği gösterilmiştir. Bu kapsamda elde edilen görüntülerden 5 cm altı mekânsal çözünürlüğe sahip ortofotolar üretilmiş ve sel, erozyon ve çökme gibi afet türlerinde yüksek doğrulukla hasar tespiti yapılmıştır (Kim ve ark. 2018). Bu tür uygulamalar, drone tabanlı afet yönetimi yaklaşımlarının saha kullanımına uygunluğunu ortaya koymaktadır.

Bu kapsamda Ilmak ve arkadaşları (2024) tarafından gerçekleştirilen çalışmada, çok yüksek çözünürlüklü (VHR) Maxar uydu görüntüleri üzerinde YOLO tabanlı nesne tanıma algoritmaları (YOLOv7, YOLOv7x, YOLOv8l ve YOLOv8x) kullanılarak Antakya’daki yıkılmış yapıların otomatik tespiti amaçlanmıştır. YOLOv7 modeli, özellikle %79 ortalama doğruluk (mean Average Precision, mAP@0.5) değeriyle en yüksek doğruluğa ulaşarak yıkılmış bina sınıfında etkili sonuçlar vermiştir. Çalışma kapsamında geliştirilen özel kütüphaneler sayesinde, tespit edilen yıkılmış binaların coğrafi koordinatları elde edilmiş ve bu veriler Coğrafi Bilgi Sistemi (CBS) ortamına entegre edilerek 28,20 km<sup>2</sup>’lik alan içinde toplam 216 yıkılmış bina belirlenmiştir. YOLO modellerinin hızlı ve yüksek doğruluklu tahmin yapabilme yetenekleri, afet sonrası müdahale süreçlerinde önemli bir katkı sunarken, çalışmada ayrıca modelin farklı senaryolara genellenebilirliğini artırmak için daha çeşitli veri setlerine ihtiyaç duyulduğu vurgulanmıştır. Bu yönüyle çalışma, derin öğrenme tabanlı nesne tespitinin deprem sonrası hasar tespiti ve afet yönetimi uygulamalarında etkin biçimde kullanılabileceğini göstermektedir.

Arai ve arkadaşları (2024) tarafından gerçekleştirilen çalışmada, deprem sonrası afet bölgelerinin yalnızca tek bir uydu kaynaklı SAR (Sentetik Açıklıklı Radar) görüntüsüyle tespit edilmesini hedeflemektedir. Geleneksel yaklaşımlarda, deprem öncesi ve sonrası birden fazla SAR verisi gerekliliği afet anında veri teminini

zorlaştırmakta, bu da erken müdahaleyi geciktirmektedir. Bu sorunu aşmak amacıyla, araştırmacılar YOLOv8 ve Detectron2 tabanlı nesne tespit algoritmalarını kullanarak yalnızca deprem sonrası elde edilen tek bir SAR verisiyle eğitilmiş derin öğrenme modelleri geliştirmiştir. Model eğitimi, 1 Ocak 2024'te Japonya'nın Noto Yarımadası'nda meydana gelen 7.6 büyüklüğündeki depremin ardından elde edilen Umbra SAR verileri kullanılarak gerçekleştirilmiştir. Eğitim ve doğrulama süreci boyunca kullanılan toplam 55 sahne ile model, heyelan, yangın, bina çökmesi, dik yamaç deformasyonu ve yol hasarları gibi çeşitli afet etkilerini başarıyla sınıflandırmıştır. Araştırmada, mAP, precision, recall ve PR eğrileri gibi yaygın ölçütler kullanılarak YOLOv8 ve Detectron2 modellerinin karşılaştırmalı analizleri yapılmış ve YOLOv8 modelinin daha hızlı ve tutarlı sonuçlar verdiği belirlenmiştir. Sadece tek bir SAR görüntüsüyle dahi yüksek doğrulukta tespit yapılabilmesi, bu yöntemin afet sonrası erken müdahale ve ikincil felaketlerin önlenmesi açısından önemli bir potansiyel taşıdığını ortaya koymaktadır. Bu yönüyle çalışma, SAR verisi tabanlı nesne tespiti ile afet yönetimi alanında yenilikçi ve uygulanabilir bir katkı sunmaktadır.

Kıratlı ve Eroğlu (2024) tarafından yürütülen çalışmada, deprem sonrası arama-kurtarma operasyonlarının etkinliğini artırmak amacıyla, Drone ile elde edilen görüntüler üzerinden ekip, iş makinesi ve yapı hasarlarının tespitine yönelik entegre bir yaklaşım sunmaktadır. Farklı ışık, yükseklik ve bakış açılarında sahip 4.392 görselden oluşan özel veri seti üzerinde çalışılarak, YOLOv5 ve YOLOv8 algoritmaları karşılaştırmalı olarak değerlendirilmiştir. YOLOv8 modeli, %88 mAP ve 0.87 F1 skoru ile YOLOv5'e kıyasla daha yüksek doğruluk ve dengeleyici performans metriklerine ulaşmıştır. Ayrıca çalışma, yalnızca insan ya da yapı tespitiyle sınırlı kalmayıp, arama-kurtarma operasyonlarına yönelik çoklu nesne (ekip, ekipman ve makine) tespiti yapan ilk kapsamlı uygulama olma niteliği taşımaktadır. Geliştirilen modelin, gerçek zamanlı tespit ve karar desteği sağlaması, afet yönetimi süreçlerinin otonom hale getirilmesini desteklemektedir. Bu yönüyle çalışma, YOLOv8 tabanlı görsel algılama teknolojilerinin arama-kurtarma operasyonlarında hızlı, doğru ve çok boyutlu tespit yetenekleri sunabileceğini göstermektedir.

Ma ve arkadaşları (2020) tarafından gerçekleştirilen çalışmada, yüksek çözünürlüklü uzaktan algılama görüntüleri kullanılarak deprem sonrası yıkılmış yapıların otomatik tespiti için geliştirilmiş bir YOLOv3 tabanlı derin öğrenme modelini önermektedir.

Geleneksel yöntemlerin, karmaşık arka planlar ve zaman alıcı özellik seçimi nedeniyle sınırlı başarı göstermesi üzerine, gerçekleştirilen çalışmada YOLOv3'ün yapısı hem ağ mimarisi hem de kayıp fonksiyonu açısından iyileştirilmiştir. Öncelikle YOLOv3'ün temel ağ yapısı olan Darknet53, daha hafif ve daha hızlı bir model olan ShuffleNet v2 ile değiştirilmiş; böylece parametre sayısı azaltılarak işlem hızı artırılmıştır. Ayrıca, kutu tahmini sırasında kullanılan kaybın (loss) ölçüm fonksiyonu olarak Genelleştirilmiş Intersection over Union (GIoU) kullanılmış, bu da modelin doğruluğunu ve konum hassasiyetini geliştirmiştir. Model, 2010 Yushu ve 2008 Wenchuan depremlerinden sonra elde edilen 0.5 m çözünürlüğe sahip hava görüntüleri ile eğitilmiş ve test edilmiştir. 2180 örnek görsel üzerinde yapılan deneylerde, geliştirilen model (YOLOv3-S-GIoU), orijinal YOLOv3'e kıyasla %93 doğruluk, %88 geri çağırma oranı ve %90.89 ortalama doğruluk (AP) ile daha üstün performans göstermiştir. Ayrıca 29.23 Frame Per Second (FPS) hızına ulaşarak gerçek zamanlı kullanım için uygun olduğu kanıtlanmıştır. Modelin rastgele eklenen gürültülere karşı yüksek dayanıklılık göstermesi, afet sonrası koşullarda kullanılabilirliğini ve sağlamlığını artırmaktadır. Bu yönüyle çalışma, uzaktan algılama ve derin öğrenme yöntemlerinin birleştirilerek afet yönetimi süreçlerinde yıkım tespiti için etkin biçimde kullanılabileceğini ortaya koymaktadır.

Shi ve arkadaşları (2021) tarafından gerçekleştirilen çalışmada, deprem sonrası uzaktan algılama görüntülerinden yıkılmış binaların hızlı ve doğru şekilde tespit edilmesini hedeflemektedir. Çalışmada, klasik YOLOv4 mimarisi geliştirilerek ResNext blokları ve derin ayrık evrişim (depthwise separable convolution) yöntemi ağın omurgasına entegre edilmiş, bu sayede hem özellik çıkarımı güçlendirilmiş hem de parametre yükü azaltılmıştır. Ayrıca, kutu regresyonu doğruluğunu artırmak amacıyla geleneksel Tam Kesişim Üzerinden Birlik (CIoU) kayıp fonksiyonu yerine Fokal Geliştirilmiş Kesişim Üzerinden Birlik (Focal-EIoU) loss önerilmiştir. Bu yeniliklerle oluşturulan model, 2008 Wenchuan ve 2010 Yushu depremlerinden sonra elde edilen 0.5 m çözünürlüklü hava görüntülerinden oluşturulan etiketli veri seti ile eğitilmiştir. Modelin performansı, YOLOv4 ve YOLOv4+ResNext modelleriyle karşılaştırılmış; YOLOv4+ResNext+Focal-EIoU modelinin %93.76 AP, %87.25 F1 skoru ve 32.7 FPS gibi üstün sonuçlara ulaştığı rapor edilmiştir. Ayrıca, önerilen modelin küçük hedefleri tanıma ve gürültüye karşı dayanıklılık açısından da güçlü bir genel performansa sahip olduğu ortaya konulmuştur. Bu yönüyle çalışma, uzaktan

algılama verileri ile deprem sonrası yıkım tespiti konusunda hem hassasiyet hem de hız açısından önemli bir ilerleme sunmaktadır.

Jing ve arkadaşları (2022) tarafından gerçekleştirilen çalışmada, 2021 yılında Çin'in Yunnan eyaletine bağlı Yangbi bölgesinde meydana gelen 6.4 büyüklüğündeki depremin ardından kırsal alandaki hasar görmüş yapıların drone görüntüleri üzerinden otomatik olarak tespit edilmesini amaçlamaktadır. Çalışmada, YOLOv5s mimarisi temel alınarak geliştirilen, Görsel Dönüştürücü ve Çift Yönlü Özellik Hiyerarşisi Ağı (Vision Transformer and Bi-Directional Feature Pyramid Network - ViT-BiFPN) bileşenlerine sahip yeni bir model olan YOLOv5s-ViT-BiFPN önerilmiştir. Modelde, küresel bağlam bilgilerini yakalayabilmek amacıyla Vision Transformer mimarisi kullanılmış; ayrıca, farklı çözünürlüklerdeki özellikleri daha etkili biçimde birleştirmek üzere geleneksel PANet yapısı yerine BiFPN entegre edilmiştir. Model, DJI Phantom 4 ile elde edilen yüksek çözünürlüklü drone ortofoto görüntüleri üzerinde eğitilmiş ve test edilmiştir. 860 yıkılmış yapıyı içeren 400 örnek görsel ile eğitilen model, test aşamasında %91.23 ortalama doğruluk ve 4 dakikadan kısa toplam tespit süresi ile hem zaman verimliliği hem de yüksek doğruluk açısından başarılı sonuçlar vermiştir. YOLOv5s-ViT-BiFPN modeli, YOLOv3 ve YOLOv5s gibi önceki versiyonlara göre ortalama doğrulukta %9.31'e varan bir iyileşme sağlamıştır. Ayrıca, modelin Ya'an depremi gibi farklı bölgelerdeki depremler için de başarılı biçimde uygulanabilir olduğu görülmüştür. Bu yönüyle çalışma, drone görüntülerine dayalı gerçek zamanlı ve transfer edilebilir yıkım tespiti açısından literatürde önemli bir boşluğu doldurmaktadır.

Ahmed ve arkadaşları (2024) tarafından geliştirilen çalışmada, afet sahalarında afetzedelerin tespiti amacıyla YOLOv8 modeline dikkat (attention) temelli yeni modüller entegre ederek geliştirilmiş bir DSP-YOLOv8 modeli sunmaktadır. Bu model, özellikle sisli, dağınık ve karmaşık arka planlı ortamlarda yüksek doğrulukla çalışabilmesi için yapılandırılmıştır. Model mimarisi, üç yenilikçi modül ile güçlendirilmiştir: Deformable Convolutional Network v2 (DCNv2), Squeeze-and-Excitation (SE) ve Uzamsal Olarak Uyarlanabilir Konvolüsyon (SPDConv.) Bu modüller aracılığıyla, modelin karmaşık şekilleri tanıma, uzamsal-çevresel bağlamı ayırt etme ve çok ölçekli hedeflerdeki tespit yetkinliği artırılmıştır. Çalışmada, doğal ve insan kaynaklı afetlere ait 5100 etiketli görüntüden oluşan özel bir veri seti kullanılarak model eğitilmiştir. Afetzedede ve arama-kurtarma personeli içer

görüntüler, etik ilkeler çerçevesinde toplanmış ve her biri sınıf etiketiyle işlenmiştir. Eğitim süreci sonucunda model, %95.11 mAP@0.5 ve %82.9 mAP@0.5:0.95 gibi oldukça yüksek başarı oranlarına ulaşmıştır. Geliştirilen modelin başarımı, YOLOv5, YOLOv6, YOLOv8, Tek Aşamalı Tespitçi (SSD) ve Faster R-CNN gibi önceki nesil modellerle karşılaştırıldığında, hem doğruluk hem de tespit kabiliyeti açısından belirgin üstünlük göstermiştir. Ayrıca, bu modelin web tabanlı arayüzle entegre edilerek gerçek zamanlı görüntü işlemeye olanak sağladığı belirtilmiştir. Model, özellikle enkaz altında kalmış, kısmen görünür halde olan ya da kamufle olmuş insanların tespiti gibi zorlayıcı senaryolarda dahi tutarlı sonuçlar sunmuş; bu da onun afet sonrası arama-kurtarma operasyonlarında yüksek pratik değer taşıyan bir çözüm haline geldiğini göstermektedir. Çalışma, gelecekte modelin inşaat malzemeleri (ör. demir donatılar) gibi dolaylı ipuçlarını da kullanarak insanların tespitini daha da geliştirebileceğini önermektedir.

Bu çalışma literatüre katkı sunmayı amaçlamakta ve deprem sonrası drone görüntülerinin YOLOv8 algoritması ile analiz edilerek enkaz tespiti yapılmasına yönelik bir yaklaşım ortaya koymaktadır. YOLOv8 (You Only Look Once, versiyon 8), özellikle gerçek zamanlı uygulamalar için yüksek hız ve doğruluk oranı sunan güncel bir nesne tespit algoritmasıdır. Çalışmanın temel katkısı, yapısal hasar sınıflandırmasına girmeksizin, yalnızca yıkılmış alanların hızlı ve otomatik biçimde tespit edilmesine odaklanmasıdır. Bu yaklaşım, arama-kurtarma operasyonlarının verimliliğini artırmak ve karar destek mekanizmalarına görsel bilgi sağlayabilmek adına önem arz etmektedir.

### 3. KURAMSAL TEMELLER

#### 3.1. Yapay Zeka

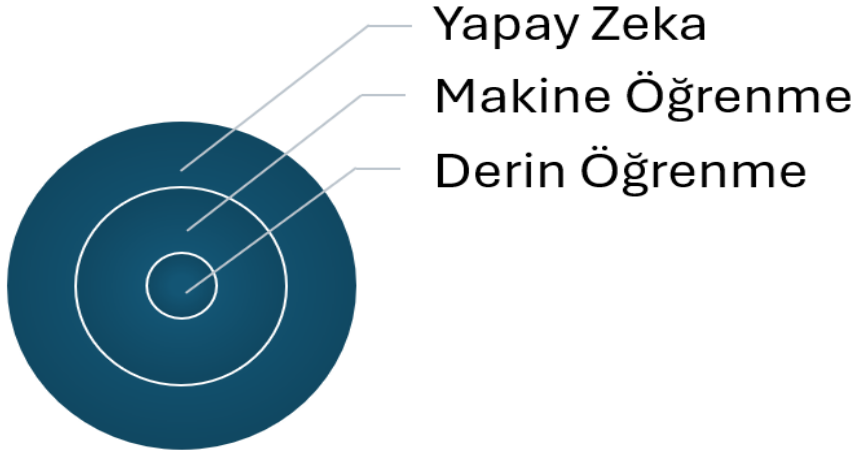
Yapay zekâ (YZ), insan zekâsını taklit edebilen sistemlerin tasarımı ve geliştirilmesini amaçlayan disiplinler arası bir araştırma alanı olarak son yıllarda büyük bir ivme kazanmıştır. Bu kavramın temelleri, 1950’li yıllarda Alan Turing’in makinelerin düşünebilme kapasitesini sorguladığı öncü çalışması ile atılmıştır. Turing’in (1950) ortaya koyduğu “Turing Testi”, bir makinenin zekâ düzeyinin, insan benzeri tepkiler üretme yeteneğiyle ölçülebileceğini ileri sürmüştür. Yapay zekâ terimi ise ilk defa 1956 yılında John McCarthy tarafından tanımlanmış ve bu tarihten itibaren hem akademik hem de endüstriyel gelişmelere yön vermiştir (McCarthy, 1956; Smith, 2020).

Erken dönemlerde geliştirilen yapay zekâ sistemleri, önceden belirlenmiş kurallar dizisiyle çalışan, öğrenmeyen ve sabit algoritmalar içeren yapılar olarak ortaya çıkmış; bu yaklaşım daha sonra “sembolik yapay zekâ” olarak adlandırılmıştır. Bu sistemler belirli mantıksal problemleri (örneğin satranç gibi) çözmeye başarılı olsa da doğal dil işleme, görüntü tanıma ve sesli komut algılama gibi daha karmaşık, bağlama duyarlı problemler karşısında yetersiz kalmıştır (Chollet, 2021). Bu sınırlılıklar, araştırmacıları veri temelli yöntemlere yöneltmiş; makine öğrenmesi ve derin öğrenme gibi alt alanların gelişimiyle birlikte yapay zekâ, daha dinamik ve özerk sistemlerin geliştirilmesine imkân sağlamıştır (Lee, 2018; Chen ve ark. 2017).

Özellikle 2000’li yıllardan itibaren artan veri hacmi, işlem gücündeki ilerlemeler ve algoritmik yeniliklerle birlikte yapay zekâ çok çeşitli alanlarda uygulanabilir hâle gelmiştir. Sağlık, savunma, finans ve eğitim gibi sektörlerde yapay zekâ tabanlı çözümler geliştirilmiş; karar verme süreçlerini hızlandıran, insan hatasını azaltan ve etkinliği artıran sistemler yaygınlaşmıştır (Erdoğan, 2022). Ancak bu gelişmelere rağmen, etik, güvenlik ve toplumsal etkiler gibi konular, yapay zekânın sürdürülebilir gelişimi açısından önemli tartışma başlıkları olarak gündeme gelmeye devam etmektedir (Kim, 2019; Wang ve Zhang, 2021).

Yapay zekâyâ yönelik araştırmaların tarihsel süreci ve teknolojik evrimi, bu alanın sadece teknik bir mesele değil; aynı zamanda etik, sosyolojik ve felsefi yönleriyle de çok katmanlı bir yapı arz ettiğini göstermektedir. Bu nedenle, yapay zekânın sunduğu olanakları maksimize etmek ve potansiyel riskleri en aza indirmek için disiplinler

arası iş birlikleri ve kapsamlı düzenleyici çerçeveler oluşturulması kritik önemdedir (Garcia, 2020).



**Şekil 3.1 :** Yapay zekâ, makine öğrenmesi ve derin öğrenmenin hiyerarşik ilişkisi.

Şekil 3.1’de makine öğrenmesinin yapay zekâ kavramı içerisinde konumlandığı, yani onun bir alt dalı olduğu belirtilmiştir. Bu alan, makinelerin veriler üzerinden öğrenme ve analiz yapabilme kapasitesine işaret eder.

Makine öğrenmesinin daha özelleşmiş bir alanı olan derin öğrenme, özellikle son yıllarda yoğun ilgi görmektedir. Derin öğrenme yöntemleri, çok katmanlı yapay sinir ağları aracılığıyla karmaşık veri yapılarında bulunan desenleri tanımlamada daha yüksek başarı sağlar.

Sonuç olarak, yapay zekâ sistemlerinde makine öğrenmesi ve derin öğrenmenin birlikte kullanılması, çeşitli uygulamalarda daha güçlü, esnek ve etkili çözümler geliştirilmesine olanak tanımaktadır

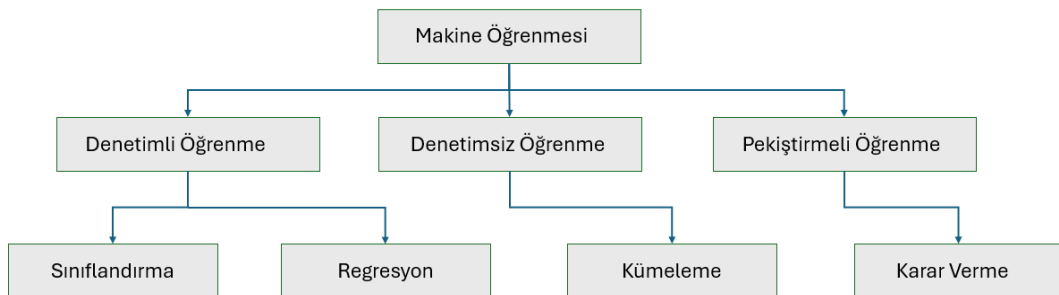
### **3.2. Makine Öğrenmesi**

Makine öğrenimi (machine learning), bilgisayar sistemlerinin açık bir şekilde programlanmaksızın deneyimlerden öğrenmesini ve performansını zamanla iyileştirmesini sağlayan bir yapay zekâ alt alanıdır. Kavram ilk olarak 1950’li yıllarda Arthur Samuel tarafından ortaya atılmış ve özellikle veri hacminin artmasıyla birlikte son yıllarda büyük bir önem kazanmıştır (Aksaç, 2022). Temel olarak, makine öğrenimi sistemleri, yapılandırılmış ya da yapılandırılmamış veriler üzerinden

desenleri tanımlayarak belirli görevleri otomatik biçimde yerine getirebilir hale gelir (Raschka, 2015). Bu yönüyle, makine öğrenmesi geleneksel istatistiksel yöntemlerden ayrılarak daha büyük ve karmaşık veri kümeleri üzerinde etkili sonuçlar üretmeye imkân tanır (Can, 2020).

Makine öğrenimi; denetimli öğrenme, denetimsiz öğrenme ve pekiştirmeli öğrenme olmak üzere üç ana kategori altında sınıflandırılmaktadır. Denetimli öğrenmede, modelin çıktığı tahmin edebilmesi için hem giriş hem de çıkış verileri sağlanır ve bu veriler arasında kurulan ilişkilerle tahmin modelleri geliştirilir. Genellikle sınıflandırma ve regresyon problemlerinde kullanılan bu yaklaşım, daha önce görülmemiş veriler üzerinde yüksek doğrulukla tahmin yapmayı hedefler (Aksaç, 2022). Denetimsiz öğrenmede ise yalnızca giriş verileri kullanılır ve veriler arasında örüntüler veya gruplar keşfedilmeye çalışılır. Özellikle kümeleme analizlerinde kullanılan bu yöntem, verinin yapısını anlamaya yönelik önemli bir araçtır. Pekiştirmeli öğrenme ise canlıların öğrenme sürecine benzer şekilde, çevreden alınan ödül veya ceza sinyalleriyle sistemin kendi stratejisini geliştirmesini sağlar.

Makine öğrenimi, klasik yapay zekâ sistemlerinden farklı olarak önceden tanımlanmış kurallara ihtiyaç duymadan yeni kurallar ve desenler keşfedebilir. Bu özelliği sayesinde, değişkenliği yüksek, çok boyutlu ve büyük hacimli verilerin analizinde güçlü bir araç olarak kullanılmaktadır (Chollet, 2021). Ayrıca, bu öğrenme yaklaşımlarının her birinde kullanılabilen derin öğrenme yöntemleri, çok katmanlı yapay sinir ağları aracılığıyla daha karmaşık ilişkileri modelleyebilmektedir. Bu bağlamda, makine öğrenimi yalnızca teorik bir kavram değil; aynı zamanda yazılım ve donanım alanlarındaki yeniliklerle şekillenen, uygulama odaklı bir mühendislik disiplindir. Makine öğrenmesinin türleri Şekil 3.2’ de gösterilmiştir.



**Şekil 3.2 :** Makine öğrenmesi türleri ve ilgili yaklaşımlar.

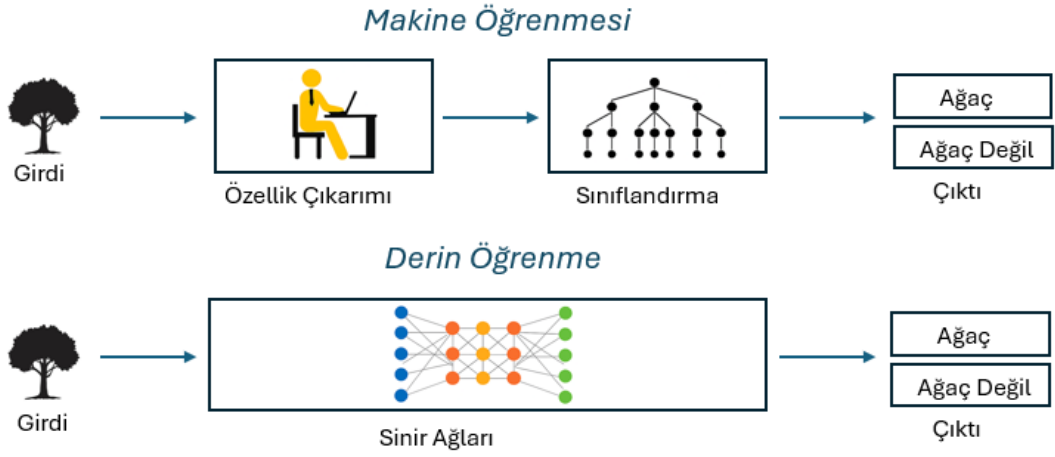
### 3.3. Derin Öğrenme

Derin öğrenme, yapay zekâ temelli sistemlerin bir alt dalı olarak, makine öğrenmesi yaklaşımıyla gelişmiş bir öğrenme yöntemidir. Bu yöntemde, veriler çok katmanlı yapılar üzerinden işlenerek sistemin özellikleri tanınması ve belirli görevleri otomatik olarak öğrenmesi sağlanır (LeCun ve ark. 2015). Derin öğrenmenin temel farklarından biri, geleneksel makine öğrenmesi modellerinde yer alan bir veya iki katmanlı yapılar yerine, çok sayıda gizli katmanın bir araya gelmesiyle daha karmaşık ve güçlü modellerin oluşturulabilmesidir.

Bu yöntemde giriş verileri metin, ses ya da görüntü gibi çeşitli biçimlerde olabilir ve her bir katmanda farklı düzeyde soyutlama işlemleri gerçekleştirilir. Sistemin parametrelerini kullanıcı tarafından doğrudan tanımlamaya gerek kalmaksızın, öğrenme işlemi sırasında otomatik olarak sınıflandırma yapılabilmesi, derin öğrenmenin en önemli avantajlarından biridir (Sorgun, 2022). Derin öğrenme sistemleri sayesinde, verilerden elde edilen özellikler daha anlamlı ve açıklayıcı hâle getirilirken, aynı zamanda sınıflandırma başarı oranları da kayda değer biçimde artırılabilir (Jeyaraj ve Samuel Nadar, 2019).

Bu yöntem, veri içerisindeki bilgileri çok katmanlı yapılarla temsil ettiği için, düşük seviyeli özelliklerden başlayarak daha soyut ve karmaşık temsillere ulaşılmasını sağlar. Böylelikle farklı soyutlama seviyeleri arasında hiyerarşik bir öğrenme gerçekleşir (Alawad ve Lin, 2016). Derin öğrenme günümüzde görüntü işleme, nesne tanıma, doğal dil işleme ve sağlık gibi pek çok alanda yaygın şekilde kullanılmaktadır.

Makine öğrenmesi ve derin öğrenme, yapay zekâ alanında veri işleme yöntemleridir. Makine öğrenmesinde, verilerden önce insan tarafından belirlenen özellikler çıkarılır ve ardından bir sınıflandırıcı ile sonuç üretilir. Bu süreçte özellik çıkarımı manuel olduğu için zaman alıcı ve uzmanlık gerektirir. Derin öğrenmede ise veriler doğrudan sinir ağına verilir; ağ, katmanlar aracılığıyla otomatik olarak anlamlı temsiller öğrenir (Şekil 3.3). Bu sayede, insan müdahalesi olmadan veriden karmaşık yapılar öğrenilir ve daha büyük veri kümeleriyle daha iyi sonuçlar elde edilir.




**Şekil 3.3 :** Makine öğrenmesi ve derin öğrenmede sınıflandırma süreci.

### 3.4. Yapay Sinir Ağları

Yapay zekânın önemli alt dallarından biri olan yapay sinir ağları (YSA), özellikle parametreler arasındaki ilişkilerin doğrusal olmadığı ya da analitik çözümlerin zorlaştığı problemlerde sıklıkla kullanılan veri odaklı bir modelleme yaklaşımıdır. Bu sistemler, girdi verilerinden elde edilen çıktılar ile hedef değerler arasındaki farkı minimize etmeye yönelik olarak eğitilir (Mazanoğlu ve Kandemir-Mazanoğlu, 2017).

Yapay zekânın temelinde insan davranışlarını taklit etme fikri yer aldığından, YSA mimarisi de biyolojik sinir sisteminden ilham alınarak geliştirilmiştir (Şekil 3.4). Biyolojik sinir hücreleri nasıl ki sinapslar aracılığıyla birbirine bağlı şekilde çalışıyor ve elektriksel sinyaller ile bilgi iletişimi gerçekleştiriyorsa; yapay sinir hücreleri de benzer şekilde dışarıdan gelen sinyalleri bir toplama fonksiyonu ile işleyip, aktivasyon fonksiyonu aracılığıyla çıktıya dönüştürür. Bu çıktı daha sonra diğer yapay nöronlara aktarılır (Öztemel, 2012). Çizelge 3.1’de biyolojik ve yapay sinir hücresi bileşenleri verilmiştir.




Şekil 3.4 : Biyolojik ve yapay nöron yapılarının karşılaştırılması.

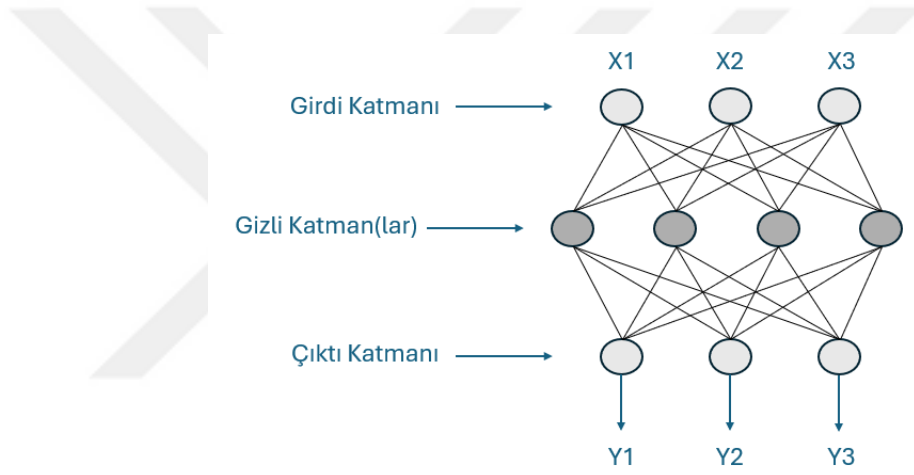
Çizelge 3.1 : Biyolojik ve yapay sinir hücresi bileşenlerinin karşılaştırılması.

Biyolojik Sinir Hücresi	Yapay Sinir Hücresi
Akson	Çıktı
Dendrit	Toplama Fonksiyonu
Çekirdek	Aktivasyon Fonksiyonu
Sinaps	Ağırlıklar

YSA modelleri genel olarak dört temel yapı altında sınıflandırılır: tek katmanlı algılayıcılar, çok katmanlı algılayıcılar, ileri beslemeli sinir ağları ve geri beslemeli sinir ağları (Öztemel, 2006). Tek katmanlı algılayıcılar (TKA) yalnızca bir giriş ve bir çıkış katmanından oluşur ve genellikle doğrusal problemleri çözmede kullanılır (Şekil 3.5). Ancak doğrusal olmayan problemlerde yetersiz kaldıkları için, daha gelişmiş olan çok katmanlı algılayıcılar (ÇKA) geliştirilmiştir (Şekil 3.6).




Şekil 3.5 : Tek katmanlı algılayıcılar.




Şekil 3.6 : Çok katmanlı algılayıcılar.

Şekil 3.7' de ileri beslemeli yapay sinir ağı modeli verilmiştir. İleri beslemeli yapay sinir ağları, verilerin giriş katmanından başlayarak gizli katmanlara ve ardından çıkış katmanına doğru sıralı bir şekilde iletiildiği, doğrusal yapılı sistemlerdir. Her katman yalnızca bir sonraki katmanla bağlantı hâlinindedir ve veriler, bu katmanlar arasında geriye dönük bir besleme olmaksızın iletilir (Öztürk ve Şahin, 2018).



**Şekil 3.7 :** İleri beslemeli ağ yapısı.

Şekil 3.8’ de geri beslemeli yapay sinir ağı modeli verilmiştir. Geri beslemeli sinir ağları ileri beslemelilerin aksine, ağıdaki bazı nöronların çıktılarının sadece kendinden sonraki katmanlara değil, aynı zamanda önceki veya aynı katmandaki nöronlara da girdi olarak gönderilebilmesine olanak tanır. Bu tür bağlantı yapıları, ağın dinamik ve doğrusal olmayan özellikler kazanmasını sağlar. Farklı geri besleme düzenlemeleri, aynı YSA mimarisi ile farklı öğrenme davranışları elde etmeye imkân tanır (Doğan, 2016; Öztürk ve Şahin, 2018).



**Şekil 3.8 :** Geri beslemeli ağ yapısı.

### 3.5. Evrişimsel Sinir Ağları

Görüntüleri anlamlandırma süreci, hayvanlar için doğal ve oldukça basit bir eylem gibi görünse de, makineler açısından oldukça karmaşık bir işlemdir. Hayvanlarda bu süreç; gözle alınan görüntünün nöronlar aracılığıyla işlenmesi ve yorumlanmak üzere beyne iletilmesiyle gerçekleşir. Ancak makinelerin benzer bir işlevi yerine getirebilmesi, görüntüdeki desenleri ve karmaşık yapıları analiz edebilecek özel algoritmalara ihtiyaç duymaktadır. Bu kapsamda geliştirilen yöntemlerden biri olan Konvolüsyonel Sinir Ağları (KSA), görsel işleme açısından son derece etkili derin öğrenme modellerinden biridir. Bu mimari, canlıların görsel sistemlerinden esinlenerek geliştirilmiş ve görüntülerdeki anlamlı öğeleri otomatik olarak tanıyabilecek yapay zeka sistemlerinin inşasında kullanılmıştır (Sarvamangala ve Kulkarni, 2022).

KSA'lar özellikle görüntü temelli verilerin işlenmesinde yaygın olarak tercih edilmektedir. Görüntü içindeki nesnelere tespit etme, sınıflandırma ve bölütleme gibi görevleri başarıyla yerine getirebilen çok katmanlı sinir ağı yapılarıdır. Görsel tanıma, tıbbi görüntü analizi, görüntü segmentasyonu ve doğal dil işleme gibi çeşitli alanlarda yüksek performans gösteren KSA'lar, geleneksel yapay sinir ağlarına kıyasla daha verimli sonuçlar üretmektedir (Taye, 2023). Bunun temel nedeni, KSA'ların görüntülerden anlamlı öznitelikleri doğrudan çıkarabilme yeteneğidir.

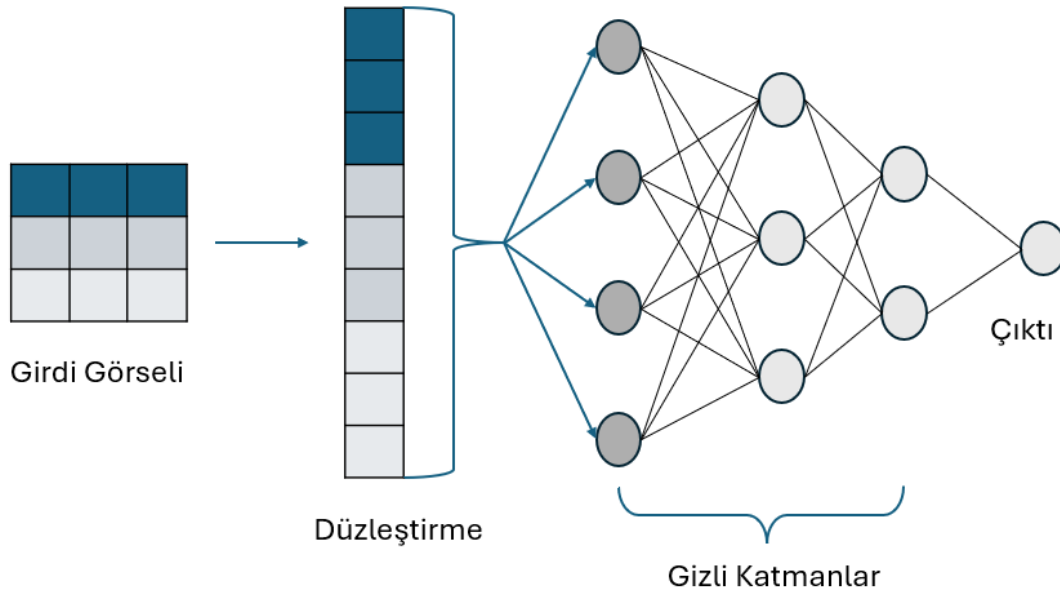
Bu yapılar, çok katmanlı ve hiyerarşik bir özellik öğrenme sistemine sahiptir. İlk katmanlarda temel şekil ve doku gibi düşük düzeyde özellikler çıkarılırken, derin katmanlara ilerledikçe daha soyut ve yüksek düzeyde kavramsal özelliklerin öğrenilmesi mümkün olur (Kugunavar ve Prabhakar, 2021). Temel yapı taşları arasında konvolüsyon katmanları, örnekleme (pooling) katmanları, aktivasyon fonksiyonları ve tam bağlantılı katmanlar yer alır. Konvolüsyon katmanı, görüntü üzerinde küçük filtrelerin hareket ettirilmesi yoluyla, farklı konumlardaki özellikleri çıkarmaya yarar. Bu filtreler, görüntüde yer alan belirli paternleri tespit ederken, örnekleme katmanları bu çıktının boyutunu düşürerek hesaplama yükünü azaltır. Tam bağlantı katmanı ise çıkarılan bu öznitelikleri sınıflandırma amacıyla kullanır (Ergin, 2018).

Girdi verisinin katmanlar üzerinden geçerek çıktıya dönüştürülmesi işlemine ileri yayılım, öğrenme sırasında ağ parametrelerinin güncellenmesine ise geri yayılım adı

verilir. Eğitim süreci boyunca, gerçek çıktılar ile modelin tahminleri arasındaki fark bir kayıp fonksiyonu ile hesaplanır ve bu fark, gradyan iniş algoritması kullanılarak minimize edilir. Böylece ağda kullanılan filtreler ve ağırlıklar sürekli olarak optimize edilir (Yamashita ve ark. 2018).

KSA mimarisinde yer alan konvolüsyon katmanları, girdilerin farklı bölgelerinde hareket eden bir pencere (filtre) kullanarak özellik haritaları üretir. Bu filtreler sayesinde model, görüntünün herhangi bir bölgesinden önemli bilgileri çıkarabilir. Örnekleme katmanları ise bu bilgilerin boyutunu azaltarak hem bellek kullanımı hem de işlem süresi açısından avantaj sağlar (Abdullah ve ark. 2022). Görüntü ve ses gibi yüksek boyutlu verilerle yapılan uygulamalarda, KSA mimarileri diğer derin öğrenme modellerine kıyasla üstün başarı göstermektedir (Benuwa ve ark. 2016).

Özellikle tıbbi görüntüleme alanında KSA'ların önemi giderek artmaktadır. KSA tabanlı sistemler, eğitilmiş bir insan beyninin tanı yetkinliğini taklit ederek hatta bazı durumlarda aşarak, otomatik ve kesin analizler yapılmasını mümkün kılar. Bu yönüyle, KSA'lar günümüzde tıbbi görüntülerin işlenmesi ve analiz edilmesinde sıkça tercih edilen yapay zeka modelleri arasında yer almaktadır (Kugunavar ve Prabhakar, 2021). Şekil 3.9'da evrişimsel sinir ağ yapısı gösterilmiştir.



**Şekil 3.9 :** Evrişimsel sinir ağ yapısı.

### 3.6. Nesne Tanıma

MobileNetV1 Nesne tespiti, görüntü ya da video gibi görsel veriler üzerinde bulunan nesnelerin hem sınıflandırılmasını hem de konularının belirlenmesini amaçlayan temel bir bilgisayarla görme görevlerinden biridir (Ekici, 2022). Bu görev, sistemin “görüntüde hangi nesnelere var ve bu nesnelere nerede bulunuyor?” sorusuna yanıt verebilmesini sağlayan algoritmaların geliştirilmesini kapsar. Bu kapsamda, doğruluk oranı ve işlem süresi nesne tespit sistemlerinin başarısını belirleyen en önemli iki kriterdir (Zou ve ark. 2023).

Nesne tespiti, değişen pozlar, bakış açıları, aydınlatma koşulları ve görüntü kalitesindeki değişkenlik gibi çeşitli zorluklar nedeniyle karmaşık bir problem olarak kabul edilmektedir. Bu zorluklar, son yıllarda alana olan ilgiyi artırmış ve araştırmacılar tarafından yoğun şekilde çalışılan konuların başında gelmesini sağlamıştır (Zhao ve ark. 2019). Nesne tespiti yalnızca endüstriyel uygulamalarda değil, tıbbi görüntüleme, insan ve yüz algılama, maske denetimi gibi çeşitli alanlarda da kritik roller üstlenmektedir (Haykır, 2023).

Bu işlemde, görüntüdeki nesnelere sınırlayıcı kutular (bounding boxes) ile çevrelenir ve her bir kutuya ait sınıf etiketi belirlenir. Ancak nesne tespiti yalnızca sınıflandırmadan ibaret değildir; zira tek bir görüntüde birden fazla farklı nesne bulunabilir ve bunların her biri farklı kategorilere ait olabilir. Bu nedenle hem nesnelerin sınıflandırılması hem de görüntü üzerinde yerlerinin belirlenmesi birlikte ele alınmalıdır (Ekici, 2022).

Nesne tespitiyle yakından ilişkili diğer görevler; sınıflandırma, yerelleştirme, anlamsal segmentasyon ve örnek segmentasyon gibi alt görevleri içerir. Örneğin anlamsal segmentasyon, görüntüdeki tüm piksellere ait oldukları kategorilerin atanmasını sağlar. Bu işlem, sınıflandırmadan farklı olarak görüntünün tamamını değil, her pikseli ayrı ayrı değerlendirir (Rieder ve Verbeet, 2019). Yerelleştirme ise görüntüde sadece tek bir nesnenin yerinin tespit edilmesine odaklanır. Örnek segmentasyonu ise, görüntüdeki her bir nesneyi bağımsız olarak tanımlar ve anlamsal segmentasyonun kapsamını genişletir (Minaee ve ark. 2021).

Derin öğrenmeye dayalı modern nesne tespiti algoritmaları, genel olarak iki aşamalı ve tek aşamalı dedektörler olarak ikiye ayrılır. İki aşamalı dedektörler, doğruluk açısından yüksek başarı gösterse de, işlem süresi açısından daha yavaştır. Bu gruba

örnek olarak R-CNN, Fast R-CNN ve Faster R-CNN gibi modeller verilebilir. R-CNN modeli, derin öğrenme temelli ilk nesne tespit algoritmalarından biridir ve yaklaşık 2000 bölge önerisi üzerinden özellik çıkarımı yapar; ancak bu süreç oldukça zaman alıcıdır. Fast R-CNN, bu süreci kısaltmakla birlikte, hâlâ bölge önerisi ve sınıflandırma adımlarında zaman kaybına yol açmaktadır. Faster R-CNN ise önceki iki modelden daha hızlı ve yüksek doğruluklu sonuçlar üretse de görüntüyü bölgelere ayırarak işlem yaptığı için gerçek zamanlı uygulamalarda sınırlı kalabilmektedir (Li ve ark. 2017).

Tek aşamalı dedektörler arasında SSD, RetinaNet, EfficientDet ve YOLO'nun farklı sürümleri yer almaktadır. Bu yöntemler, tek bir ileri yayılım adımıyla hem sınıflandırma hem de konum belirleme işlemini aynı anda gerçekleştirerek çok daha kısa sürede sonuç üretirler. YOLO (You Only Look Once) algoritmasının ilk sürümleri hıza odaklanmış ancak doğruluk konusunda sınırlı kalmış olsa da, son sürümlerinde bu eksiklikler önemli ölçüde giderilmiştir. YOLO'nun yeni versiyonları, çok daha fazla sınıfı tanıyabilme, büyük veri kümelerine uyum sağlama ve yüksek çözünürlüklü görüntülerde etkili çalışabilme gibi önemli avantajlara sahiptir (Parlak, 2022).

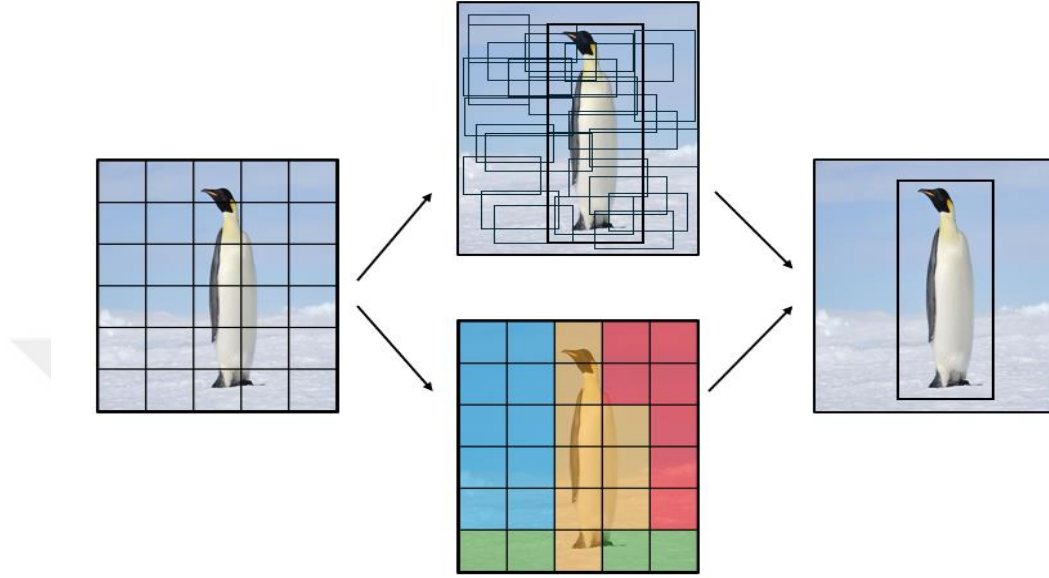
Gerçek zamanlı nesne tespiti yapılabilmesi, özellikle afet yönetimi gibi zamanla yarışın önemli olduğu uygulamalarda büyük avantaj sağlamaktadır. Bu çalışmada da, yüksek hız ve doğruluk sunması nedeniyle YOLO tabanlı nesne tespit algoritması tercih edilmiştir.

### **3.7. YOLO Algoritması**

YOLO (You Only Look Once), derin öğrenmeye dayalı nesne tespiti uygulamalarında yaygın olarak kullanılan, evrimsel sinir ağı tabanlı bir algoritmadır. İlk olarak 2015 yılında geliştirilen bu yöntem, görüntüdeki nesnelerin konumlarının ve sınıflarının aynı anda, tek bir ileri yayılım adımıyla belirlenmesine olanak tanır. Algoritmanın temel yaklaşımı, görüntüyü yalnızca bir kez analiz ederek hem sınıflandırma hem de yerleştirme işlemlerini eş zamanlı olarak gerçekleştirmesidir. Bu özelliği sayesinde, YOLO yüksek hız ve gerçek zamanlı işleme kabiliyeti sunmakta ve özellikle zaman kısıtlı uygulamalarda tercih edilmektedir.

YOLO mimarisi, nesne tespiti sürecinde görüntüyü sabit boyutlarda ızgara hücrelerine ayırır. Her bir hücre, kendisine düşen alan içerisinde nesne olup olmadığını değerlendirir. Tespit edilen nesneler için sınırlayıcı kutular (bounding boxes) üretilir ve bu kutulara karşılık gelen sınıf tahminleri yapılır (Şekil 3.10). Bu işlem, görüntü

üzerinde tek bir geçişle tamamlandığı için sistem son derece hızlı çalışır. Bu açıdan, YOLO algoritması, yine tek aşamalı dedektörler arasında yer alan SSD gibi modellere benzerlik göstermektedir (Liu ve ark. 2016).



**Şekil 3.10 :** Görüntüde sınırlayıcı kutularla nesne belirleme.

Şekil 3.11’ de YOLO ailesinin zaman içerisindeki gelişmeleri gösterilmiştir. İlk sürümleri yalnızca sınırlı sayıda nesneyi algılayabilirken, sonraki versiyonlar çok daha fazla nesne sınıfını, daha yüksek doğrulukla tanımlayabilmektedir. Günümüzde YOLO algoritmasının on iki farklı versiyonu geliştirilmiştir ve her yeni sürümde hem tespit doğruluğu hem de işlem hızı yönünden önemli iyileştirmeler yapılmıştır. Özellikle son versiyonlar, büyük veri kümelerinde ve yüksek çözünürlüklü görüntülerde dahi hızlı ve doğru nesne tespiti yapabilmektedir. Bu yönleriyle YOLO, görüntü analizinde hem akademik araştırmalarda hem de endüstriyel uygulamalarda etkin biçimde kullanılan modern ve güçlü bir nesne tespit yöntemidir.



**Şekil 3.11 : YOLO algoritmalarının evrimi.**

Bu çalışmada, derin öğrenme tabanlı nesne tespiti algoritmaları arasından YOLOv8 tercih edilmiştir. YOLOv8, önceki sürümlere kıyasla daha yüksek doğruluk mAP oranı ve daha düşük gecikme süresine sahiptir. Mimarisinde yapılan optimizasyonlar sayesinde, farklı boyutlardaki nesnelere daha hassas şekilde algılayabilmekte ve gerçek zamanlı uygulamalarda üstün performans sergilemektedir.

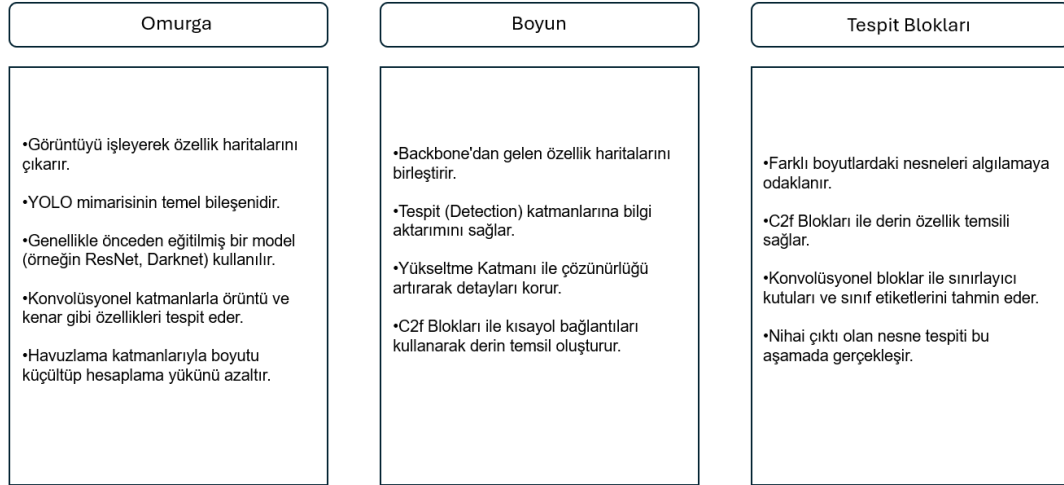
### 3.8. YOLOv8 Mimarisinin Temelleri

Ultralytics tarafından geliştirilen YOLOv8, nesne tespiti alanında yüksek doğruluk ve işlem hızı sunması nedeniyle son dönemde öne çıkan modellerden biridir. Bu model, önceki YOLO sürümlerinde karşılaşılan pek çok yapısal sınırlılığı ortadan kaldırarak daha stabil ve verimli bir yapı ortaya koymuştur (Ultralytics YOLOv8, 2023). YOLOv8, farklı ihtiyaçlara göre optimize edilmiş beş ayrı model (YOLOv8n, YOLOv8s, YOLOv8m, YOLOv8l ve YOLOv8x) ile kullanıcıya esneklik sağlamaktadır (Talaat ve ZainEldin, 2023). Bu sürüm, yalnızca nesne tanıma değil, aynı zamanda segmentasyon ve sınıflandırma görevlerinde de etkili sonuçlar sunmaktadır.

Modelin öne çıkan özelliklerinden biri, gerçek zamanlı nesne tespiti yapabilmesidir. Bu sayede görüntü veya video akışı üzerinden birden fazla nesnenin eşzamanlı olarak algılanması ve örnek segmentasyon gibi ileri düzey bilgisayarla görme görevlerinin başarıyla yerine getirilmesi mümkündür (Aboah ve ark. 2023). Ayrıca YOLOv8, daha büyük boyutlu öznetelik haritaları ve geliştirilmiş evrimsel katmanlar kullanarak, önceki YOLO sürümlerine kıyasla daha yüksek doğruluk ve verimlilik sağlamaktadır (Tamang ve ark. 2023).

Yeni nesil bir ana ağ yapısına (backbone), çapasız bir tespit başlığına ve özelleştirilmiş bir kayıp fonksiyonuna sahip olan YOLOv8, nesne tespiti, görüntü sınıflandırması ve segmentasyon gibi görevler için güçlü bir altyapı sunmaktadır. Bu özellikleri

sayesinde, genişletilebilir ve çok amaçlı uygulamalara uyarlanabilir yapısıyla, günümüzün bilgisayarla görme sistemleri içerisinde tercih edilen modellerden biri hâline gelmiştir.



Şekil 3.12 : YOLOv8 mimarisini.

Şekil 3.12' de YOLOv8 mimarisinin üç temel bileşenini – Omurga (Backbone), Boyun (Neck) ve Tespit Blokları (Detection Blocks) – şematik olarak verilmiştir. Her bir bölüm, mimaride üstlendiği işlevsel rol doğrultusunda özetlenmiş ve maddeler halinde açıklanmıştır.

Omurga, modelin giriş katmanı olan omurga, görüntüyü işleyerek temel özellik haritalarını çıkarır. Bu aşamada genellikle önceden eğitilmiş bir konvolüsyonel sinir ağı (örneğin Darknet veya ResNet) kullanılır. Görüntüdeki kenar, doku ve desen gibi düşük seviyeli özellikler konvolüsyonel katmanlar yardımıyla tespit edilirken, havuzlama katmanları ile uzamsal boyut azaltılarak hesaplama yükü düşürülür.

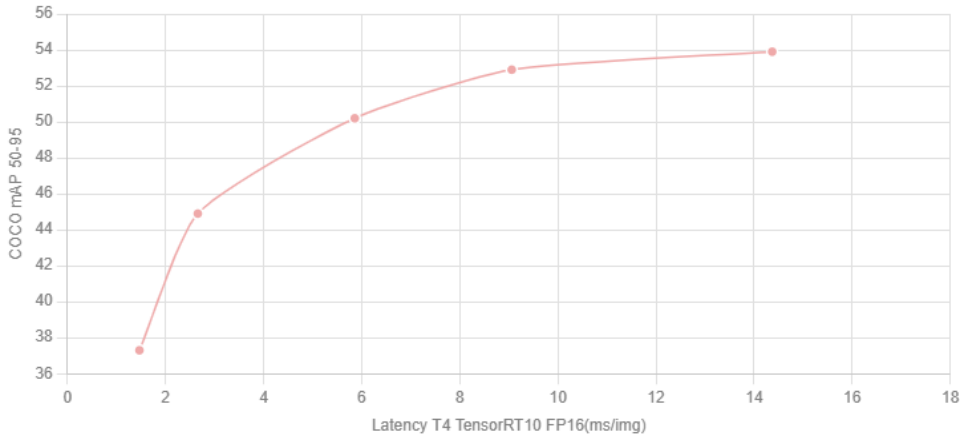
Boyun, omurgadan gelen çok seviyeli özellik haritalarını birleştirerek tespit katmanlarına uygun hale getirir. Yükseltme (upsample) katmanları, düşük çözünürlüklü haritaları büyütürken daha ince detayların korunmasını sağlar. C2f blokları ise kısayol bağlantıları ve derinlik katmanları ile derin özellik temsili oluşturarak ağı daha sağlam genelleştirme yapmasına katkı sağlar.

Tespit Blokları, nesne tespitinin yapıldığı son aşamadır. Farklı ölçeklerdeki nesnelere algılayabilmek için çoklu çıkış katmanları içerir. C2f blokları ile öğrenilen derin

özellikler, konvolüsyonel katmanlar aracılığıyla nesnelerin sınıfı ve sınırlayıcı kutuları (bounding boxes) olarak tahmin edilir. Nihai olarak modelin çıktısı bu bloklardan elde edilir (Dunlu, 2023).

### 3.8.1. YOLOv8 performans değerleri

Şekil 3.13’ de YOLOv8 modellerine ait performans değerleri verilmiştir. Yatay ekseninde modellerin milisaniye cinsinden tek bir görüntüyü işleme süresi, dikey ekseninde ise COCO veri seti üzerinde elde edilen mAP değerleri yer almaktadır. Doğruluk değeri arttıkça modelin daha fazla işlem süresine ihtiyaç duyduğu görülmüştür. Örneğin, yaklaşık 1.5 ms gecikme süresine sahip bir modelin doğruluğu %37 seviyesindeyken, yaklaşık 14 ms gecikme süresine sahip bir modelin doğruluğu %54'e ulaşmaktadır. Bu durum, doğruluk ile gecikme arasında belirgin bir denge olduğunu ortaya koymakta; yani daha hassas sonuçlar veren modellerin işlem süresi bakımından daha maliyetli olduğu anlaşılmaktadır. Bu nedenle, gerçek zamanlı nesne tespiti gibi uygulamalarda kullanılacak model seçilirken hız ve doğruluk arasında dikkatli bir optimizasyon yapılması gerekmektedir.



Şekil 3.13 : YOLOv8 modeline ait gecikme–doğruluk dengesi.

**Çizelge 3.2 :** YOLOv8 modellerinin mAP, hız, parametre sayısı ve FLOP değerlerine göre karşılaştırılması.

Model	Boyut (piksel)	mAPval	Hız CPU ONNX(ms)	HIZ A100 TensorRT (ms)	Params (M)	FLOP (B)
YOLOv8n	640	37.3	80.4	0.99	3.2	8.7
YOLOv8s	640	44.9	128.4	1.20	11.2	28.6
YOLOv8m	640	50.2	234.7	1.83	25.9	78.9
YOLOv8l	640	52.9	375.2	2.39	43.7	165.2
YOLOv8x	640	53.9	479.1	3.53	68.2	257.8

Çizelge 3.2’ de YOLOv8 mimarisine ait farklı versiyonların (n, s, m, l, x) belirli donanım ve koşullar altında elde ettiği performans ölçümleri karşılaştırılmıştır. Tüm modeller 640x640 piksel giriş boyutuyla test edilmiştir. "mAPval" sütunu, modellerin nesne tespiti doğruluğunu temsil eden ortalama hassasiyet değerlerini göstermektedir. Bu değer artması, modelin doğruluk açısından daha iyi performans sunduğunu ifade eder. En küçük model olan YOLOv8n, %37.3 doğruluk elde ederken, en büyük model olan YOLOv8x %53.9 doğruluk elde etmiştir.

Bununla birlikte, daha yüksek doğruluk daha fazla işlem gücü gerektirdiğinden, model boyutu büyüdükçe hem parametre sayısı (Params, milyon cinsinden) hem de hesaplama karmaşıklığı (FLOP, milyar cinsinden) artmaktadır. Örneğin, YOLOv8n modeli yalnızca 3.2 milyon parametreye ve 8.7 GFLOP hesaplama gereksinimine sahipken, YOLOv8x modeli 68.2 milyon parametre ve 257.8 GFLOP ile çalışmaktadır.

Çizelge 3.2’de modellerin ONNX formatında CPU üzerinde (Hız CPU ONNX) ve A100 GPU’da TensorRT ile çalıştırıldığında (HIZ A100 TensorRT) elde ettikleri gecikme (latency) süreleri verilmiştir. YOLOv8n modeli CPU üzerinde ortalama 80.4 ms’ de işlem yaparken, YOLOv8x modeli için bu süre 479.1 ms’ ye kadar çıkmaktadır. A100 GPU üzerinde ise gecikme süreleri oldukça düşüktür: YOLOv8n için 0.99 ms, YOLOv8x için 3.53 ms olarak ölçülmüştür.


Kullanılacak olan model seçileceğinde doğruluk ve performans ihtiyaçlarına göre karar verilmelidir. Gerçek zamanlılık gerektiren uygulamalarda daha küçük modeller tercih edilirken, doğruluk hassasiyetinin ön planda olduğu senaryolarda daha büyük modellerin kullanımı daha uygundur. Bu tez kapsamında enkaz tespiti süreci YOLOv8'in nano, small, medium ve large modelleri kullanılarak gerçekleştirilmiştir. Kullanılan modellerin performansları birbiriyle karşılaştırmalı olarak analiz edilmiştir.



## 4. MATERYAL VE METOT

### 4.1. Çalışmanın Tasarımı

Bu çalışma, afet sonrası hasar tespit süreçlerini hızlandırmak ve insan müdahalesine olan ihtiyacı azaltmak amacıyla, drone ile elde edilen görüntüler üzerinden YOLOv8 nesne tespiti algoritması kullanılarak enkaz tespiti yapılmasını hedeflemektedir. Çalışma kapsamında geliştirilen sistemin genel yapısı, veri seti hazırlama, veri etiketleme, model eğitimi ve değerlendirme olmak üzere dört temel aşamadan oluşmaktadır (Şekil 4.1). İlk aşamada, farklı açılardan ve senaryolardan elde edilen görüntüler toplanmış ve bu görüntüler etiketleme sürecine uygun şekilde düzenlenmiştir. Etiketleme işlemi sonrasında, elde edilen veri seti Ultralytics tarafından geliştirilen YOLOv8 modeliyle eğitilmiştir. Eğitim sürecinde, farklı model konfigürasyonları değerlendirilerek en uygun yapı belirlenmiş ve son aşamada modelin doğruluk düzeyi, test ortamında gerçekleştirilen simülasyonlarla analiz edilmiştir. Bu çalışma, hem akademik araştırmalar için uygulanabilir bir örnek sunmakta hem de sahada kullanılacak hızlı ve etkili bir enkaz tespit sisteminin temelini oluşturmaktadır.



Şekil 4.1 : Çalışmanın genel tasarımı.

### 4.2. Veri Seti Hazırlığı

Bu çalışmada, toplam 2099 adet görüntü içeren bir veri seti kullanılmıştır. Görseller, Hatay-Maraş depremine ait kamuya açık drone görüntülerinden oluşturulmuştur. Bu görüntüler, Yahya Eke (2023) tarafından YouTube platformunda yayımlanan kayıtlar temel alınarak elde edilmiştir. Görsellerdeki enkaz alanları manuel olarak sınırlayıcı kutularla işaretlenmiş ve YOLO formatına uygun şekilde etiketlenmiştir.

Veri seti, eğitim ve doğrulama işlemleri için otomatik olarak şu şekilde bölünmüştür:

- Eğitim seti (Train Set): 1874 görüntü (%89)

Modelin öğrenme süreci bu görseller üzerinden gerçekleştirilmiştir. Eğitim verisinin yüksek oranlı tutulması, modelin nesne sınıflarını etkili biçimde öğrenmesini sağlamıştır.

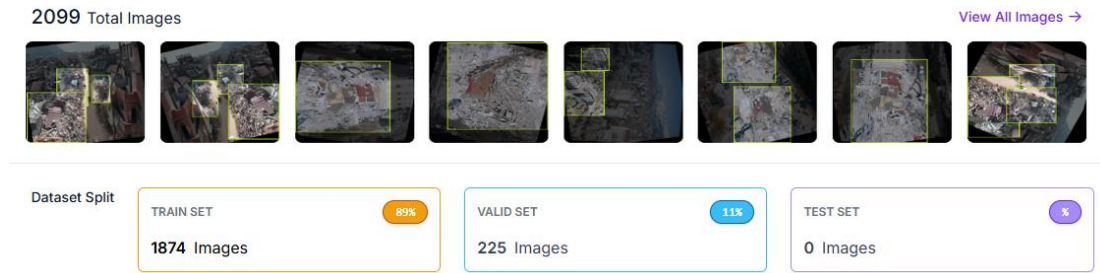
- Doğrulama seti (Validation Set): 225 görüntü (%11)

Eğitim sırasında her epoch sonunda doğrulama yapılarak aşırı öğrenme (overfitting) riski izlenmiş ve model performansı kontrol altında tutulmuştur.

- Test seti: 0 görüntü (%0)

Bu çalışmada test veri seti kullanılmamış; modelin performansı, yalnızca eğitim ve doğrulama veri setleri üzerinden değerlendirilmiştir.

Ayrıca, modelin farklı açılardan ve koşullardan gelen görüntüler karşısında daha kararlı sonuçlar vermesi amacıyla rotation (döndürme) ve flip (yansıtma) veri artırma teknikleri kullanılmıştır. Böylece hem veri çeşitliliği sağlanmış hem de toplam 2099 görüntüden oluşan kapsamlı bir veri seti elde edilmiştir. Etiketleme işlemleri Roboflow platformu üzerinden gerçekleştirilmiş olup, veri seti yalnızca "enkaz" sınıfını içerecek şekilde tek sınıflı olarak hazırlanmıştır. Şekil 4.2'de veri setinin dağılımı verilmiştir.



Şekil 4.2 : Enkaz görüntülerinin veri kümesindeki dağılımı.

### 4.3. Veri Etiketleme Süreci

Bu çalışmada, veri setinin etkin şekilde hazırlanabilmesi ve etiketleme sürecinin kolaylaştırılması amacıyla Roboflow platformu tercih edilmiştir. Roboflow, özellikle bilgisayarla görme projelerinde sıkça kullanılan, kullanıcı dostu arayüzü ile dikkat çeken çevrim içi bir veri yönetim ve etiketleme ortamıdır. Platform sayesinde, veri setindeki görsellerin yüklenmesi, sınıflandırılması, proje bazlı organize edilmesi ve

çeşitli formatlara dönüştürülerek dışa aktarılması oldukça pratik bir şekilde gerçekleştirilmiştir.

Etiketleme işlemi sırasında, görüntülerde yer alan enkaz bölgeleri manuel olarak “bounding box” yöntemi ile belirlenmiştir. Bu yöntemle, her görüntüdeki hedef nesne (enkaz) dikdörtgen çerçeveler içine alınarak tanımlanmış ve her bir nesne uygun etiket ismiyle ilişkilendirilmiştir. Roboflow’un sunduğu otomatik hizalama, sınıf tanımlama ve hata uyarı sistemleri, etiketleme sürecinin doğruluğunu artırmaya katkı sağlamıştır. Ayrıca platform, veri setini YOLOv8 ile uyumlu formatta dışa aktarabilme özelliği sayesinde, etiketlenen görüntülerin doğrudan model eğitiminde kullanılmasına olanak tanımıştır.

Yalnızca yıkılmış binalar sınıfı üzerinden etiketleme yapılmasının sebebi, afet sonrası müdahale süreçlerinde öncelikli olarak hasarlı bölgelerin tespitine duyulan acil ihtiyaçtır. Yıkılmamış veya hasarsız yapıların tespiti, afet yönetimi açısından ikincil öneme sahip olduğundan, sınıflandırma sürecinde yalnızca yıkım odaklı bir yaklaşım tercih edilmiştir. Bu tercih, modelin sınıf dengesizliği probleminden etkilenmesini azaltmak ve yüksek doğrulukta enkaz tespiti sağlamak amacıyla yapılmıştır. Ayrıca, görsel benzerlik taşıyan sınıfların birlikte işlenmesi durumunda, modelin genel performansında düşüş yaşanması muhtemeldir. Bu nedenle, sınırlı kaynaklarla çalışan sistemlerde sade ve etkili bir sınıflandırma yapılması, gerçek zamanlı uygulamalarda karar destek mekanizmalarının güvenilirliğini artırmaktadır.

Bu süreçte oluşturulan etiketli görüntüler, YOLO formatına uygun şekilde train, validation klasörlerine ayrılarak model eğitimine hazır hâle getirilmiştir. Roboflow üzerinden gerçekleştirilen etiketleme süreci, yalnızca doğruluğu artırmakla kalmamış, aynı zamanda zaman ve iş gücü açısından da önemli ölçüde verimlilik sağlamıştır. Şekil 4.3’ de orijinal görseller, Şekil 4.4’ de etiketlenmiş görseller verilmiştir.



Şekil 4.3 : Etiketleme yapılmamış örnek görseller.



Şekil 4.4 : Etiketleme yapılmış örnek görseller.

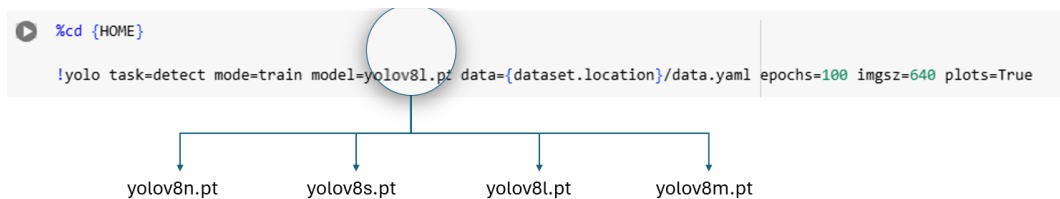
#### 4.4. YOLOv8 Modeli ve Model Eğitimi

Bu çalışmada, enkaz tespiti amacıyla Ultralytics tarafından geliştirilen YOLOv8 (You Only Look Once, Version 8) nesne tanıma algoritmasının farklı boyutlandırmalara sahip versiyonları (YOLOv8n, YOLOv8s, YOLOv8m, YOLOv8l) kullanılmıştır (Şekil 4.5). YOLOv8, önceki sürümlerine kıyasla daha yüksek doğruluk oranı, düşük gecikme süresi ve optimize edilmiş model mimarisi ile öne çıkmaktadır. Bu özellikleri sayesinde, özellikle afet yönetimi gibi gerçek zamanlı müdahale gerektiren senaryolarda etkin bir biçimde kullanılabilir.

Modelin temel parametreleri şu şekildedir:

- Model tipleri: YOLOv8n (nano), YOLOv8s (small), YOLOv8m (medium), YOLOv8l (large)
- Giriş boyutu: 640×640 piksel
- Çıktı sınıfı: Enkaz (tek sınıf)
- Çıktı formatı: Sınırlayıcı kutular (bounding boxes)
- Epoch sayısı: 100

Model eğitim süreci, Google Colab platformunda NVIDIA T4 GPU destekli bir ortamda gerçekleştirilmiştir. Ultralytics'in açık kaynaklı YOLOv8 mimarisi kullanılarak yalnızca “enkaz” sınıfına yönelik tek sınıflı nesne tespiti yapılmıştır. Tüm görseller, eğitim sürecine dahil edilmeden önce 640×640 piksel boyutuna yeniden ölçeklendirilmiştir. Farklı model varyantlarının performansı karşılaştırmalı olarak değerlendirilmiş ve sonuçlar analiz edilmiştir.



```
%cd {HOME}
!yolo task=detect mode=train model=yolov8l.pt data={dataset.location}/data.yaml epochs=100 imgsz=640 plots=True
```

yolov8n.pt   yolov8s.pt   yolov8l.pt   yolov8m.pt

Şekil 4.5 : YOLOv8 eğitim süreci.

Model tek bir sınıf için eğitilmiştir. Eğitimi başlatan kod Şekil 4.5’ de verilmiştir. Kodun açıklamaları aşağıda maddeler halinde verilmiştir:

- `task=detect`: Modelin nesne tespiti (object detection) amacıyla kullanılacağını belirtir.
- `mode=train`: Modelin eğitim modunda çalıştırılacağını ifade eder.
- `model=` Her model tipi (yolov8n.pt, yolov8s.pt, yolov8m.pt, yolov8l.pt) ayrı ayrı eğitilmiş ve performansları karşılaştırılmıştır.
- `data={dataset.location}/data.yaml`: Eğitim ve doğrulama veri yolları, sınıf sayısı ve etiket isimleri gibi bilgileri içeren .yaml uzantılı veri yapılandırma dosyasının konumudur.
- `epochs=100`: Modelin toplam 100 döngü (epoch) boyunca eğitileceğini belirtir.
- `imgsz=640`: Eğitim sırasında tüm görüntülerin 640x640 piksel boyutuna yeniden ölçeklendirileceğini ifade eder.
- `plots=True`: Eğitim süreci boyunca doğruluk (accuracy), mAP, loss gibi metriklerin görselleştirilmesini sağlar ve bu çıktılar runs/detect/train klasörüne kaydedilir.

Bu yapılandırma ile, YOLOv8n, YOLOv8s, YOLOv8m, YOLOv8l, modelleri yalnızca “enkaz” sınıfını tanıyacak şekilde eğitilmiş ve elde edilen ağırlık dosyaları, test ve değerlendirme aşamalarında kullanılmıştır.

## 4.5. Test Ortamı ve Simülasyon Sahası

### 4.5.1. Kullanılan drone donanımı

Test sürecinde, hava tabanlı görüntüleme ihtiyacını karşılamak ve simülasyon sahasından yüksek çözünürlüklü görüntüler elde etmek amacıyla DJI Mavic 2 marka drone kullanılmıştır. Bu model, kompakt yapısı, gelişmiş kamera sistemi ve istikrarlı uçuş performansı ile özellikle araştırma ve görsel analiz uygulamaları için uygun bir donanıma sahiptir. Şekil 4.6 ‘da kullanılan drone’a ait görsel verilmiştir.



**Şekil 4.6 :** DJI mavic 2 drone görseli.

DJI Mavic 2 özellikleri aşağıda verilmiştir:

- Kamera: 1 inç CMOS sensöre sahip Hasselblad kamera
- Fotoğraf Çözünürlüğü: 20 megapiksel
- Video Çözünürlüğü: 4K UHD (3840×2160 piksel)
- Gimbal: 3 eksenli stabilizasyon sistemi
- Uçuş Süresi: Yaklaşık 31 dakika
- Engel Algılama: Ön, arka, üst, alt ve yanlarda çok yönlü engel sensörleri
- GPS ve GLONASS desteği sayesinde konumlama ve rota takibi açısından yüksek doğruluk sağlamaktadır.

Bu drone, sahada stabil görüntü elde etmek ve enkaz benzeri yapıların detaylarını net şekilde yakalamak açısından başarılı sonuçlar vermektedir. Otomatik uçuş modları, sabit irtifa kontrolü ve hassas kamera sabitleyicisi sayesinde test sahasındaki farklı açılardan görüntü toplama işlemleri güvenli ve verimli şekilde gerçekleştirilmiştir.

#### 4.5.2. Simülasyon sahasının oluşturulması

Simülasyon sahasında hazırlanan enkaz görsellerinin, farklı zemin tipleri üzerinde test edilmesi amacıyla üç ayrı fiziksel ortam belirlenmiştir. Her bir ortamda, farklı yapı ve renk özelliklerine sahip yüzeylere yüksek çözünürlüklü enkaz çıktıları yerleştirilmiştir ve DJI Mavic 2 drone kullanılarak havadan görüntüleme işlemi gerçekleştirilmiştir. Bu çeşitlendirme, YOLOv8 modelinin yalnızca tek tip zemin üzerinde değil, farklı çevresel arka planlara sahip alanlarda da genel performansının değerlendirilmesini mümkün kılmıştır. Şekil 4.7’ de 3 adet zemine yerleştirilmiş görseller verilmiştir.



Şekil 4.7 : Enkaz görüntüsü yerleştirilmiş görsel.

İlk sahada, düz ve açık renkli bir parke taş zemin üzerinde büyük boyutlu bir enkaz görseli yerleştirilmiştir. Bu yüzey, düz yapısı sayesinde net kontur ayrımı sağlamakta ve drone tarafından görüntüleme açısından ideal bir test ortamı oluşturmaktadır.

İkinci sahada, çim ve toprak karışımı doğal bir yüzey tercih edilmiştir. Bu ortam, gerçek afet sahalarını taklit eden düzensiz bir arka plana sahiptir. Bu yüzeyde modelin, doğal dokular ve farklı ışık-gölge koşulları altında da nesne tespit başarısı değerlendirilmiştir.

Üçüncü sahada, yine parke zemin kullanılmış ancak bu kez daha açık renk tonlarına sahip ve farklı doğrusal çizgiler içeren bir zemin yapısı seçilmiştir. Bu ortamda yerleştirilen enkaz görseli, modelin farklı zemin desenleri karşısındaki hassasiyetini test etmeye olanak sağlamıştır.

Bu üç farklı ortamdaki görüntüler, test veri seti olarak kullanılmış ve YOLOv8 modelinin genelleme kapasitesi, çeşitli arka plan koşullarında ölçülmüştür. Görüntüler, hem dik açıdan (nadir perspektif) hem de eğimli uçuş açılarından alınarak modele çeşitli bakış açıları kazandırılmıştır. Bu sayede eğitilen modellerin, farklı çevresel koşullarda gerçek zamanlı enkaz tespiti yapabilme yetenekleri değerlendirilmiştir.

#### **4.5.3. Görüntü toplama süreci**

Simülasyon sahasında yerleştirilen enkaz görselleri üzerinde gerçekleştirilen testlerde, DJI Mavic 2 marka drone kullanılarak sahaya ait görüntüler elde edilmiştir. Drone, yaklaşık 5 ila 10 metre irtifa aralığında yatay ve dikey ekseninde hareket ettirilerek farklı açılardan ve yüksekliklerden video kayıtları alınmıştır. Bu yöntem, modelin daha çeşitli görüntülerle test edilmesini sağlamıştır.

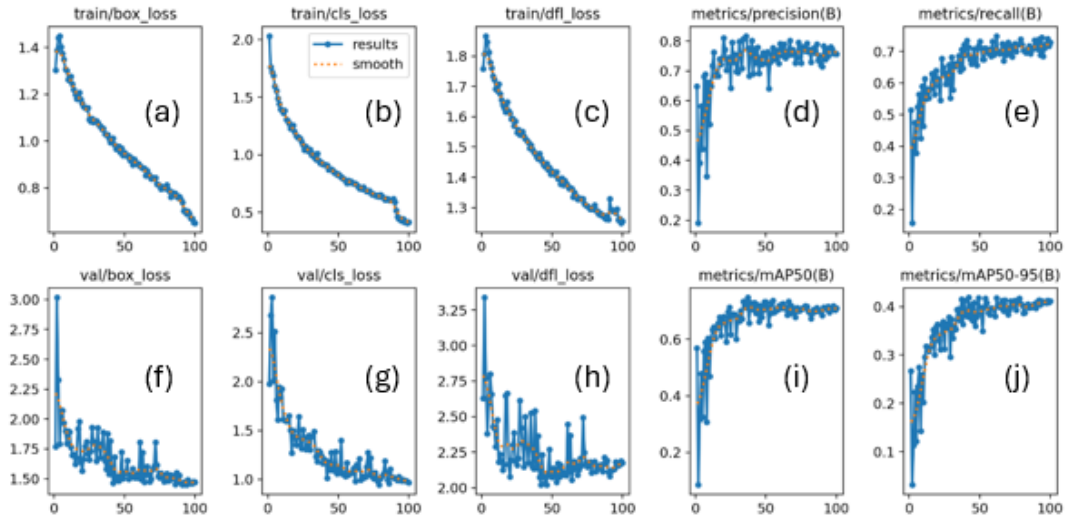
Video çekimleri sırasında, drone sabit noktada havada durarak belirli yüksekliklerde dik açıyla kayıt yapmış; ardından çapraz açığa geçerek görsellerin eğimli perspektiflerden de yakalanmasını sağlamıştır. Böylece yalnızca doğrudan yukarıdan değil, hafif eğimli (oblique) açılardan da veri elde edilmiştir. Bu uygulama, modelin hem yüksekte bakış hem de gerçek afet sahalarında karşılaşılabilecek çapraz perspektiflere karşı ne derece başarılı sonuçlar verebileceğini test etmek açısından önem arz etmektedir.

## 5. BULGULAR

### 5.1. Model Performans Değerlendirmesi

#### 5.1.1. YOLOv8 nano

Şekil 5.1’ de, YOLOv8 nano modeli ile gerçekleştirilen eğitim sürecine ait performans metrikleri verilmiştir. Eğitim verisi üzerinde hesaplanan box loss (a), class loss (b) ve distribution focal loss (c) değerlerinde istikrarlı bir azalma olmuştur, bu da modelin öğrenme sürecinin verimli gerçekleştiğini ortaya koymuştur. Benzer şekilde, doğrulama verisinde hesaplanan val/box loss (f), val/cls loss (g) ve val/dfi loss (h) değerlerinde de belirgin bir düşüş meydana gelmiştir. Ayrıca, eğitim süresince modelin kesinlik (d) ve duyarlılık (e) metrikleri 100. epoch sonunda yaklaşık 0.90’ ın üzerine çıkmıştır. Modelin sınırlayıcı kutu tahminlerindeki doğruluğunu gösteren mAP@0.5 (i) metriği yaklaşık 0.72 seviyelerine ulaşırken, daha geniş IoU eşik değerlerini kapsayan mAP@0.5:0.95 (j) metriği 0.40 seviyelerine kadar yükselmiştir. Modelin detaylı başarı ölçütleri Çizelge 5.1’de verilmiştir.



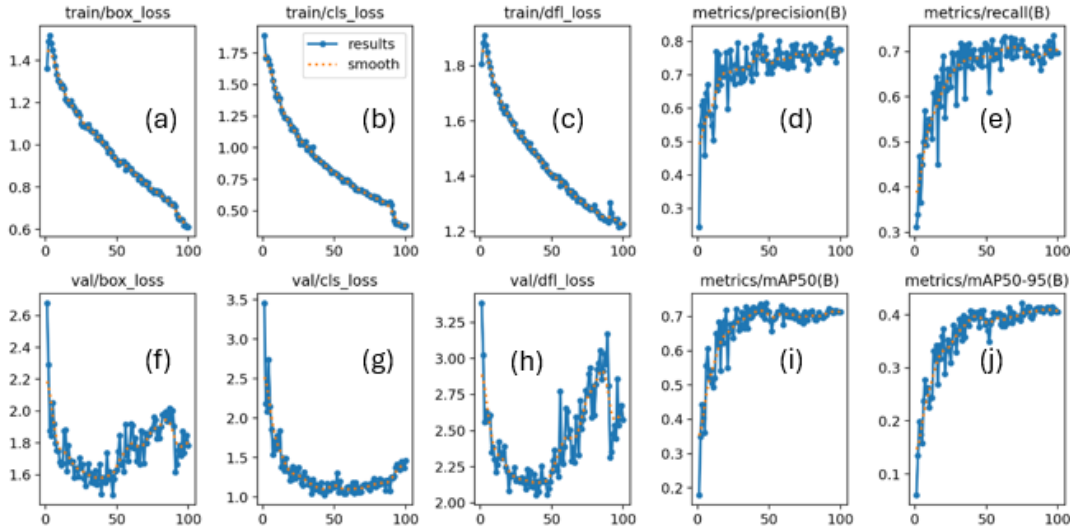
**Şekil 5.1 :** YOLOv8 nano modeli eğitim grafikleriği; (a) eğitim kutu kaybı, (b) eğitim nesne kaybı, (c) eğitim sınıf kaybı, (d) kesinlik, (e) duyarlılık, (f) doğrulama kutu kaybı, (g) doğrulama nesne kaybı, (h) doğrulama sınıf kaybı, (i) mAP\_0.5, (j) mAP\_0.95.

**Çizelge 5.1 : YOLOv8 nano model performans metrikleri.**

Model	F1	P	R	mAP@0.5
V8 nano	0.74	1.0	0.90	0.729

### 5.1.2. YOLOv8 small

Şekil 5.2’ de, YOLOv8 small modeli ile gerçekleştirilen eğitim sürecine ait performans metrikleri verilmiştir. Eğitim verisi üzerinde hesaplanan box loss (a), class loss (b) ve distribution focal loss (c) değerleri düzenli olarak azalmış, bu da modelin hedef nesnelere daha doğru sınırlayıcı kutularla tespit etmeye başladığını ortaya koymuştur. Doğrulama verisi üzerindeki val/box loss (f), val/cls loss (g) ve val/df loss (h) grafiklerinde düşüş ve artışlar meydana gelmiştir. Modelin başarımını değerlendiren kesinlik (d) ve duyarlılık (e) metrikleri 0.85 üstü seviyelere ulaşmıştır. Ortalama doğruluk metriklerinden olan mAP@0.5 (i), yaklaşık 0.71 seviyesine ulaşmış, farklı IoU eşik değerlerini kapsayan mAP@0.5:0.95 metriği ise 0.40 seviyesinde sabitlenmiştir (j). YOLOv8 small modelinin performans metrikleri Çizelge 5.2’ de verilmiştir.




**Şekil 5.2 : YOLOv8 small modeli eğitim grafikleri; (a) eğitim kutu kaybı, (b) eğitim nesne kaybı, (c) eğitim sınıf kaybı, (d) kesinlik, (e) duyarlılık, (f) doğrulama kutu kaybı, (g) doğrulama nesne kaybı, (h) doğrulama sınıf kaybı, (i) mAP\_0.5, (j) mAP\_0.95.**

**Çizelge 5.2 :** YOLOv8 small model performans metrikleri.

Model	F1	P	R	mAP@0.5
V8 Small	0.76	1.0	0.86	0.713

### 5.1.3. YOLOv8 medium

Şekil 5.3’ de YOLOv8 medium modeline ait eğitim performans metrikleri verilmiştir. Eğitim verisi üzerinde hesaplanan box loss (a), class loss (b) ve distribution focal loss (c) değerleri, epoch sayısının artışıyla birlikte düzenli olarak azalmıştır. Doğrulama verisi üzerinde izlenen val/box loss (f), val/cls loss (g) ve val/dfloss (h) grafiklerinde ise özellikle ilk 20 epoch boyunca hızlı bir iyileşme olmuştur, ardından bu değerler sabit kalmıştır. Modelin başarımlarından kesinlik (d) değeri yaklaşık 1.0 seviyesine ulaşmıştır. Duyarlılık (e) metriği ise yaklaşık 0.93 seviyesine ulaşmış ve bu düzeyde sabit kalmıştır. Ortalama doğruluk metrikleri olarak hesaplanan mAP@0.5 (i) değeri yaklaşık 0.75, daha geniş IoU aralığını kapsayan mAP@0.5:0.95 (j) ise 0.40 seviyesine ulaşmıştır. YOLOv8 medium modelinin performans metrikleri Çizelge 5.3’ de verilmiştir.



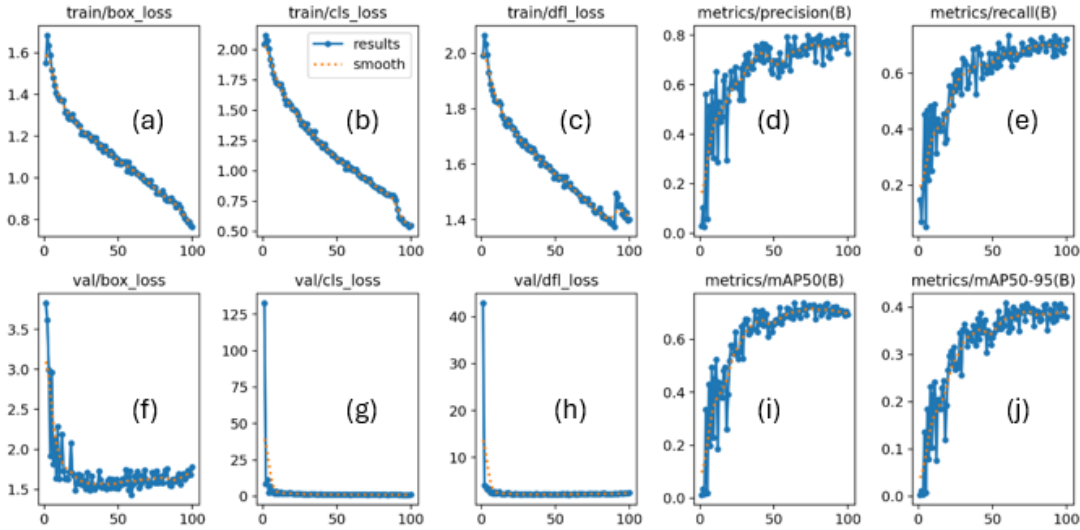
**Şekil 5.3 :** YOLOv8 medium modeli eğitim grafikleri; (a) eğitim kutu kaybı, (b) eğitim nesne kaybı, (c) eğitim sınıf kaybı, (d) kesinlik, (e) duyarlılık, (f) doğrulama kutu kaybı, (g) doğrulama nesne kaybı, (h) doğrulama sınıf kaybı, (i) mAP\_0.5, (j) mAP\_0.95.

**Çizelge 5.3 : YOLOv8 medium model performans metrikleri.**

Model	F1	P	R	mAP@0.5
V8 Medium	0.73	1.0	0.93	0.759

#### 5.1.4. YOLOv8 large

Şekil 5.4' de YOLOv8 Large modelinin eğitim sürecine ait performans metrikleri verilmiştir. Eğitim verisi üzerinde hesaplanan box loss (a), class loss (b) ve distribution focal loss (c) değerleri istikrarlı ve düzenli bir şekilde azalmıştır. Doğrulama verisi üzerinde izlenen val/box loss (f), val/cls loss (g) ve val/dfi loss (h) değerleri hızlı şekilde düşmüştür. Modelin performans değerlendirmesinde kullanılan kesinlik metriği (d), eğitim boyunca düzenli bir artış göstererek 1.0 seviyesine ulaşmıştır. Benzer şekilde, duyarlılık metriği (e) de artış göstermiş ve 0.90 seviyesine yaklaşmıştır. Ortalama doğruluk ölçütlerinden mAP@0.5 (i), yaklaşık 0.71 değerine ulaşırken, daha geniş IoU eşiklerini kapsayan mAP@0.5:0.95 (j) metriği 0.40 civarında sabitlenmiştir. YOLOv8 large modelinin performans metrikleri Çizelge 5.4' de verilmiştir.



**Şekil 5.4 : YOLOv8 large modeli eğitim grafikleri; (a) eğitim kutu kaybı, (b) eğitim nesne kaybı, (c) eğitim sınıf kaybı, (d) kesinlik, (e) duyarlılık, (f) doğrulama kutu kaybı, (g) doğrulama nesne kaybı, (h) doğrulama sınıf kaybı, (i) mAP\_0.5, (j) mAP\_0.95.**

**Çizelge 5.4 : YOLOv8 large model performans metrikleri.**

Model	F1	P	R	mAP@0.5
V8 Large	0.73	1.0	0.89	0.717

## 5.2. Model Performans Karşılaştırması

Çizelge 5.5' de kullanılan modellere ait performans metrikleri karşılaştırmalı olarak verilmiştir. Bu metrikler; F1 skoru (F1), hassasiyet (Precision - P), duyarlılık (Recall - R) ve mAP@0.5 değerleridir.

En yüksek F1 skoru 0.76 ile YOLOv8 Small modeli tarafından elde edilmiştir. Bu değer, modelin doğruluk ve duyarlılık arasında denge kurma yeteneğinin en iyi olduğunu göstermiştir.

Hassasiyet (P) değerleri tüm modellerde 1.0 olarak elde edilmiştir. Bu durum modellerin pozitif sınıfları doğru tespit etme konusunda oldukça başarılı olduklarını göstermiştir.

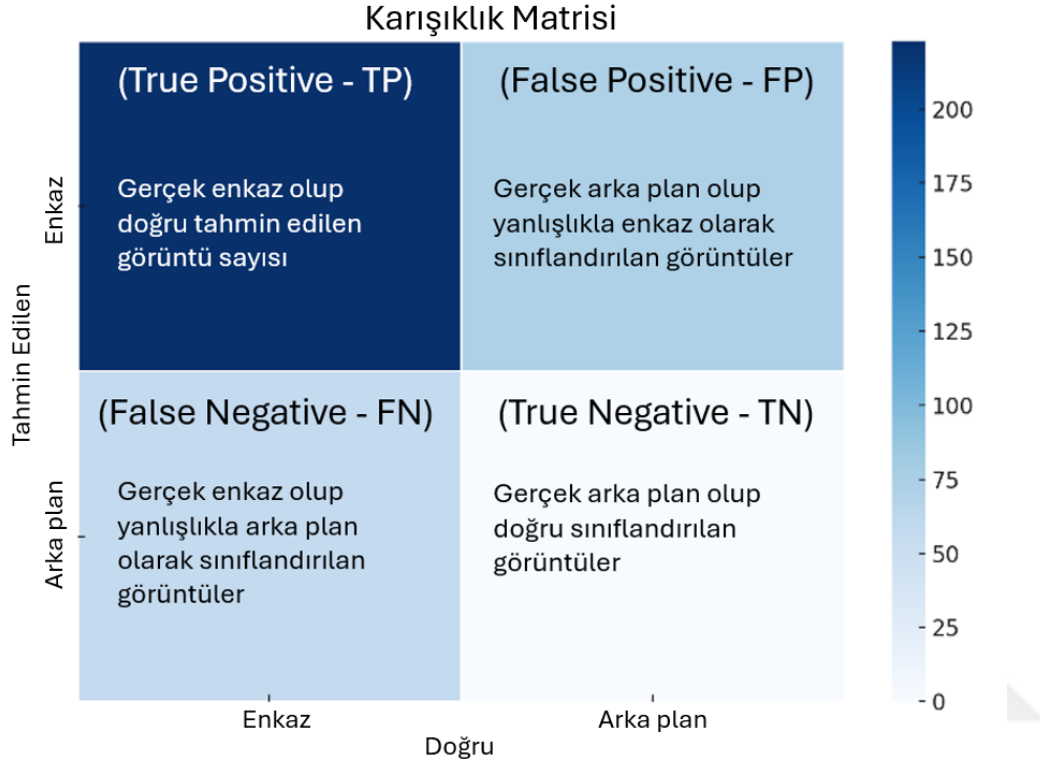
Duyarlılık (R) metriğinde en yüksek değer 0.93 ile YOLOv8 Medium modeli tarafından elde edilmiştir. Bu durum, Medium modelin pozitif örnekleri kaçırma oranının düşük olduğunu göstermiştir.

mAP@0.5 değerinde en yüksek değer 0.759 ile YOLOv8 Medium modeli tarafından elde edilmiştir. Bu, Medium modelin genel tespit performansının en yüksek olduğunu göstermiştir.

**Çizelge 5.5 : Kullanılan modellerin performans metriklerinin karşılaştırılması.**


Model	F1	P	R	mAP@0.5
V8 Nano	0.74	1.0	0.90	0.729
V8 Small	0.76	1.0	0.86	0.713
V8 Medium	0.73	1.0	0.93	0.759
V8 Large	0.73	1.0	0.89	0.717

Sonuç olarak, YOLOv8 Medium modeli, mAP@0.5 ve duyarlılık açısından öne çıkarken, YOLOv8 Small modeli en yüksek F1 skoruna sahip olması nedeniyle pratik uygulamalarda tercih edilebilir bir alternatif olarak değerlendirilebilir.



**Şekil 5.5 :** Karışıklık matrisinin yapısı.

Şekil 5.5' de, modelin sınıflandırma başarımını değerlendirmede kullanılan karışıklık matrisi görselleştirilmiştir. Bu matris, modelin gerçek enkaz ve arka plan görüntülerini ne ölçüde doğru veya hatalı sınıflandırdığını sayısal olarak ortaya koyar. Dört temel bileşenden oluşan matrister; True Positive (TP) gerçek enkazların doğru tespit edildiği durumu, False Positive (FP) arka plan görüntülerinin yanlışlıkla enkaz olarak sınıflandırıldığı durumu, False Negative (FN) gerçek enkazların gözden kaçırılarak arka plan olarak sınıflandırıldığı durumu ve True Negative (TN) ise arka planın doğru şekilde sınıflandırıldığı durumu ifade etmektedir. Bu yapı sayesinde modelin doğruluk, hassasiyet ve duyarlılık gibi performans ölçütleri hesaplanabilmektedir.



**Şekil 5.6 :** Karışıklık matrisleri ; (a) Nano, (b) Small, (c) Medium, (d) Large.

Şekil 5.6’ da kullanılan modellere ait karışıklık matrisleri verilmiştir. Nano modeli, küçük yapısıyla düşük donanım gereksinimi sunması açısından avantajlıdır. Ancak modelin TN değeri sıfır olup, arka plan sınıflandırmasında yetersiz kalmıştır. Bununla birlikte, temel düzeyde doğru enkaz tespiti yapabilmektedir, bu da modelin sınırlı kaynaklarla hızlı müdahale gereken durumlar için uygun olduğunu göstermiştir.

Small modeli, Nano’ya kıyasla daha yüksek doğru enkaz tespiti ve daha düşük kaçırılan enkaz oranı vermiştir. Bu durum, modelin özellikle enkaz odaklı görevlerde daha dengeli ve güvenilir performans sergilediğini göstermiştir. TN yine sıfır olup, arka planı ayırt etme kapasitesi sınırlıdır.

Medium modeli, tüm modeller arasında en yüksek doğru enkaz tespiti (TP) ve en düşük kaçırılan enkaz (FN) oranlarına sahiptir. Ancak yanlış pozitif değeri Small

modele göre daha yüksektir. Bu, modelin duyarlılığının (recall) yüksek olduğunu fakat kesinliğinin (precision) daha düşük kaldığını göstermiştir.

Large modeli, karmaşık yapısına rağmen daha düşük doğru tespit ve daha yüksek hata oranları vermiştir. Model mevcut veri setiyle yeterince verimli öğrenememiş veya aşırı genelleme yapmıştır. Bu çalışma kapsamında, Large modelinin diğer modellere kıyasla daha az uygun olduğu görülmüştür. Çizelge 5.6' da Karışıklık matrislerinin karşılaştırılması verilmiştir.

**Çizelge 5.6 : Karışıklık matrislerinin karşılaştırılması.**

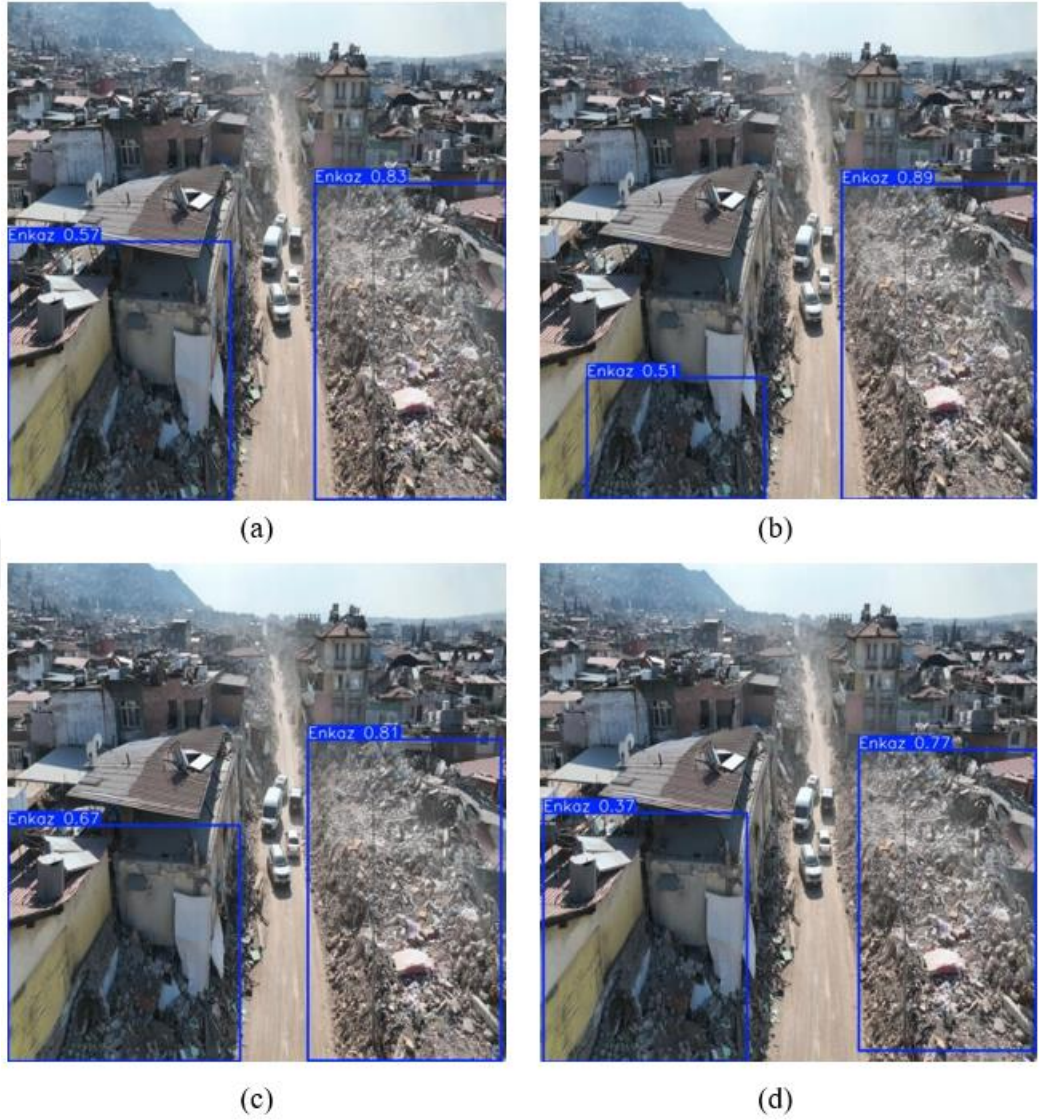
Model	TP	FP	FN	TN
Nano	217	54	63	0
Small	222	54	58	0
Medium	223	73	57	0
Large	217	73	63	0

- En yüksek doğru enkaz tespiti (TP): YOLOv8 Medium (223)
- En az kaçırılan enkaz (FN): YOLOv8 Medium (57)
- En düşük yanlış alarm (FP): YOLOv8 Nano ve Small (54)
- Arka plan sınıfı için doğru sınıflama (TN): Tüm modellerde 0

### 5.3. Görsel Çıktılar ve Örnek Tespitler

#### 5.3.1. Gerçek afet saha tespiti

Dokuz farklı test görseli kullanılarak yapılan değerlendirmede, her bir görsel için YOLOv8 ailesine ait dört farklı model varyantının (Nano, Small, Medium ve Large) performansı karşılaştırılmıştır. Model çıktıları, her bir enkaz sahnesi üzerine çizilen sınırlayıcı kutular (bounding box) ve bu kutulara ait güven skorları ile birlikte verilmiştir. Bu karşılaştırma sayesinde, farklı model boyutlarının Hatay depreminden alınmış karmaşık enkaz görüntüleri üzerindeki nesne tespit performansı görsel olarak değerlendirilmiştir.




**Şekil 5.7 :** Birinci test görüntüsüne ait sonuçlar; (a) Nano, (b) Small, (c) Medium, (d) Large

Şekil 5.7’ de yer alan Nano modeli, iki ayrı enkaz alanını 0.57 ve 0.83 doğrulukla tespit edebilmiştir. Small model ise aynı alanlarda 0.51 ve 0.89 gibi daha yüksek bir skorla tespit yapmış, özellikle derinlik algısı gerektiren uzak bölgedeki enkazı daha güçlü şekilde yakalamıştır. Bu durum Small modelin daha hassas kenar tanıma ve karmaşık yapıları ayırıştırma kabiliyetine sahip olduğunu göstermektedir.

Medium modelin 0.67 ve 0.81’lik tahminleri, Nano’ya göre daha dengeli bir başarı sağlarken; Large modelin birinci bölgedeki düşük güven skoru (0.37), bazı durumlarda aşırı genelleme eğilimi gösterebileceğine işaret etmektedir. Ancak ikinci enkaz

alanında Large model 0.77 gibi yüksek bir doğrulukla başarılı bir tespit gerçekleştirmiştir.



**Şekil 5.8** : İkinci test görüntüsüne ait sonuçlar; (a) Nano, (b) Small, (c) Medium, (d) Large.

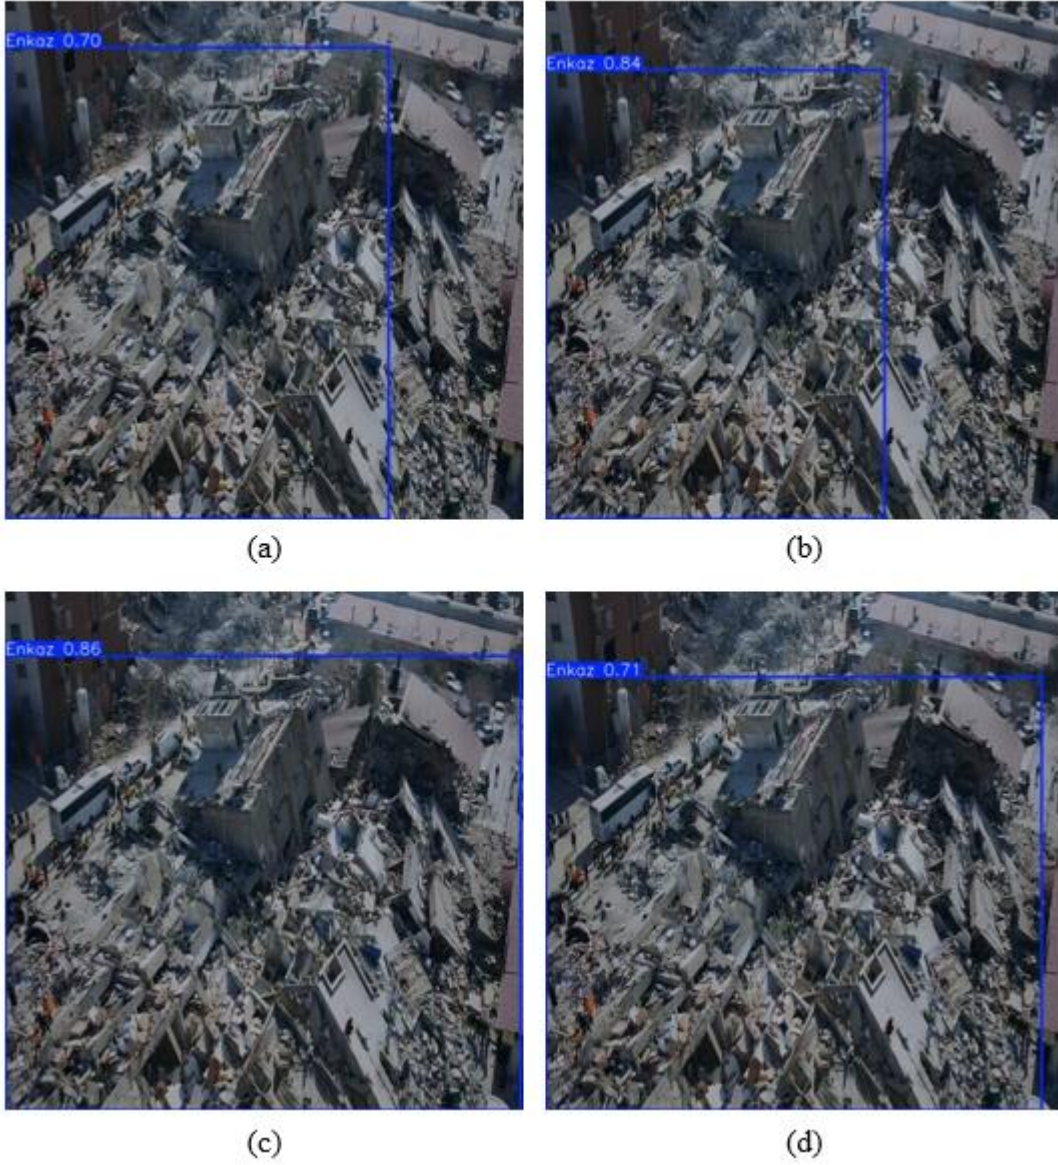
Şekil 5.8’ de yer alan YOLOv8 Nano modeli, iki ayrı enkaz bölgesini tespit etmiş ve bu bölgeleri sırasıyla 0.78 ve 0.86 güven skoru ile sınıflandırmıştır. Bu skorlar, Nano modelinin sınırlı parametre yapısına rağmen oldukça başarılı bir performans

gösterdiğini, özellikle ikinci kutuda yüksek bir kararlılıkla enkazı tanımladığını ortaya koymaktadır.

YOLOv8 Small modeli ise benzer şekilde iki enkaz bölgesi tespit etmiş ve bu bölgeleri 0.82 ve 0.84 güven skorları ile etiketlemiştir. Small modelin, hem konumlama hem de güven skoru bakımından Nano modele göre daha dengeli bir çıktı üretmiştir.

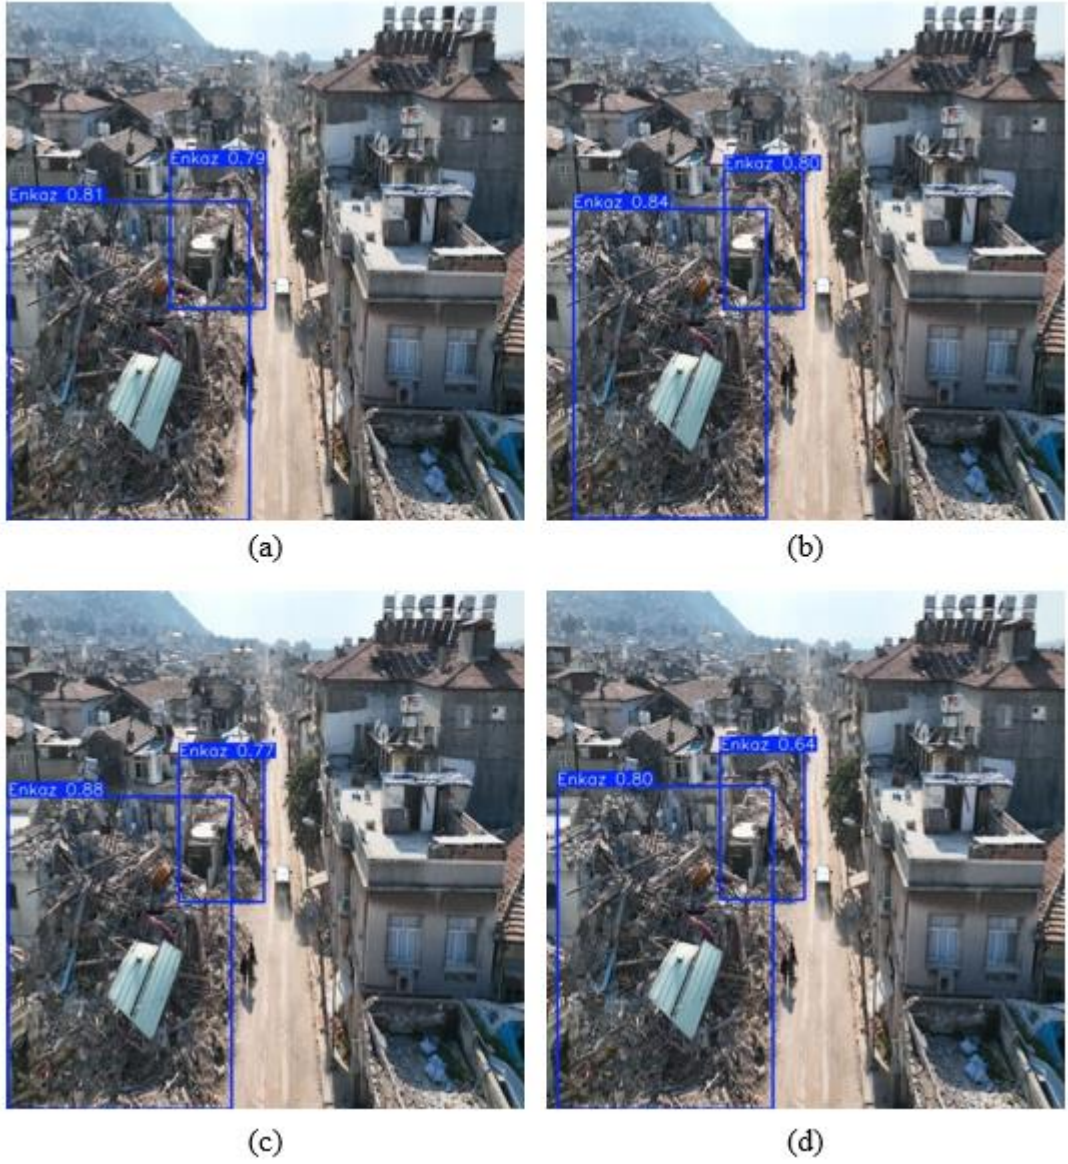
YOLOv8 Medium modeli, önceki modellerden farklı olarak daha yüksek güven skorları üretmiştir (0.85 ve 0.88). Medium modeli daha fazla parametre içermesi sayesinde enkaz yapılarını daha ayrıntılı analiz edebilmiştir.

YOLOv8 Large modeli ise en yüksek skorları veren model olmuştur: 0.82 ve 0.91. Ancak diğer örneklerde verildiği gibi Large modelin bu başarısı her zaman tutarlı değildir. Bu sahnede ise model, hem doğruluk hem de konumlama açısından oldukça başarılıdır.




**Şekil 5.9 :** Üçüncü test görüntüsüne ait sonuçlar; (a) Nano, (b) Small, (c) Medium, (d) Large.

Şekil 5.9’ da yer alan Nano modeli, genel olarak doğru tespit yapmış olsa da 0.70 gibi görece daha düşük bir güven skoruyla çalışmıştır. Enkaz sınırlarını büyük oranda doğru belirlemiş ancak detaylı ayrımlarda zayıf kalmıştır. Small modeli, bu örnekte en yüksek güven skorlarından birini üretmiştir (0.84). Görselde hem konumlama hem de sınırlayıcı kutunun kapsayıcılığı açısından oldukça isabetli sonuç vermiştir. Medium modeli 0.86 gibi oldukça yüksek bir güven değeriyle tespit yapmış ve enkazın sınırlarını en kapsamlı şekilde yakalamıştır. Modelin daha fazla parametreye sahip olması, bu tarz karmaşık yıkım alanlarında avantaj sağlamıştır. Large modeli ise bu örnekte beklenenden daha düşük bir güven skoru (0.71) üretmiştir.



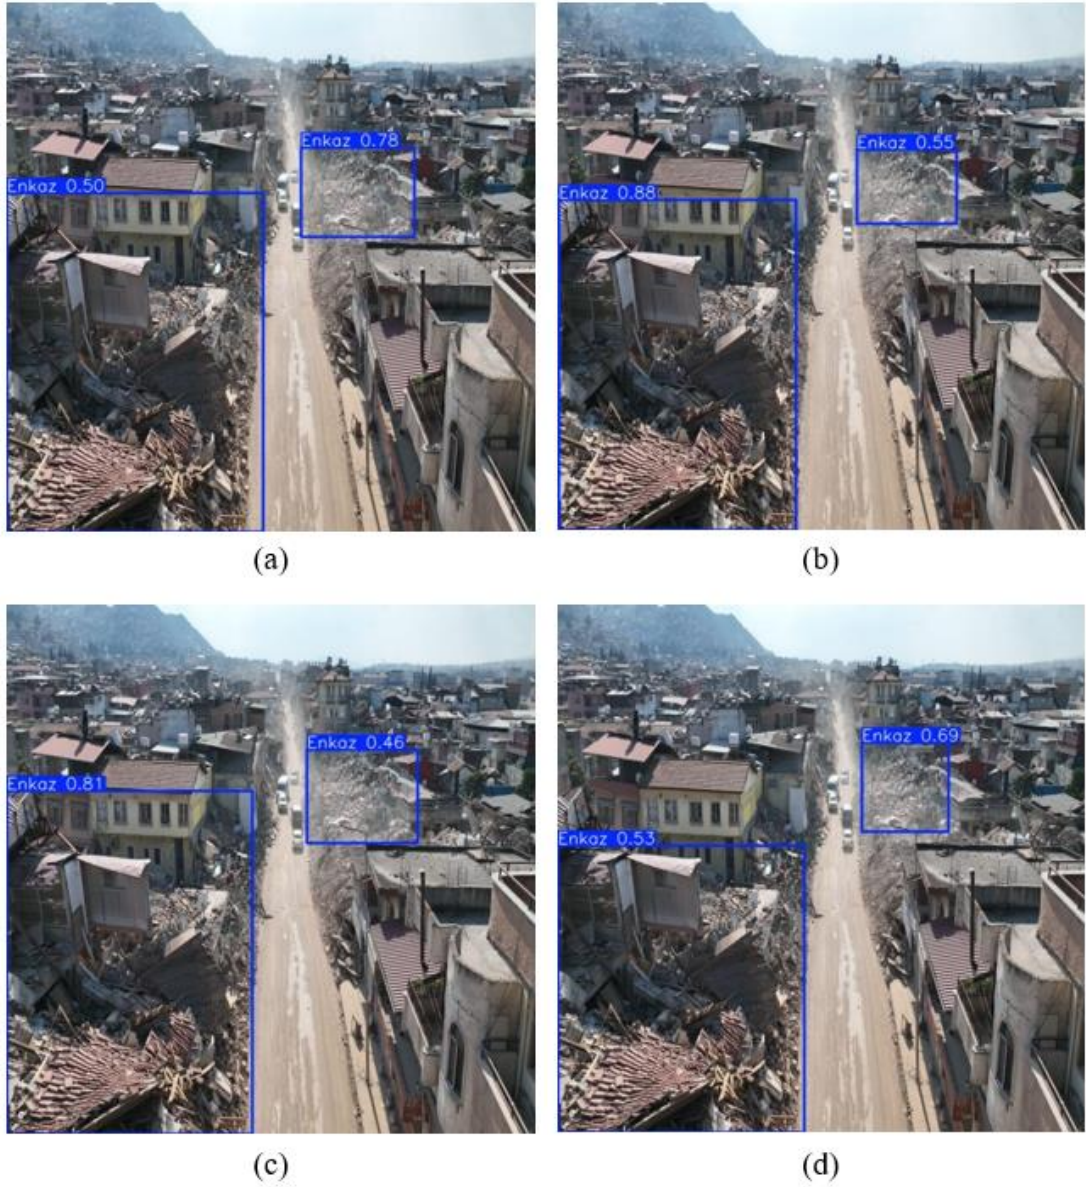
**Şekil 5.10** : Dördüncü test görüntüsüne ait sonuçlar; (a) Nano, (b) Small, (c) Medium, (d) Large.

Şekil 5.10’da yer alan Nano modeli, 0.81 ve 0.79 gibi oldukça yüksek iki güven skoru ile iki farklı enkaz bölgesini başarıyla tespit etmiştir. Kutuların konumlandırması doğru ve dengelidir. Small modeli, 0.84 ve 0.80 güven skorlarıyla enkaz bölgelerini başarılı biçimde algılamış, özellikle detaylı enkaz kümelerini ayırmakta net sonuçlar üretmiştir. Nano modeline kıyasla kutu yerleşimleri daha kompakt ve keskin sınırlarla çizilmiştir. Medium modeli, bu sahnede en yüksek güven skorlarından birini üretmiştir (0.88 ve 0.77). Large modeli ise 0.80 gibi yüksek bir skor sunarken, ikinci kutuda 0.64 gibi daha düşük bir değerle sınırlı bir tespit gerçekleştirmiştir.



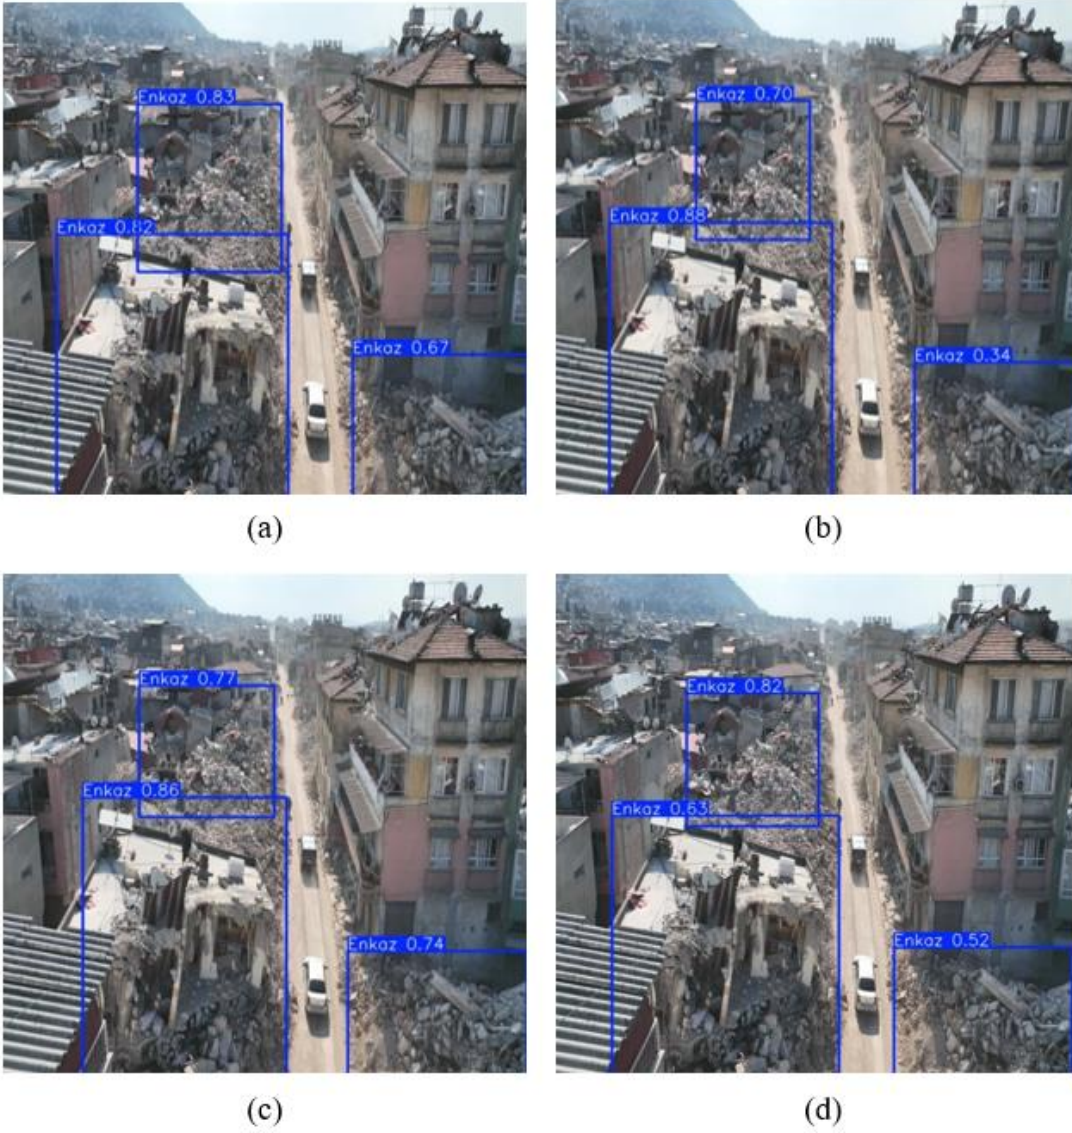
**Şekil 5.11** : Beşinci test görüntüsüne ait sonuçlar; (a) Nano, (b) Small, (c) Medium, (d) Large.

Şekil 5.11’de yer alan Nano model, üç enkaz bölgesini de başarılı şekilde tespit etmiş ve 0.88, 0.84 ve 0.83 gibi oldukça yüksek güven skorları üretmiştir. Small modeli de benzer şekilde üç enkazı tespit edebilmiş ancak üçüncü kutuda (0.74) güven skoru nispeten daha düşüktür. Medium model, diğer iki modelle benzer olarak üç enkazı da tespit etmiştir. Ancak tüm kutuların varlığı ve skorların üst düzeyde olması modelin istikrarlı çalıştığını göstermektedir. Large modelin performansı ise daha dengesizdir. Üç enkaz alanını tespit etmiş olsa da üçüncü kutudaki skor (0.50) oldukça düşüktür, diğer iki kutuda ise 0.57 ve 0.81 doğruluk değerleri üretmiştir.



**Şekil 5.12 : Altıncı test görüntüsüne ait sonuçlar; (a) Nano, (b) Small, (c) Medium, (d) Large.**

Şekil 5.12’de yer alan Nano modeli, her iki bölgeyi de tespit etmiş, ancak sol bölge için düşük bir güven skoru (0.50) üretmiştir. Buna karşılık, açık alandaki ikinci enkazı %78 doğrulukla tespit etmiştir. Small model, sol tarafta 0.88, sağ tarafta 0.55 güven skoru üretmiştir. Medium model, sol bölgedeki nesneyi 0.81 ile oldukça başarılı şekilde tespit ederken, sağdaki açık alanda güven skoru 0.46’ya düşmüştür. Large modeli ise sol bölgede 0.53, sağ taraftaki açık alanda ise 0.69 skor elde etmiştir.




**Şekil 5.13 :** Yedinci test görüntüsüne ait sonuçlar; (a) Nano, (b) Small, (c) Medium, (d) Large.

Şekil 5.13’ de yer alan Nano model, sahnedeki üç enkaz alanını da başarılı şekilde tespit etmiş ve 0.83, 0.82 ve 0.67 gibi yüksek skorlar üretmiştir. Small model, en yüksek skoru 0.88 ile ortadaki büyük enkaz alanında göstermiştir; ancak sağ arka plandaki enkazı 0.34 gibi oldukça düşük bir güvenle algılamıştır. Medium model, sahnedeki tüm enkazları başarıyla ve istikrarlı skorlarla tespit etmiştir (0.86, 0.77 ve 0.74). Large modeli de üç hedefi doğru şekilde tespit etmiştir (0.82 – 0.63 – 0.52).



(a)

(b)



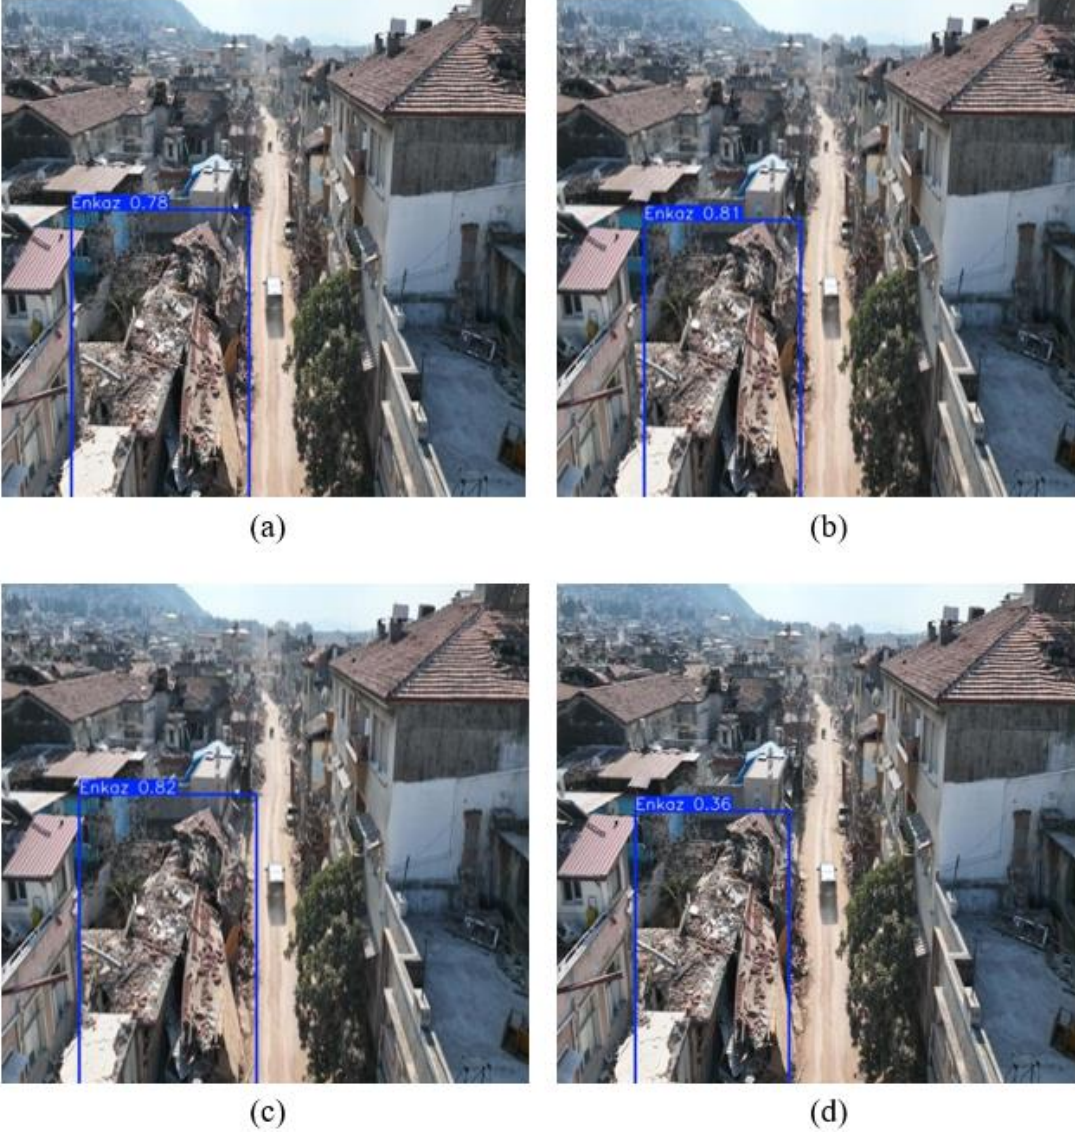
(c)



(d)

**Şekil 5.14** : Sekizinci test görüntüsüne ait sonuçlar; (a) Nano, (b) Small, (c) Medium, (d) Large.

Şekil 5.14'te yer alan Nano modeli üç enkaz alanını da yüksek güven skorlarıyla (0.87, 0.82, 0.72) tespit etmiştir. Small modelde de benzer biçimde üç bölge tespit edilmiştir ve skorlar 0.81, 0.90 ve 0.76 seviyesindedir. Medium model, Nano ve Small'a benzer doğrulukta (0.80, 0.89, 0.57) sonuçlar üretmiştir. Large model, tespit kutuları Small modele göre daha az odaklı görünmekte, bazı enkaz alanları daha geniş veya çevresel yapı ile karışık olarak sınırlanmıştır.




**Şekil 5.15 :** Dokuzuncu test görüntüsüne ait sonuçlar; (a) Nano, (b) Small, (c) Medium, (d) Large.

Şekil 5.15'te yer alan Nano modeli 0.78 güven skoru ile oldukça belirgin bir tespit gerçekleştirmiştir. Small modeli ise daha yüksek bir başarıyla, 0.81 skorla tespit etmiştir. Medium model 0.82 güven skoru ile en yüksek değeri üretmiştir. Buna karşın Large modelin tespit başarımı 0.36 gibi oldukça düşük bir seviyede kalmıştır.

### 5.3.2. Simülasyon ortamda enkaz tespiti

İki farklı simülasyon test görseli kullanılarak yapılan değerlendirmede, her bir görsel için YOLOv8 ailesine ait dört farklı model varyantının (Nano, Small, Medium ve Large) performansı karşılaştırılmıştır.



**Şekil 5.16 :** Birinci simülasyon görüntüsüne ait sonuçlar; (a) Nano, (b) Small, (c) Medium, (d) Large.

Şekil 5.16’da simülasyon ortamında oluşturulmuş sabit bir enkaz görüntüsünün dört farklı YOLOv8 modeline (Nano, Small, Medium, Large) tespit ettirilmesine ilişkin sonuçlar gösterilmiştir.

Nano model, görüntüyü 0.65 güven skoru ile tespit etmiş ve nesneyi doğru şekilde sınırlamıştır. Small model 0.89 güven skoru ile en yüksek doğruluk oranına ulaşmıştır.

Medium modelin güven skoru 0.71 olup Nano modelden daha yüksek, ancak Small modelden daha düşüktür. Large modeli ise 0.65 skorla Nano modeliyle aynı düzeyde bir güven sağlamıştır.



(a)



(b)



(c)



(d)

**Şekil 5.17** : İkinci simülasyon görüntüsüne ait sonuçlar; (a) Nano, (b) Small, (c) Medium, (d) Large.

Şekil 5.17’de yer alan görsellerde nano, small, medium ve large versiyonlarının, düz zemin üzerine yerleştirilmiş bir enkaz görselini tanıma kapasiteleri değerlendirilmektedir.

Nano modeli, enkazı 0.62 güven skoruyla başarılı şekilde tespit edebilmiştir. Small modeli ise benzer bir doğrulukla 0.59 güven skoru üretmiştir. Medium ve Large modelleri ise 0.44 ve 0.46 gibi düşük güven skoruyla diğer modellerin gerisinde kalmıştır.

#### 5.4. Sonuçların Genel Değerlendirmesi

Farklı YOLOv8 modellerinin gerçek zamanlı performansları, tek bir test görüntüsü üzerinde yapılan ölçümlerle karşılaştırılmıştır. Her model için ön işleme (preprocess), çıkarım (inference) ve işlem sonrası (postprocess) süreleri ayrı ayrı analiz edilmiştir. YOLOv8n modeli 354.9 ms toplam sürede çalışarak yaklaşık 2.8 FPS ile en düşük hızı göstermiştir. Buna karşın YOLOv8l modeli, 209.1 ms’lik toplam süreyle yaklaşık 4.8 FPS’ye ulaşarak, daha büyük bir model olmasına rağmen optimize edilmiş işlem sonrası süresi sayesinde yüksek performans sergilemiştir. Bu sonuçlar, yalnızca doğruluk metrikleriyle değil, aynı zamanda gerçek zamanlı kullanım açısından da modellerin etkinliğini değerlendirme gerekliliğini ortaya koymaktadır. Çizelge 5.7’de gerçek zamanlı performans değerleri verilmiştir.

**Çizelge 5.7 :** Gerçek zamanlı performans karşılaştırması.

Model	Ön İşleme (ms)	Çıkarım (ms)	İşlem Sonrası (ms)	Toplam Süre (ms)	Yaklaşık FPS
V8 Nano	8.4	9.2	337.3	354.9	2.8
V8 Small	3.0	16.5	207.2	226.7	4.4
V8 Medium	6.2	37.0	172.8	216.0	4.6
V8 Large	3.0	62.6	143.5	209.1	4.8

Bu çalışmada, farklı boyutlardaki YOLOv8 modelleri (Nano, Small, Medium ve Large) kullanılarak afet bölgelerinden alınan görüntülerde enkaz tespiti yapılmış,

modellerin başarıları hem sayısal metrikler hem de görsel çıktı analizi üzerinden değerlendirilmiştir.

Elde edilen F1 skoru, precision, recall ve mAP@0.5 değerleri dikkate alındığında, modeller genel olarak tatmin edici performans sergilemiştir. Özellikle YOLOv8 Small modeli, en yüksek F1 skoru (0.76) ve oldukça yüksek bir precision (0.987) değeri ile dikkat çekmiştir. Buna karşın, Medium modeli daha yüksek bir mAP@0.5 (0.759) skoruyla genel doğruluk açısından öne çıkmıştır. Nano modeli, düşük parametre sayısına rağmen 0.74 F1 skoru ve 0.729 mAP ile hafif yapıli sistemler için verimli bir seçenek olduğunu göstermiştir. Large model ise bazı durumlarda overfitting belirtileri göstermiş ve düşük F1 (0.73) ve recall (0.89) değerleri ile diğer modellere kıyasla daha sınırlı başarı sağlamıştır.

Confusion matrix analizleri de bu tabloyu destekler niteliktedir. Small ve Medium modellerinin doğru pozitif tespit sayıları yanlış sınıflandırma sayılarından daha düşük kalmıştır. Görsel örneklerde ise Small ve Medium modellerin hem farklı perspektiflerde hem de farklı ışık ve çevre koşullarında daha tutarlı ve güven seviyesi yüksek tespitler gerçekleştirdiği görülmüştür. Özellikle büyük ve karmaşık enkaz alanlarında Small modelin nesne sınırlayıcı kutuları daha doğru konumlandığı dikkat çekmiştir.

Simülasyon ortamlarında yapılan testlerde ise, Small modeli yüksek genelleme yetenekleri ile alışılmadık sahnelerde bile enkaz tespitini başarıyla gerçekleştirebildiği, buna karşın Large modelin bu tür ortamlarda düşük güven skorlarıyla daha başarısız sonuçlar verdiği gözlenmiştir. Bu durum, modelin veri seti çeşitliliğine olan duyarlılığını ve eğitim örnekleri dışındaki ortamlarda yaşadığı performans düşüşünü ortaya koymaktadır.

Sonuç olarak, bu çalışma göstermiştir ki model boyutu arttıkça her zaman daha yüksek başarı elde edilmemektedir. Hafif yapıli modeller olan Nano ve Small, hem hız hem de doğruluk açısından başarılı performans sergileyerek gerçek zamanlı enkaz tespiti gibi görevlerde etkin kullanılabileceklerini ortaya koymuştur. Medium modeli, genel denge ve kararlılık açısından en başarılı model olarak öne çıkmıştır.

## 6. SONUÇLAR VE TARTIŞMA

Bu çalışmada, afet bölgelerinde drone ile elde edilen görüntüler üzerinde enkaz tespiti yapmak amacıyla YOLOv8 algoritmasının dört farklı modeli (Nano, Small, Medium, Large) karşılaştırmalı olarak değerlendirilmiştir. Kullanılan veri seti, Kahramanmaraş ve Hatay illerinden elde edilen gerçek afet görüntülerinden oluşturulmuştur. Görseller tek sınıflı (enkaz) olarak etiketlenmiş ve eğitim-veri çoğaltma aşamasında rotation (döndürme) ve flip (yansıtma) tekniği kullanılmıştır. Toplamda 2099 görüntüden oluşan veri seti %89 eğitim ve %11 doğrulama şeklinde bölünmüştür.

Farklı modellerin eğitim performansları box\_loss, cls\_loss, dfl\_loss ve metriksel göstergelerle analiz edilmiş, doğrulama süreçlerinde elde edilen mAP@0.5, F1 score, Precision ve Recall değerleriyle birlikte karışıklık matrisleri karşılaştırılmıştır. Ayrıca, her modelin çeşitli gerçek afet görüntüleri üzerindeki sınırlayıcı kutu tahminleri görsel olarak da değerlendirilmiştir. YOLOv8 Medium modeli, mAP@0.5 skoruyla %75.9 değerine ulaşarak tüm modeller arasında en yüksek doğruluk oranını göstermiştir. Recall (0.93) değeri ile gerçek enkazların kaçırılmadan doğru şekilde tespit edilmesinde en başarılı model olmuştur. Görsel tespit örneklerinde de Medium modelin sınırlayıcı kutularının hem daha doğru konumlandığı hem de güven skorlarının yüksek olduğu gözlenmiştir. YOLOv8 Small modeli ise özellikle güven skoru açısından tutarlılık göstererek, düşük kaynaklı sistemler için dengeli ve hızlı bir alternatif sunmuştur. YOLOv8 Large modeli bazı görüntülerde yüksek skorlar üretmiş olsa da, kimi durumlarda aşırı öğrenme ve düşük doğruluk (ör. 0.34, 0.36 gibi) gibi dalgalanmalar sergilemiştir. YOLOv8 Nano modeli hafifliği sayesinde düşük donanım ihtiyacı sunarken, performans açısından sınırlı kalmıştır.

Genel olarak, bu çalışma göstermektedir ki; afet sonrası enkaz tespiti gibi hassas görevlerde YOLOv8 Medium modeli, doğruluk, güvenilirlik ve genel denge açısından en başarılı performansı göstermektedir. Bu model, gelecekte gerçek zamanlı arama-kurtarma sistemlerinde, afet yönetimi karar destek araçlarında ya da drone tabanlı enkaz tarama sistemlerinde etkili biçimde kullanılabilir.



## KAYNAKLAR

- Abdi, G., & Jabari, S. (2021). A multi-feature fusion using deep transfer learning for earthquake building damage detection. *Canadian Journal of Remote Sensing*, 47(2), 337–352.
- Abdullah, A. A., Hassan, M. M. and Mustafa, Y. T. (2022). A review on bayesian deep learning in healthcare: Applications and challenges. *IEEE Access*, 10, 36538-36562.
- Aboah, A., Wang, B., Bagci, U. & Adu-Gyamfi, Y. (2023). Real-time multi-class helmet violation detection using few-shot data sampling technique and yolov8. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, (pp. 5349-5357).
- Ahmed, A., Wang, H., Almadwami, H., AL-Soswa, M., & Abo Kaf, A. (2024). Using a Hybrid-Domain Attention Mechanism with YOLOv8 for Victim Detection in Disasters. *7th International Conference on Computer Information Science and Application Technology (CISAT)*, IEEE, 878–886.
- Aksaç, K. (2022). Prediction of the future success of candidates before recruitment with machine learning: a case study in the banking sector, (Yüksek Lisans tezi), Galatasaray Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Alawad, M. & Lin, M. (2016). Stochastic-based deep convolutional networks with reconfigurable logic fabric, *IEEE Transactions on Multi-Scale Computing Systems*, 2(4), 242–256.
- Arai, K., Nakaoka, Y., & Okumura, H. (2024). Method for Disaster Area Detection with Just One SAR Data Acquired on the Day After Earthquake Based on YOLOv8. *International Journal of Advanced Computer Science and Applications (IJACSA)*, 15(3), 433–439.
- Benuwa, B. B., Zhan, Y. Z., Ghansah, B., Wornyo, D. K. and Banaseka Kataka, F. (2016). A review of deep machine learning. *International Journal of Engineering Research in Africa*, 24, 124-136.
- Can, Ö. Y. (2020). Makine Öğrenmesi Teknikleri Kullanılarak Kredi Risk Analizi [Master's thesis, Istanbul Aydın University Graduate School of Education, Istanbul].
- Chen, L., Wang, F., & Zhang, Y. (2017). Deep Learning for Human Intelligence. *IEEE Intelligent Systems*, 32(4), 74-79.
- Chollet, F. (2021). *Python ile Derin Öğrenme*, İkinci Baskı, Buzdağı Yayınevi, Ankara.
- Cüce, H. (2023). Climate change-related natural disasters: Environmental effects and sustainable monitoring. *International Journal of Environmental Trends (IJENT)*, 7(2), 113–125. <https://dergipark.org.tr/pub/ijent>
- Doğan, O. (2016). *Yapay Sinir Ağları*.
- Dunlu, (2023). YOLOv8 Mimarisi. Medium. <https://medium.com/@dunlu4822/yolov8-mimarisi-ef203cd0f388> (Erişim Tarihi: 03.08.2025).

- Ekici, E. (2022). Deep learning based fruit and vegetable recognition for android pos devices, (Yüksek Lisans tezi), İstanbul Teknik Üniversitesi, Lisansüstü Eğitim Enstitüsü, İstanbul.
- Erdoğan, Y. (2022). Kumaş hatalarının derin öğrenme ile tespiti, (Yüksek Lisans tezi), Süleyman Demirel Üniversitesi, Fen Bilimleri Enstitüsü, Isparta.
- Ergin, T. (2018). Convolutional Neural Network (ConvNet yada CNN) nedir, nasıl çalışır. Medium. Erişim: 17 Ekim 2024, <https://medium.com/@tuncerergin/convolutional-neural-network-convnetyada-cnn-nedir-nasil-calisir-97a0f5d34cad>.
- Fernandez Galarreta, J., Kerle, N., & Gerke, M. (2015). Uav-based urban structural damage assessment using object-based image analysis and semantic reasoning. *Natural Hazards and Earth System Sciences*, 15(6), 1087–1101.
- Fujita, A., Sakurada, K., Imaizumi, T., Ito, R., Hikosaka, S., & Nakamura, R. (2017). Damage detection from aerial images via convolutional neural networks. *IEEE IAPR international conference on machine vision applications (MVA)*, 5–8
- Garcia, R. (2020). Exploring the Future of Artificial Intelligence: Challenges and Opportunities. *Future Computing Research Journal*, 5(2), 17-28.
- Haykır, A.A. (2023). Transfer learning based super resolution of aerial images and the effects of the super resolution on object detection, (Yüksek Lisans tezi), İstanbul Teknik Üniversitesi, Lisansüstü Eğitim Enstitüsü, İstanbul.
- Hong, Z., Zhong, H., Pan, H., Liu, J., Zhou, R., Zhang, Y., Han, Y., Wang, J., Yang, S., & Zhong, C. (2022). Classification of building damage using a novel convolutional neural network based on post-disaster aerial images. *Sensors*, 22(15), 5920.
- Ilmak, D., Iban, M. C., & Şeker, D. Z. (2024). A geospatial dataframe of collapsed buildings in Antakya city after the 2023 Kahramanmaraş earthquakes using object detection based on YOLO and VHR satellite images. *IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, 2024, 1–6.
- Jeyaraj, P. R. & Samuel Nadar, E. R. (2019). Computer vision for automatic detection and classification of fabric defect employing deep learning algorithm, *International Journal of Clothing Science and Technology*, 31(4), 510–521.
- Jing, Y., Ren, Y., Liu, Y., Wang, D., & Yu, L. (2022). Automatic Extraction of Damaged Houses by Earthquake Based on Improved YOLOv5: A Case Study in Yangbi. *Remote Sensing*, 14(2), 382.
- Joshi, A. R., Tarte, I., Suresh, S., & Koolagudi, S. G. (2017). Damage identification and assessment using image processing on post-disaster satellite imagery. *IEEE Global Humanitarian Technology Conference (GHTC)*
- Kalantar, B., Ueda, N., Al-Najjar, H. A., & Halin, A. A. (2020). Assessment of convolutional neural network architectures for earthquake-induced building damage detection based on pre-and post-event orthophoto images. *Remote Sensing*, 12(21), 3529.
- Khodaverdi Zahraee, N., & Rastiveis, H. (2017). Object-oriented analysis of satellite images using artificial neural networks for post-earthquake buildings change detection. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 42, 139–144.

- Kim, S. (2019). Ethical Considerations in the Development of Artificial Intelligence. *Journal of Ethics in Technology*, 1(1), 45-56.
- Kim, S.S., Yoo, S.H., Park, J.S., Cho, S.B., Kim, T.H. (2018) Rapid Disaster Mapping through Data Integration from UAVs and Multi-sensors Mounted on Investigation Platforms of NDMI, Korea The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, Volume XLII-3/W4, 2018 Geo-Information For Disaster Management (Gi4DM), 18–21 March 2018, Istanbul, Turkey.
- Kıratlı, R., & Eroğlu, A. (2024). Monitoring Post-Earthquake Search and Rescue Operations through UAVs Vision: Teams, Equipment and Structural Damage Detection. 8th International Artificial Intelligence and Data Processing Symposium (IDAP'24), 21–22 Eylül 2024, Malatya, Türkiye. IEEE.
- Kugunavar, S. and Prabhakar, C. J. (2021). Convolutional neural networks for the diagnosis and prognosis of the coronavirus disease pandemic. *Visual computing for industry, biomedicine, and art*, 4(1), 12.
- LeCun, Y., Bengio, Y. & Hinton, G. (2015). Deep learning, *Nature*, 521(7553), 436-444.
- Lee, H. (2018). Machine Learning and Its Application in Artificial Intelligence. *ACM Computing Surveys*, 50(4), 1-34.
- Li, F. F., Johnson, J. & Yeung, S. (2017). Lecture 11: Detection and segmentation. URL:[http://cs231n.stanford.edu/slides/2017/cs231n\\_2017\\_lecture11.pdf](http://cs231n.stanford.edu/slides/2017/cs231n_2017_lecture11.pdf). Available: 06.11.2023.
- Liu, W., Anguelov, D., Erhan, D., Szegedy, C., Reed, S., Fu, C.-Y., & Berg, A. C. (2016). SSD: Single shot multibox detector. In *European Conference on Computer Vision* (pp. 21–37). Springer.
- Ma, H., Liu, Y., Ren, Y., & Yu, J. (2020). Detection of collapsed buildings in post-earthquake remote sensing images based on the improved YOLOv3. *Remote Sensing*, 12(1), 44.
- Mazanoğlu, K., & Kandemir-Mazanoğlu, E. Ç. (2017). Çatlaklı kirişlerin yapay sinir ağları ile modellenmesi. *Afyon Kocatepe Üniversitesi Fen ve Mühendislik Bilimleri Dergisi*, 17, 1129–1135.
- McCarthy, J. (1956). Artificial Intelligence: A Proposal for the Dartmouth Conference. *AI Magazine*, 27(4), 55-60.
- Minaee, S., Boykov, Y., Porikli, F., Plaza, A., Kehtarnavaz, N. & Terzopoulos, D. (2021). Image segmentation using deep learning: A survey, *IEEE transactions on pattern analysis and machine intelligence*, 44(7), 3523-3542.
- Öztemel, E. (2006). *Yapay Sinir Ağları* (2. baskı). Papatya Yayıncılık.
- Öztemel, E. (2012). *Yapay Sinir Ağları* (3. baskı). Papatya Yayıncılık.
- Öztürk, K., & Şahin, M. E. (2018). Yapay sinir ağları ve yapay zekâya genel bir bakış. *Takvim-i Vekayi*, 6(2), 25–36.
- Parlak, İ. E. (2022). Alüminyum Döküm Hatalarının Derin Öğrenme Yaklaşımıyla Tespiti ve Sınıflandırılması, (Doktora tezi), Uludağ Üniversitesi, Fen Bilimleri Enstitüsü, Bursa.

- Rao, A., Jung, J., Silva, V., Molinario, G., & Yun, S. H. (2023). Earthquake building damage detection based on synthetic-aperture-radar imagery and machine learning. *Natural Hazards and Earth System Sciences*, 23(2), 789–807.
- Raschka, S. (2015). *Python machine learning*. Packt Publishing Ltd.
- Rieder, M. & Verbeet, R. (2019). Robot-human-learning for robotic picking processes. In *Artificial Intelligence and Digital Transformation in Supply Chain Management: Innovative Approaches for Supply Chains*. Proceedings of the Hamburg International Conference of Logistics (HICL), (pp. 87-114). Berlin: epubli GmbH.
- Sarvamangala, D. R. and Kulkarni, R. V. (2022). Convolutional neural networks in medical image understanding: a survey. *Evolutionary intelligence*, 15(1), 1-22.
- Shi, L., Zhang, F., Xia, J., Xie, J., Zhang, Z., Du, Z., & Liu, R. (2021). Identifying damaged buildings in aerial images using the object detection method. *Remote Sensing*, 13(21), 4213.
- Sorgun, Ö. (2022). X-ray görüntülerinde faster R-CNN kullanılarak yasaklı nesne tespiti, (Yüksek Lisans tezi), Sakarya Uygulamalı Bilimler Üniversitesi, Lisansüstü Eğitim Enstitüsü, Sakarya.
- Talaat, F. M. & ZainEldin, H. (2023). An improved fire detection approach based on YOLO-v8 for smart cities, *Neural Computing and Applications*, 35(28), 20939-20954.
- Tamang, S., Sen, B., Pradhan, A., Sharma, K. & Singh, V. K. (2023). Enhancing COVID-19 Safety: Exploring YOLOv8 Object Detection for Accurate 60 Face Mask Classification, *International Journal of Intelligent Systems and Applications in Engineering*, 11(2), 892-897.
- Taye, M. M. (2023). Theoretical understanding of convolutional neural network: concepts, architectures, applications, future directions. *Computation*, 11(3), 52.
- Ultralytics. (2023). Ultralytics YOLOv8 Documentation. <https://docs.ultralytics.com/> (Erişim tarihi: 08.09.2023)
- Ünlü, R., & Kiriş, R. (2022). Detection of damaged buildings after an earthquake with convolutional neural networks in conjunction with image segmentation. *The Visual Computer*, 38(2), 685–694.
- Wang, Q., & Zhang, X. (2021). Ethical Frameworks for Artificial Intelligence Development. *Journal of Ethics in Technology*, 3(2), 89-102.
- Xiong, C., Li, Q., & Lu, X. (2020). Automated regional seismic damage assessment of buildings using an unmanned aerial vehicle and a convolutional neural network. *Automation in Construction*, 109, 102994.
- Yahya Eke. (2023). Büyük Felaket / Kahramanmaraş Depremi Drone Görüntüleri // Great earthquake disaster in Türkiye [Video]. YouTube. [https://www.youtube.com/watch?v=Nf326iK2r\\_o](https://www.youtube.com/watch?v=Nf326iK2r_o)
- Yamashita, R., Nishio, M., Do, R. K. G. and Togashi, K. (2018). Convolutional neural networks: an overview and application in radiology. *Insights into imaging*, 9, 611-629.

- Zhang, J., & Gong, L. (2013). Sar images before and after earthquake change detection based on object oriented method and damage evaluation. IEEE International Geoscience and Remote Sensing Symposium-IGARSS
- 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, Z., Chen, K., Shi, Z., Guo, Y. & Ye, J. (2023). Object detection in 20 years: A survey, Proceedings of the IEEE, 111(3), 257-276.





## ÖZGEÇMİŞ

### Kimlik Bilgileri:

İsim: Ömer Faruk

Soy İsim: Picak

### Öğrenim Durumu:

**Lisans** : Karamanoğlu Mehmetbey Üniversitesi, Elektrik-Elektronik Müh., Karaman,  
2018 – 2022

**Yüksek Lisans** : Karamanoğlu Mehmetbey Üniversitesi, Elektrik-Elektronik Müh.,  
Karaman, 2022 – Devam Ediyor

### Yüksek Lisans Tezinden Üretilen Yayınlar:

- Picak, F. Ö., Sabancı, K. (2025). Yapay Zeka Kullanılarak Deprem Bölgelerinden Drone İle Alınan Görüntülerden Enkaz Tespitinin Gerçekleştirilmesi. Karamanoğlu Mehmetbey Üniversitesi Mühendislik ve Doğa Bilimleri Dergisi 7 (1), 11-18.
- Picak, F. Ö., Sabancı, K. (2025). YOLOv8 Algoritması ile Afet Görüntülerinden Enkaz Tespiti. 5. Uluslararası Çağdaş Akademik Araştırmalar Konferansı ICCAR, 30-31 Mayıs 2025, Konya.

### Deneyim Alanları:

Aselsan / Stajyer, Ankara, 2022

Oflaz Mekanik / Elektrik- Elektronik Mühendisi, Karaman, 2022 - 2023

Türk Hava Yolları / Uzman Yardımcısı, İstanbul, 2023 – Devam Ediyor