

Yapay Zeka Kullanılarak Deprem Bölgelerinden Drone ile Alınan Görüntülerden Enkaz Tespitinin Gerçekleştirilmesi

Ömer Faruk PİCAK^{*id}, Kadir SABANCI^{id}

Karamanoğlu Mehmetbey Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü, Karaman, Türkiye

Alındı/Received: 09/05/2025; Kabul/Accepted: 30/06/2025; Yayın/Published: 30/06/2025

* Sorumlu yazar e-posta: 220801112@stu.kmu.edu.tr

Öz

Bu çalışmada YOLOv8 derin öğrenme algoritması kullanılarak enkaz tespitine yönelik bir sistem önerilmektedir. 2023 yılında meydana gelen Hatay-Maraş depremi sonrasında drone ile elde edilen görüntüler ile birlikte genel enkaz görüntülerinin de eklenmesiyle oluşturulan bir veri seti kullanılmıştır. Deprem sonrası arama-kurtarma operasyonlarının etkinliğini artırmayı hedefleyen bu sistem, yüksek çözünürlüklü drone görüntülerinden elde edilen verilerle eğitilmiş ve gerçek zamanlı tespit kabiliyeti sunmaktadır. Çalışma kapsamında oluşturulan veri setleri Roboflow platformu ile etiketlenmiş, çeşitli veri artırma teknikleri uygulanmış ve model eğitim süreci optimize edilmiştir. Modelin etkinliği, hem doğrulama veri kümesindeki performans metrikleriyle hem de saha koşullarına benzer şekilde oluşturulan fiziksel bir test ortamında gözlemlenmiştir. 2×3 metre boyutlarında basılmış enkaz görüntüsünün zemin üzerine yerleştirilerek drone ile taranması sonucunda modelin başarıyla tespit yaptığı görülmüştür. Ayrıca, YOLOv8 modeli Raspberry Pi 4B cihazına bağlı kamera modülü ile görüntü alındıktan sonra bu görüntüler işlenmiş ve düşük donanım kapasitesine rağmen model, enkaz tespitini başarıyla gerçekleştirmiştir. Bu durum, geliştirilen sistemin taşınabilir ve enerji verimli yapısıyla afet sahalarında pratik olarak kullanılabileceğini göstermektedir. Elde edilen bulgular, YOLOv8 tabanlı sistemin hem doğruluk hem de uygulama açısından enkaz tespiti görevinde başarılı sonuçlar verdiğini ve afet yönetimi süreçlerine entegre edilebilecek potansiyele sahip olduğunu ortaya koymaktadır.

Anahtar Kelimeler: Enkaz, YOLO, Görüntü İşleme

Debris Detection from Drone Imagery in Earthquake Zones Using Artificial Intelligence

Abstract

In this study, a debris detection system is proposed using the YOLOv8 deep learning algorithm. The system is trained on a custom dataset composed of drone footage captured following the 2023 Hatay-Maraş earthquake, supplemented with general debris images. Aimed at enhancing the efficiency of post-earthquake search and rescue operations, the system leverages high-resolution drone imagery to provide real-time detection capabilities. The dataset was annotated using the Roboflow platform, enriched through various data augmentation techniques, and the model training process was optimized accordingly. The effectiveness of the model was evaluated both through performance metrics on the validation dataset and in a physical test environment simulating real-world conditions. A high-resolution image of a debris scene, printed at 2×3 meters, was placed on the ground and scanned by a drone. The YOLOv8 model successfully identified the debris regions in real-time. In addition, the model was tested by capturing images using a camera module connected to a Raspberry Pi 4B device. The captured images were processed separately, and the model successfully performed debris detection despite the limited computational capacity. These results demonstrate that the proposed system, with its portable and energy-efficient structure, can be practically deployed in disaster zones. Overall, the findings indicate that the YOLOv8-based model delivers high performance in terms of both detection accuracy and operational feasibility, revealing strong potential for integration into disaster management systems.

Key Words: Debris, YOLO, Image Processing

Atf / To cite: Picak ÖF, Sabancı K (2025). Yapay Zeka Kullanılarak Deprem Bölgelerinden Drone ile Alınan Görüntülerden Enkaz Tespitinin Gerçekleştirilmesi. Karamanoğlu Mehmetbey Üniversitesi Mühendislik ve Doğa Bilimleri Dergisi, 7(1): 11-18.

1. GİRİŞ

Depremler, ani gerçekleşen ve geniş ölçekli yıkıma yol açabilen doğal afetler arasında yer almakta olup, hem can kaybı hem de fiziksel hasar bakımından toplumları derinden etkileyen felaketlerdir. Deprem sonrası dönemde arama ve kurtarma faaliyetlerinin başarısı, büyük ölçüde hasarın hızlı ve doğru bir şekilde değerlendirilmesine bağlıdır. Enkaz altında kalan kişilerin hayatta kalma şansının zamanla doğrudan ilişkili olması nedeniyle, bu tür afetlerde erken müdahale kritik önem taşımaktadır (Ünlü ve Kiriş 2022). Geleneksel hasar tespit yöntemleri çoğunlukla saha araştırmaları ve gözleme dayalı manuel uygulamalarla yürütülmektedir. Ancak bu yöntemler; zaman alıcı, emek yoğun ve çoğu zaman arama-kurtarma ekipleri açısından riskli olabilmektedir (Hasanlou ve ark. 2021).

Bu bağlamda, özellikle son yıllarda gelişen insansız hava aracı (İHA – drone) teknolojileri, afet yönetimi süreçlerinde devrim niteliğinde yenilikler sunmaktadır. Dronelar; yüksek çözünürlüklü kameralara sahip olmaları, zorlu alanlara erişim sağlamaları ve geniş bölgelere ilişkin görüntüleri kısa sürede toplayabilmeleri sayesinde, afet bölgelerinde hızlı veri temini için son derece uygun araçlardır (Abdi ve Jabari 2021). Elde edilen bu görüntüler, yapay zeka (YZ) ve özellikle derin öğrenme algoritmaları kullanılarak işlenebilir ve böylece enkaz bölgeleri otomatik olarak analiz edilerek, kurtarma ekiplerine anlık bilgi desteği sağlanabilir. Bu durum, yalnızca kurtarma hızını artırmakla kalmayıp, ekiplerin güvenliğini de artırmakta ve kaynak kullanımını daha etkin hale getirmektedir.

Literatürde, afet sonrası hasar tespiti amacıyla hem uydu hem de hava görüntüleri üzerinde uzaktan algılama tekniklerinin kullanıldığı çok sayıda çalışma mevcuttur (Rao ve ark. 2023; Zhang ve Gong 2013). Bu çalışmalar, genellikle deprem öncesi ve sonrası çekilen görüntüler arasında değişim tespiti (change detection) yöntemlerine dayanmakta ve yapısal farklılıkları bu karşılaştırmalar üzerinden analiz etmektedir (Khodaverdi ve Rastiveis 2017; Joshi ve ark. 2017). Ancak bu yöntemler, genellikle afet öncesi görüntülerin temin edilmesini zorunlu kılmakta ve bulut örtüsü, düşük çözünürlük gibi nedenlerle istenen doğruluğa ulaşmakta sınırlılıklar barındırmaktadır (Hasanlou ve ark. 2021).

Bu sınırlamaları aşmak adına, son dönem çalışmalarında İHA'lar ile toplanan yüksek çözünürlüklü görüntüler üzerinde derin öğrenme algoritmalarının uygulanmasına yönelik yöntemler geliştirilmiştir. Örneğin, Xiong ve ark. (2020), CNN tabanlı bir model ile dronelerden elde edilen bina görüntülerinin işlenmesi yoluyla sismik hasar tespiti gerçekleştirmiş ve %89'un üzerinde doğruluk elde etmiştir. Benzer şekilde, Fernandez Galarreta ve ark. (2015), 3B nokta bulutu verilerini nesne tabanlı görüntü analizi (OBIA) ile birleştirerek cephe ve çatı düzeyinde hasar tespiti yapabilecek bir yapı ortaya koymuştur. Kıratlı ve Eroğlu (2024) ise, İHA görüntüleri üzerinden yalnızca yapı değil aynı zamanda arama-kurtarma ekipleri, iş makineleri ve ekipmanları gibi çoklu nesne tespitini içeren ilk kapsamlı uygulamalardan birini sunmuş; YOLOv8 modelinin %88 mAP ve 0.87 F1 skoru ile yüksek doğruluk

sağladığını göstermiştir. Bu çalışmalar, drone görüntülerinin sahip olduğu yüksek mekânsal çözünürlüğün ve farklı açılardan veri yakalama kapasitesinin, hasar tespit süreçlerinde detay seviyesini ciddi biçimde artırabileceğini ortaya koymuştur.

Ancak mevcut çalışmaların büyük bölümü, uydu ya da genel hava görüntüleri üzerinde oluşturulan açık kaynaklı veri setlerine dayandığı için, drone görüntülerine özgü modelleme ihtiyaçlarını tam olarak karşılamamaktadır. Örneğin, Fujita ve ark. (2017) tarafından kullanılan veri kümeleri, çoğu zaman drone kameralarının yakaladığı detay seviyesini içermemektedir. Ayrıca drone görüntülerine özgü ışık koşulları, farklı açılar, görüntü çözünürlüğü ve çerçeveleme gibi faktörler, modellerin genel geçer kullanımını kısıtlamakta ve özel optimize edilmiş sistemlere ihtiyaç duyulmaktadır (Hong ve ark. 2022; Kalantar ve ark. 2020).

Bu çalışmanın temel amacı, mevcut literatüre katkı sağlamak ve deprem sonrası drone görüntülerinden elde edilen verilerin YOLOv8 Large (YOLOv8L) modeli kullanılarak analiz edilmesiyle enkaz tespitini gerçekleştirmektir. Böylece arama-kurtarma operasyonlarına doğrudan destek verebilecek, hızlı ve uygulanabilir bir sistem geliştirilmesi hedeflenmiştir. YOLOv8 (You Only Look Once, versiyon 8), önceki nesil modellerine kıyasla daha yüksek doğruluk oranı, optimize edilmiş mimarisi ve hızlı işlem kabiliyeti ile gerçek zamanlı uygulamalarda öne çıkan bir nesne tespit algoritmasıdır. Literatürde özellikle Xiong ve ark. (2020), Kıratlı ve Eroğlu (2024) gibi çalışmalar CNN ve YOLO tabanlı modellerle bina hasarı ve çoklu nesne tespitine odaklanmış; ancak YOLOv8 Large modeliyle doğrudan tek sınıflı (enkaz) tespiti üzerine gerçekleştirilen ve saha koşullarına benzer görsel testler ile desteklenen bir çalışmaya sınırlı sayıda rastlanmaktadır. Bu yönüyle çalışma, kullanılan veri tipi, tek sınıf odaklanması ve fiziksel test ortamıyla YOLOv8 Large modelinin enkaz tespiti için sistematik olarak değerlendirilmesi bakımından özgün bir katkı sunmaktadır.

Bu bağlamda çalışma, enkaz bölgelerinin hızlı bir şekilde tespiti, arama-kurtarma ekiplerine yön verebilecek güvenilir görsel çıktılar üretilmesi ve YOLOv8 Large modelinin afet sonrası uygulamalara entegrasyon potansiyelinin test edilmesi üzerine odaklanmaktadır. Çalışmada, yapı bazlı detaylı hasar sınıflandırmaları yerine doğrudan müdahaleye katkı sağlayacak genel enkaz tespiti hedeflenmiş ve YOLOv8 Large modelinin sunduğu hız-doğruluk dengesi analiz edilmiştir. Bu doğrultuda, çalışmada YOLOv8 Large modelinin doğrudan drone görüntüleri üzerinden tek sınıflı enkaz tespiti görevindeki performansının sistematik biçimde incelenmesi, afet yönetimi literatürüne özellikle saha uygulamalarına dönük bütüncül bir katkı sağlamaktadır.

2. MATERYAL VE METOT

2.1. Çalışmanın Tasarımı

Bu çalışma, deprem sonrası oluşan enkaz alanlarının tespiti amacıyla insansız hava aracı (İHA) ile elde edilen görüntülerin, nesne tanıma tabanlı derin öğrenme

algoritması olan YOLOv8 (You Only Look Once - Version 8) kullanılarak analiz edilmesini kapsamaktadır. Çalışma, klasik görüntü işleme tekniklerinden farklı olarak gerçek zamanlı nesne tespiti sağlayan modern bir yapay zeka yaklaşımı sunmayı amaçlamaktadır.

2.2. Veri Seti Hazırlığı

Bu araştırma, 2023 Hatay-Maraş depreminin ardından dronelar ile elde edilen görüntülerin kullanılmasıyla, deprem hasar tespiti amacıyla kapsamlı bir veri seti oluşturmayı hedeflemektedir. Veri seti, YouTube platformunda kamuya açık olarak paylaşılan afet görüntülerinden elde edilen videoların kare kare analiz edilmesi ve bu videolardan yüksek çözünürlüklü toplam 1312 adet fotoğrafın çıkarılması yoluyla oluşturulmuştur. Bu görüntülerin %95'i (1214 görsel) eğitim setine, %5'i (98 görsel) doğrulama setine ayrılmıştır. Görüntülerin önemli bir kısmı video üzerinden elde edilmiş olup, genel enkaz görüntüleri ile desteklenmiştir.

Drone görüntüleri, geleneksel uydu veya hava fotoğraflarına kıyasla daha yüksek çözünürlükte görsel bilgi sunmakta, bu da enkaz alanlarının daha doğru tespit edilmesine olanak sağlamaktadır (Joshi ve ark. 2017). Ayrıca, elde edilen özgün görüntülerin sayısını artırmak ve modelin farklı senaryolara karşı genelleme kapasitesini güçlendirmek amacıyla veri artırma (data augmentation) teknikleri uygulanmıştır. Bu teknikler arasında yansıtma (flip) ve döndürme (rotation) ayarlamaları yer almaktadır. Bu sayede modelin farklı görüntü açısı ve yapısal varyasyonlara karşı daha dayanıklı hale gelmesi sağlanmıştır. Şekil 1, Şekil 2 ve Şekil 3'de veri artırma uygulanan görseller sunulmuştur.



Şekil 1. Enkaz Görüntüsü



Şekil 2. Enkaz Görüntüsü (Yansıtma)



Şekil 1. Enkaz Görüntüsü (Döndürme)

2.3 Veri Etiketleme

Veri toplama ve etiketleme sürecini daha verimli hâle getirmek amacıyla Roboflow platformu kullanılmıştır. Roboflow, drone görüntülerinin yüklenmesi, sınıflandırılması, veri seti olarak düzenlenmesi ve YOLO formatında dışa aktarılması için kullanıcı dostu bir arayüz sunmaktadır. Görsellerdeki enkaz alanları manuel olarak "bounding box" yöntemiyle etiketlenmiş, tüm etiketleme süreci Roboflow üzerinden gerçekleştirilmiştir. Roboflow ortamındaki etiketleme görselleri Şekil 4, Şekil 5'te verilmiştir.



Şekil 4. Etiketleme yapılmamış örnek bir görsel



Şekil 5. Etiketleme yapılmış örnek bir görsel

2.4. YOLOv8 Modeli ve Model Eğitimi

Bu çalışmada, enkaz tespiti amacıyla Ultralytics tarafından geliştirilen YOLOv8 (You Only Look Once, Version 8) nesne tanıma algoritmasının "large" (YOLOv8l) versiyonu kullanılmıştır. YOLOv8, önceki sürümlerine kıyasla daha gelişmiş doğruluk oranları, düşük gecikme süresi ve optimize edilmiş model mimarisi ile dikkat çekmektedir. Özellikle gerçek zamanlı uygulamalara uygunluğu sayesinde afet yönetimi gibi kritik senaryolarda etkili bir biçimde kullanılabilir. Bu çalışmada YOLOv8 Large tercih edilmesinin temel nedeni, modelin geniş parametre kapasitesi ve gelişmiş

mimarisi sayesinde yüksek doğruluk ve detaylı enkaz tespiti için daha uygun olmasıdır. Large yapı, özellikle karmaşık sahne ve yüksek çözünürlüklü görüntülerde daha doğru sınırlayıcı kutular oluşturabilme ve küçük nesne tespiti başarısını artırabilme potansiyeline sahiptir.

Modelin temel parametreleri şu şekildedir:

- **Model tipi:** YOLOv8l (large)
- **Giriş boyutu:** 640×640 piksel
- **Çıktı sınıfı:** Enkaz (tek sınıf)
- **Çıktı formatı:** Sınırlayıcı kutular (bounding boxes)
- **Epoch sayısı:** 100

Model eğitimi, Google Colab platformunda NVIDIA T4 GPU destekli bir ortamda gerçekleştirilmiştir. Eğitim süreci boyunca Ultralytics'in açık kaynaklı YOLOv8 mimarisi kullanılarak yalnızca “enkaz” sınıfına odaklanan tek sınıflı nesne tespiti yapılmıştır. Görseller, 640×640 piksel boyutuna yeniden ölçeklendirilmiş ve eğitim sürecine dahil edilmiştir.

2.5. Temel Performans Metrikleri

F1 Skoru: Modelin kesinlik (precision) ve geri çağırma (recall) değerleri arasındaki dengeyi ölçen bir performans göstergesidir. 0 ile 1 arasında değer alır; 1'e yakın skorlar modelin hem doğru tahmin yapma hem de gerçek pozitifleri yakalama başarısının yüksek olduğunu gösterir.

Kesinlik (Precision, P): Modelin pozitif olarak tahmin ettiği örneklerin ne kadarının gerçekten doğru olduğunu ifade eder. Yüksek kesinlik değeri, modelin yanlış pozitif tahminlerinin az olduğunu gösterir ve yanlış alarm riskini azaltır.

Geri Çağırma (Recall, R): Modelin, veri kümesindeki tüm gerçek pozitif örnekleri ne ölçüde doğru tespit ettiğini gösterir. 1'e yakın geri çağırma değeri, modelin doğru pozitiflerin büyük çoğunluğunu başarıyla yakaladığını gösterir.

2.6. Görselleştirme ve Değerlendirme Metrikleri

PR Eğrisi: Precision ve recall değerlerinin farklı eşik seviyelerinde nasıl değiştiğini görselleştirir. Modelin kesinlik ve geri çağırma arasındaki performans dengesini incelemek için önemli bir araçtır.

Ortalama Hassasiyet (mAP): Precision ve recall değerlerinin çeşitli eşikler ve sınıflar üzerindeki ortalamasını alarak modelin genel başarımını özetleyen bir metriktir. Nesne tespit algoritmalarının karşılaştırılmasında yaygın olarak kullanılır ve modelin hem doğruluk hem de kapsayıcılığını tek bir değerle ifade eder.

Karışıklık Matrisi: Modelin tahmin ettiği sınıflarla gerçek sınıfları karşılaştırarak doğru ve yanlış tahminleri detaylandıran bir tablodur. Modelin hangi sınıflarda başarılı olduğunu, hangi sınıflarda hataya daha yatkın olduğunu ve hata türlerinin dağılımını analiz etmek için kullanılır.

3. BULGULAR

YOLOv8 modeli kullanılarak gerçekleştirilen enkaz tespiti çalışmasının çıktıları üç başlık altında sunulmaktadır: (1) saha uygulaması gözlemi, (2) model performans metrikleri ve (3) görsel çıktıların değerlendirilmesi. Model eğitimi için elde edilen performans metrikleri Tablo 1'de sunulmuştur.

Tablo 1. Model performans metrikleri

Model	F1/C	P/C	R/C
V8 Large	0.76/0.590	1.0/0.926	0.86/0.0

Tablo 1'de sunulan YOLOv8 Large modeline ait performans metrikleri incelendiğinde, modelin genel tespit başarısını yansıtan F1 skoru 0.76 olarak elde edilmiştir. Bu değer, modelin doğruluk ve yakalama oranları arasındaki dengeyi görece iyi kurabildiğini göstermektedir. Precision (1.0) değeri, modelin ürettiği tüm pozitif tespitlerin eksiksiz biçimde doğru sınıfa ait olduğunu ve yanlış pozitif üretmediğini göstermesi açısından dikkate değerdir. Bu durum, özellikle yanlış alarm üretiminin kritik olduğu arama-kurtarma ve enkaz tespiti gibi uygulamalarda modelin güvenilirliğini desteklemektedir. Öte yandan recall (0.86) değeri, modelin sahadaki gerçek enkazların büyük bir çoğunluğunu doğru şekilde tespit edebildiğini, ancak hâlâ belirli bir kısmını kaçırma olasılığının bulunduğunu ortaya koymaktadır. Tabloya yansıyan F1/C (0.590), P/C (0.926) ve R/C (0.0) ortalama güven değerleri ise modelin sınıf bazlı tespit performansında dengesizlikler yaşadığını ve özellikle belirli enkaz örüntülerini yakalamakta zorlandığını göstermektedir. Bu bulgular, YOLOv8 Large modelinin yüksek doğruluk ve kesinlik değerlerine sahip olmakla birlikte, sahadaki karmaşık ve çeşitli enkaz örnekleri için recall oranını daha da iyileştirmeye yönelik optimizasyonların gerekli olduğunu işaret etmektedir.

3.1. Simülasyon Ortamında Enkaz Tespiti: Saha Uygulaması

Gerçek dünya koşullarına benzer bir test ortamı oluşturmak amacıyla, etiketlenmiş bir enkaz görüntüsü 2×3 metre boyutlarında yüksek çözünürlüklü olarak çıktı alınmış ve zemin üzerine yerleştirilmiştir. Bu sahte enkaz alanı, modelin drone ile yapılan tespit işlemlerinde nasıl çalıştığını gözlemlemek üzere oluşturulmuştur. Test sürecinde DJI Mavic 2 marka drone kullanılmıştır. Bu cihaz, 1 inç CMOS sensöre sahip 20 MP çözünürlüklü kamerası ve 4K video kayıt kapasitesi ile yüksek kaliteli görüntüler elde etme imkânı sunmaktadır. Üç eksenli gimbal sistemi sayesinde uçuş sırasında stabil ve net görüntüler sağlayarak, modelin sahadaki performansının daha doğru bir şekilde değerlendirilmesine olanak tanımıştır.

Drone, yaklaşık 5–10 metre irtifadan bu alanı görüntülemiş ve YOLOv8 modeli yardımıyla gerçek zamanlı nesne tespiti gerçekleştirilmiştir. Model, görüntüdeki enkaz bölgesini başarıyla algılayarak sınırlayıcı kutularla işaretlemiş ve saha ortamında çalışabilirliğini göstermiştir. Bu test, modelin eğitim verisi ile gerçek hayata yakın ortamlarda nasıl performans gösterdiğine dair niteliksel bir doğrulama sunmuştur. Şekil 6'da simülasyon ortamında gerçekleştirilen bu testlere ait

görsel örnekler sunulmuştur. Şekil 7'de, DJI Mavic 2 drone'un görseli verilmiştir.



Şekil 6. Enkaz görüntüsü yerleştirilmiş görsel



Şekil 7. DJI Mavic 2 drone görseli

3.2. Model Performans Değerlendirmesi ve Eğitim Sonuçları

YOLOv8 modeli ile gerçekleştirilen eğitim süresi boyunca değişen box_loss, cls_loss ve dfl_loss gibi temel kayıpların yanı sıra doğruluk metrikleri olan precision,

recall, mAP50 ve mAP50-95 değerleri görselleştirilmiştir. İlk sıradaki grafiklerde görüldüğü üzere, eğitim süresince tüm kayıp fonksiyonlarında (box_loss, cls_loss ve dfl_loss) düzenli bir azalma gözlenmiş, bu durum modelin öğrenme sürecini başarıyla tamamladığını göstermektedir.

Alt satırdaki doğrulama (validation) kayıplarında ise zaman zaman keskin dalgalanmalar meydana gelmiştir. Bu durum, veri setindeki sınırlı çeşitlilik ya da modelin belirli örneklerde aşırı uyum göstermesi nedeniyle oluşan overfitting riskine işaret edebilir. Ancak genel eğilim doğrultusunda doğrulama kayıpları da zamanla azalmaktadır.


Modelin doğruluk metrikleri incelendiğinde; precision (kesinlik) ve recall (duyarlılık) değerlerinin giderek arttığı ve eğitim boyunca istikrarlı bir şekilde iyileştiği görülmektedir. Bu gelişme, modelin hem doğru pozitif tespit oranının hem de gerçek pozitifleri kapsama oranının arttığını ortaya koymaktadır. Benzer şekilde, mAP@0.5 ve mAP@0.5:0.95 değerleri de eğitim süresince yükseliş göstermiştir. Özellikle mAP@0.5 değerinin 0.766 seviyelerine ulaşması, modelin yüksek güvenle doğru sınırlayıcı kutular (bounding box) üretebildiğini göstermektedir. Tablo 2'de ortalama hassasiyet değeri sunulmuştur.

Tablo 2. Ortalama Hassasiyet (mAP@0.5) değeri


Model	mAP@0.5
V8 Large	0.766

Bu grafikler, modelin yalnızca eğitim verisine değil, aynı zamanda doğrulama verisine karşı da başarılı şekilde genelleme yapabildiğini ve uygulamaya elverişli bir doğruluk seviyesine eriştiğini göstermektedir. Modele ait eğitim grafiği Şekil 8'de verilmiştir.

Modelin sınıflandırma performansına ilişkin karışıklık matrisi incelendiğinde, "Enkaz" sınıfına ait 100 görüntünün doğru şekilde tahmin edildiği ve modelin bu sınıfta yüksek doğruluk sergilediği görülmektedir. Bununla birlikte, 30 adet "Enkaz" görüntüsünün "Background" olarak hatalı sınıflandırılması, modelin bazı enkaz alanlarını tespit edemediğini ve bu alanda hataya açık olduğunu göstermektedir. Ayrıca, 29 adet "Background" görüntüsünün yanlışlıkla "Enkaz" olarak etiketlenmesi, modelin sahte pozitif üretme eğilimine işaret etmektedir. "Background" sınıfına ait hiçbir görüntünün doğru şekilde tahmin edilememesi ise modelin bu sınıfı öğrenmekte zorlandığını, muhtemelen veri setinde bu sınıfın yeterince dengeli ve temsil edici şekilde yer almadığını düşündürmektedir. Bu durum, gelecekteki çalışmalar için sınıf dengesi ve örnek çeşitliliğinin artırılmasının önemine vurgu yapmaktadır. Şekil 9'da yer alan karışıklık matrisi, modelin doğrulama veri kümesi üzerindeki sınıflandırma başarımını göstermektedir. Görüldüğü üzere model, 100 enkaz örneğini doğru şekilde tespit etmiş (True Positive - TP) ve 29 adet arka plan örneğini yanlışlıkla enkaz olarak sınıflandırmıştır (False Positive - FP). Öte yandan 30 enkaz örneği yanlış şekilde arka plan (False Negative - FN) olarak etiketlenmiştir.



Şekil 8. YOLOv8 Large modeli eğitim grafiği




Şekil 9. YOLOv8 ile elde edilen Karışıklık Matrisi

YOLOv8 modelinin farklı sahnelerdeki enkaz görüntülerine verdiği tepkiler incelendiğinde, modelin "Enkaz" sınıfına ait nesneleri tutarlı şekilde mavi sınırlayıcı kutularla işaretlediği görülmektedir. Görseller, yoğun yıkımın yaşandığı şehir merkezlerinden daha az yapılaşmış alanlara kadar geniş bir çeşitliliğe sahiptir. Bu çeşitlilik karşısında modelin tespit başarısını koruması, öğrenilen desenlerin farklı coğrafi yapılar ve perspektiflerde de geçerli olduğunu göstermektedir. Bu da modelin genelleme kabiliyetinin yüksek olduğunu ve eğitim sürecinde kazandığı bilgiyle sahadaki yeni durumlara başarılı şekilde adapte olabildiğini ortaya koymaktadır. Ayrıca, modelin bu görsel çıktıları, uygulamanın gerçek dünya koşullarındaki saha kullanımı açısından niteliksel bir doğrulama niteliği taşımaktadır. Şekil 10'da doğrulama verisine ait çıktılar sunulmuştur.

3.3. Görsel Çıktılar ve Örnek Tespitler

Modelin eğitimi sonrasında hem doğrulama veri kümesinde hem de saha ortamına benzer koşullarda gerçekleştirilen uygulamalarda elde edilen örnek görseller, YOLOv8 mimarisinin enkaz tespiti konusundaki etkinliğini ortaya koymaktadır.

Görsellerde, çeşitli çevresel koşullarda ve farklı perspektiflerden elde edilmiş enkaz görüntüleri, model tarafından başarıyla algılanmış ve "Enkaz" sınıfı altında, ilgili bölgeler sınırlayıcı kutular (bounding box) ile işaretlenmiştir.



Şekil 10. Doğrulama verisine ait görsel


Özellikle, yüksek skor değerleriyle (örneğin 0.81, 0.85, 0.93 gibi) yapılan tespitler, modelin güven düzeyinin tatmin edici seviyede olduğunu göstermektedir. Aynı zamanda bazı görüntülerde yer alan düşük olasılıklı tahminler, modelin belirsiz bölgelerde de duyarlılığını koruduğunu ve temkinli bir şekilde sınıflandırma yaptığını ortaya koymaktadır.

Çalışmanın önemli katkılarından biri de, enkaz görüntüsünün fiziksel çıktısının (2x3 m ebatlarında) açık alana yerleştirilerek drone ile taranması suretiyle yapılan sahaya benzer simülasyon testleridir. Bu uygulama, modelin yalnızca dijital ortamda değil, fiziksel bir senaryoda da kullanılabilirliğini test etme fırsatı sunmuştur. Sonuçlar, modelin saha koşullarına adapte olabileceğini ve gerçek zamanlı arama-kurtarma operasyonlarına entegre edilebileceğini göstermektedir.

Ayrıca, geliştirilen YOLOv8 tabanlı modelin düşük donanım kapasiteli sistemlerdeki uygulanabilirliğini

değerlendirmek amacıyla, Raspberry Pi 4B cihazı ve bağlı kamera modülü ile testler gerçekleştirilmiştir. Bu testlerde, Raspberry Pi Camera ile alınan görüntüler daha sonra modele aktarılmış ve görüntü üzerinde enkaz tespit işlemi başarıyla gerçekleştirilmiştir. Modelin, bu sınırlı donanım ortamında da doğru ve kararlı şekilde enkaz bölgelerini tanımlayabildiği gözlemlenmiştir. Bu sonuç, sistemin yalnızca güçlü bilgisayarlarda değil, taşınabilir ve enerji verimli platformlarda da etkili biçimde çalışabileceğini ve özellikle enerji altyapısının sınırlı olduğu afet bölgelerinde pratik bir çözüm sunabileceğini ortaya koymaktadır.

Genel olarak elde edilen görseller, modelin yapısal karmaşıklık, açısal farklılık, ışık koşulları gibi çeşitli değişkenler altında dahi istikrarlı sonuçlar verdiğini ve enkaz tespiti görevinde kullanılabilirliğini kanıtladığını göstermektedir. Eğitim sonuçları Şekil 11 ve Şekil 12’de sunulmuştur.



Şekil 11. YOLOv8 modelinin gerçek afet sahasında enkaz tespiti örneği

Şekil 11’de sunulan örnek görüntüler, YOLOv8 Large modelinin farklı afet senaryolarında enkaz tespiti konusundaki başarımını ortaya koymaktadır. Modelin, karmaşık şehir dokusu ve farklı açılardan çekilmiş drone görüntüleri üzerinde enkaz bölgelerini genel olarak doğru şekilde sınırladığı ve yüksek güven skorları üretebildiği görülmektedir. Örneğin, ilk ve ikinci görsellerde yer alan büyük enkaz yığınları için sırasıyla 0.85 ve 0.81 gibi yüksek skorlar elde edilmiştir; bu durum modelin büyük ve belirgin enkaz kütlelerini doğru şekilde algılama kapasitesini yansıtmaktadır.

Bununla birlikte, bazı görsellerde küçük ya da kısmen örtülü enkaz alanlarının tespiti sırasında skorların görece düşük (0.27) olduğu dikkat çekmektedir. Bu, özellikle karmaşık arka plan ve kentsel kalıntılar arasında enkaz sınırlarının ayırt edilmesindeki zorlukları ve modelin daha ince ayrıntılarda sınırlı kalabileceğini göstermektedir. Ayrıca, üçüncü görselde olduğu gibi modelin farklı ölçek ve perspektifteki yapılar üzerinde de başarılı bir şekilde nesne tespiti yaptığı, yüksek doğrulukla sınır çizimleri gerçekleştirdiği gözlemlenmiştir.

Genel olarak bu örnekler, modelin geniş ölçekli ve açık alandaki enkaz alanlarını etkili biçimde tanımlayabildiğini, ancak karmaşık sahnelerde küçük enkaz kümelerinde sınırlı başarı sergileyebileceğini göstermektedir. Bu durum, modelin saha koşullarına özgü ek optimizasyonlarla desteklenmesi gerekliliğine işaret etmektedir. Şekil 12’de verilen görseller, YOLOv8 Large modelinin kontrollü fiziksel test ortamında farklı zemin ve ölçeklerde gerçekleştirdiği enkaz tespiti örneklerini yansıtmaktadır. Görsellerde, sahaya yerleştirilen basılı enkaz görselleri üzerine yapılan drone çekimleri sonucunda modelin ürettiği sınırlayıcı kutular ve güven skorları sunulmuştur. Özellikle ikinci görselde yer alan ve futbol sahasında yerleştirilmiş görsel için modelin 0.79 gibi yüksek bir güven skoru ile doğru sınırlayıcı kutu oluşturduğu görülmektedir. Bu, modelin açık ve kontrastı belirgin alanlarda etkin bir şekilde enkaz tespiti gerçekleştirebildiğini göstermektedir.

Buna karşılık, karmaşık desenlere sahip ya da arka plan dokusu nedeniyle sınırlı kontrasta sahip zeminler üzerinde modelin daha düşük güven skorları ürettiği dikkat çekmektedir. Bu bulgu, modelin kontrollü ortamlarda bile zemin ve arka planın görsel karakteristiklerinden etkilenebileceğini ve bu durumun saha uygulamalarında dikkate alınması gerektiğini göstermektedir.

Genel olarak sonuçlar, YOLOv8 Large modelinin fiziksel test ortamında enkaz benzeri nesneleri algılayabildiğini, ancak tespit güvenliğinin zemin özelliklerine ve görüntü kontrastına duyarlı olduğunu ortaya koymaktadır.

4. TARTIŞMA VE SONUÇ

Bu çalışmada, 2023 Hatay-Maraş depreminin ardından elde edilen drone görüntüleri kullanılarak YOLOv8 tabanlı bir derin öğrenme modeli ile enkaz tespiti gerçekleştirilmiştir. Geliştirilen sistem, yüksek çözünürlüklü veriler üzerinde eğitilmiş ve saha benzeri bir ortamda test edilmiştir. Özellikle, 2×3 metre boyutlarında basılmış bir enkaz görüntüsünün zemin üzerine yerleştirilerek drone ile gerçek zamanlı olarak taranması, sistemin pratik koşullarda nasıl çalıştığını ortaya koyan özgün bir yaklaşım sunmuştur.



Şekil 12. Sahada kurulan test ortamında YOLOv8 modelinin enkaz tespiti

Tespit sürecinde modelin görüntüdeki enkazı başarılı şekilde tanımlaması, YOLOv8'in sahadaki kullanım potansiyelini göstermesi açısından dikkat çekicidir. Bu bulgu, modelin yalnızca laboratuvar ortamında değil, gerçek uygulama senaryolarında da kullanılabilirliğini göstermektedir. Literatürde yer alan benzer

çalışmalarda (Xiong ve ark. 2020; Fernandez Galarreta ve ark. 2015) daha kompleks hasar sınıflamaları yapılmakta olsa da bu çalışmada yalnızca enkaz nesnesine odaklanılmış ve sınıf sayısı tekil tutulmuştur. Bu sayede hem eğitim süreci sadeleşmiş hem de gerçek zamanlı çalışabilirlik sağlanmıştır.

ÇIKAR ÇATIŞMASI

Yazarlar arasında çıkar çatışması yoktur.

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.
- 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
- Hasanlou, M., Shah-Hosseini, R., Seydi, S. T., Karimzadeh, S., & Matsuoka, M. (2021). Earthquake damage region detection by multitemporal coherence map analysis of radar and multispectral imagery. *Remote Sensing*, 13(6), 1195.
- 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.
- Joshi AR, Tarte I, Suresh S, Koolagudi SG (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 HA, Halin AA (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.
- 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.
- Rao A, Jung J, Silva V, Molinario G, Yun SH (2023). Earthquake building damage detection based on synthetic-aperture-radar imagery and machine learning. *Natural Hazards and Earth System Sciences*, 23(2): 789–807.
- 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.
- 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.
- 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*.