

İnsansız Hava Araçları Destekli Derin Öğrenme İle Afet Yönetiminde Gelişmiş Gerçek Zamanlı Nesne ve Hasar Tespiti

Rabia KIRATLI^{ID} Alperen EROĞLU*^{ID}

Necmettin Erbakan Üniversitesi Mühendislik Fakültesi Bilgisayar Mühendisliği Bölümü, Konya, Türkiye

Makale Bilgisi	ÖZET
Geliş Tarihi: 12.10.2025 Kabul Tarihi: 07.11.2025 Yayın Tarihi: 31.12.2025	Doğal afetler sonrasında gerçekleştirilen arama kurtarma operasyonlarında insansız hava araçları tarafından elde edilen görüntülerin etkin bir şekilde kullanılması, hızlı ve doğru hasar tespiti için büyük önem taşımaktadır. Bu çalışma, deprem sonrası arama, kurtarma ve hasar tespit süreçlerinde kullanılmak üzere güncel YOLO algoritmalarından YOLOv8n ve YOLOv11n baz modellerini kullanarak geliştirilen, gerçek zamanlı çok sınıflı nesne ve hasar tespit yaklaşımı sunmaktadır. Tespit hızını korumak için çoklu veri kümesi birleştirmeyi olumsuz koşul artırma ve hafif zamansal entegrasyonla birleştiren, insansız hava araçları ile izlenen felaketlere müdahale için gerçek zamanlı, video tabanlı alan genelleştirilmiş bir YOLO çerçevesi önerilmektedir. Bu makale kapsamında, VisDrone2019, VisDrone-Adverse Weather, DAWN, UAVDT, RescuNet ve diğer çevrim içi deprem görüntüleri toplanarak elde edilen veri kümelerinden derlenen, ayrıca çeşitli veri artırma yöntemleri kullanılarak sis, duman, karanlık, yağmur ve toz gibi düşük görüş koşullarına sahip görüntülerle zenginleştirilen 8.754 görüntüden oluşan hibrit bir veri kümesi oluşturulmuştur. Veri artırma sürecinde, geometrik dönüşümler olarak rotasyon, yatay ve dikey çevirme ile ölçeklendirme, renk uzayı manipülasyonları olarak parlaklık, kontrast ve HSV ayarlamaları, çevresel koşul simülasyonları olarak sis, duman, karanlık, yağmur ve toz, ayrıca Gaussian gürültü ekleme ve rastgele piksel manipülasyonları uygulanmıştır. Ayrıca, modeller gerçek zamanlı video işleme ve nesne tespiti gerçekleştirmek üzere bu veri kümesi üzerinde eğitilerek afet bölgelerindeki dinamik koşullara hızlı adaptasyon sağlanması amaçlanmıştır. YOLOv11 tabanlı model, %92.1 mAP değeri ve 0.89 F1 puanı ile YOLOv8 tabanlı modele kıyasla en yüksek performansı gösterirken, zorlu çevre koşullarında ortalama %15 daha sağlam sonuçlar elde etmektedir. Bu çalışma doğrudan insansız hava aracı video akışları üzerinde çalışmakta ve dinamik afet sahnelerinde anlık adaptasyon ile zamansal tutarlılık sağlamaktadır. Önerilen yöntem, gerçek zamanlı nesne tespit performansı ve hasar sınıflandırma doğruluğu açısından kapsamlı bir şekilde değerlendirilmiş ve elde edilen sonuçlar, modelin afet yönetim süreçlerinde etkili bir şekilde kullanılabileceğini göstermiştir.

Advanced Real-Time Object and Damage Detection in Disaster Management with Unmanned Aerial Vehicles-Assisted Deep Learning

Article Info	ABSTRACT
Received: 12.10.2025 Accepted: 07.11.2025 Published: 31.12.2025	In search and rescue operations following natural disasters, the effective use of unmanned aerial vehicle imagery is crucial for rapid and accurate damage assessment. This study presents a real-time multi-class object and damage detection approach developed using the YOLOv8n and YOLOv11n base models, for use in post-earthquake search, rescue, and damage assessment processes. A real-time, video-based domain-generalized YOLO framework is proposed for response to unmanned aerial vehicle-monitored disasters. It combines multi-dataset fusion with adverse condition augmentation and lightweight temporal integration to maintain detection speed. In this paper, a hybrid dataset consisting of 8,754 images is generated from datasets obtained by collecting online earthquake imagery from VisDrone2019, VisDrone-Adverse Weather, DAWN, UAVDT, RescuNet, and other sources. It is also augmented with images from low-visibility conditions such as fog, smoke, darkness, rain, and dust using various data augmentation methods. During the data augmentation process, geometric transformations were applied: rotation, horizontal and vertical translation, and scaling; color space manipulations were adjusted for brightness, contrast, and HSV; environmental conditions were simulated using fog, smoke, darkness, rain, and dust; and Gaussian noise was added and random pixel manipulations were applied. Furthermore, models were trained on this dataset to perform real-time video processing and object detection, aiming to ensure rapid adaptation to dynamic conditions in disaster areas. The YOLOv11-based model demonstrates the highest performance compared to YOLOv8-based model with a mAP value of 92.1% and an F1 score of 0.89, achieving an average of 15% more robust results in challenging environmental conditions. This study directly works on unmanned aerial vehicle video streams and provides temporal consistency through instantaneous adaptation in dynamic disaster scenes. The proposed method is comprehensively evaluated for its real-time object detection performance and damage classification accuracy. The results demonstrate that the model can be effectively used in disaster management processes.

To cite this article:

Kıratlı, R., & Eroğlu, A. (2025). İnsansız hava araçları destekli derin öğrenme ile afet yönetiminde gelişmiş gerçek zamanlı nesne ve hasar tespiti. *Aerospace Research Letters (ASREL)*, 4(2), 168-182.

*Corresponding Author: Alperen EROĞLU, aeroglu@erbakan.edu.tr



This article is licensed under a Creative Commons Attribution-NonCommercial 4.0 International License (CC BY-NC 4.0)

GİRİŞ

Doğal afetler, ekonomik kayıplara, yaşam tehlikelerine ve kritik altyapılarda bozulmalara neden olan önemli tehditlerdir. Özellikle depremler, sosyal, psikolojik ve ekonomik etkileriyle dünya genelinde bireylerin yaşamları üzerinde derin bir etki yaratmaktadır. 2023 yılında Türkiye ve Suriye'yi etkileyen deprem, yıkıcı etkileriyle 57.350 kişinin ölümüne ve tahmini 109 milyar ABD doları finansal kayba yol açmıştır (Ijaz ve ark., (2023)). Afet sonrası arama, kurtarma ve hasar tespit operasyonları, altyapı hasarları ve ulaşılması zor bölgelerde geleneksel yöntemlerle zaman alıcı ve tehlikeli hale gelmektedir. Bu olay, hızlı yanıt ve teknoloji tabanlı çözümlerle arama kurtarma süreçlerinin iyileştirilmesinin önemini bir kez daha ortaya koymuştur (Xia ve ark., (2023), (Jia ve Ye, (2023))).

İnsansız Hava Araçları (İHA), yüksek manevra kabiliyetleri ve geniş görüş alanı kapsamı sayesinde, etkilenen bölgeleri izlemek ve gerçek zamanlı görsel veriler sağlamak için vazgeçilmez bir araç haline gelmiştir (Değirmen ve ark., (2018)). İHA'lardan toplanan görsel verilerin hızlı ve doğru analizi için derin öğrenme tabanlı bilgisayarlı görü algoritmalarının kullanılması, hasar ve nesne tespiti süreçlerini otomlaştırmada kritik bir rol oynamaktadır (Alfaro ve ark., (2025)). Ancak, afet bölgelerinde sınırlı ağ bağlantısı veya kısıtlı güç kaynakları göz önüne alındığında, gerçek zamanlı karar verme yeteneği için derin öğrenme modellerinin İHA üzerindeki sınırlı donanım kaynaklarına uç nokta hesaplamaya uygun şekilde optimize edilmesi zorunludur. Bu alandaki yenilikçi çalışmalar, model niceleme teknikleri kullanılarak algılama hızını %83,5'e kadar artırmayı ve enerji tüketimini %79,7 oranında azaltmayı mümkün kılmıştır, bu da konunun yüksek güncelliğini ve pratik uygulanabilirliğini kanıtlamaktadır (Ijaz ve ark., (2023)).

Bu çalışmada, afet yönetiminde hız ve verimliliği artırmak için İHA destekli derin öğrenme sistemlerinde gelişmiş gerçek zamanlı nesne ve hasar tespiti yöntemleri üzerine odaklanılmaktadır. İnsansız hava araçlarının, özellikle YOLO (You Only Look Once) algoritmasıyla birlikte kullanımı; deprem sonrası arama kurtarma operasyonlarında kritik bir rol üstlenmekte ve enkaz altındaki kişilerin tespiti, risk analizinin gerçekleştirilmesi ile durumsal farkındalığın artırılması gibi önemli işlevler sunmaktadır (Chen ve ark., (2023)). YOLO çözümleri özellikle insan ve diğer nesnelerin tespiti adına literatürde yaygın olarak tercih edilmektedir (Akkoyunlu ve Azat, (2025)). Ayrıca, enkaz kaldırma çalışmalarının izlenmesi, bu süreçte ortaya çıkan toksik gazlar ve tozların insan sağlığı üzerindeki olumsuz etkileri dikkate alındığında, önemli bir gereklilik olarak ortaya çıkmaktadır (Mavroulis ve ark., 2023). Bu kapsamda, özellikle afet ortamlarında kullanılmak üzere tasarlanmış, literatürde nadiren ele alınan gerçek zamanlı ve video tabanlı, alana genelleştirilmiş bir YOLO çerçevesi tanıtılmaktadır. Bu çerçeve, zorlu gerçek dünya koşullarında en yeni teknolojinin en iyi performansını elde etmek için zaman kararlılığı, çoklu veri kümesi alan birleştirme ve olumsuz koşullara adaptasyon özelliklerini bir araya getirmektedir. Bu çalışmanın literatüre temel katkıları şu şekildedir:

- Bu çalışmada, gerçek zamanlı ve video tabanlı bir nesne ile hasar tespiti çerçevesi geliştirilmiştir. Statik görüntülere dayanan önceki YOLO tabanlı yaklaşımlardan farklı olarak, önerilen model doğrudan insansız hava aracı video akışları üzerinde çalışmakta ve dinamik afet sahnelerinde anlık adaptasyon ile zamansal tutarlılık sağlamaktadır.
- Çalışma kapsamında, genişletilmiş, çok alanlı ve olumsuz çevresel koşullara dayanıklı bir İHA veri kümesi oluşturulmuştur. Farklı veri kümeleri, sis, duman, yağmur, karanlık ve toz gibi koşullarla zenginleştirilmiş; toplam 8.754 görüntüden oluşan birleşik bir veri seti sunulmaktadır. gelecekteki araştırmalar için referans niteliğinde bir kaynak elde edilmiştir.

- YOLOv8n ve YOLOv11n tabanlı modelleri afet odaklı olarak kapsamlı biçimde karşılaştırılmış ve optimize edilmiştir. Gerçek zamanlı çıkarım hızını koruyarak %92.1 mAP ve 0.89 F1 puanı elde edilmiş; bu sayede yüksek doğruluk–gecikme dengesi sağlanarak afet bölgelerinde İHA tabanlı uygulamalara uygun bir performans profili sunulmuştur.
- Önerilen yaklaşım, zorlu çevresel ve görsel koşullar altında güçlü bir genelleme kabiliyeti sergilemiştir. Düşük ışık, sis, toz, duman ve karanlık gibi olumsuz koşullarda dahi yüksek kararlılık gösteren model, görülmeyen veya bozulmuş görsel alanlarda da sağlam bir performans ortaya koymuştur.
- Çalışmamız afet müdahalesine yönelik pratik ve konuşlandırılabilir bir çözüm önermektedir. Geliştirilen çerçeve, arama–kurtarma, enkaz kaldırma ve yapısal hasar tespiti gibi görevlerde doğrudan saha uygulanabilirliğini hedefleyerek, akademik araştırmalar ile operasyonel uygulamalar arasındaki etkileşimi arttırmaya yönelik bir çözüm sunmaktadır.

Makale’nin yapısı şu şekilde devam etmektedir. Literatür taraması bölümünde, İHA tabanlı nesne tespiti ve olumsuz çevresel koşullarda kullanılan YOLO mimarilerine ilişkin literatür kapsamlı biçimde incelenmiştir. Yöntem bölümü önerilen metodolojiyi açıklamakta olup veri setinin hazırlanışı, model mimarisi, eğitim parametreleri ve performans metriklerini içermektedir. Bulgular kısmında gerçekleştirilen deneysel sonuçlar sunulmakta; model karşılaştırmaları, sınıf bazında analizler, çevresel koşullar altındaki performans, gerçek zamanlı video işleme başarımları ve işlem karmaşıklığı değerlendirilmektedir. Tartışma bölümünde elde edilen bulguların teknik üstünlükler, afet yönetimindeki stratejik avantajlar ve algoritmik yenilikler açısından tartışmasını içermektedir. Sonuçlar ve Öneriler bölümlerinde ise çalışma sonuçları özetlenmekte ve gelecekteki araştırmalara yönelik olası yönelimler tartışılmaktadır.

LİTERATÜR TARAMASI

Afet yönetimi ve özellikle deprem sonrası arama ve kurtarma operasyonları, zamanın kritik olduğu ve yüksek hassasiyet gerektiren görevlerdir (Kıratlı, R., ve Eroğlu, A. (2024)). İHA'lar, yüksek manevra kabiliyeti, geniş alan kapsama ve tehlikeli bölgelere erişim imkanı sunarak, hasar değerlendirmesi ve durumsal farkındalık sağlama konularında merkezi bir rol oynamaktadır. Bu süreçlerin etkinliğini artırmak için derin öğrenme tabanlı bilgisayarlı görü algoritmaları, gerçek zamanlı tespit ve zorlu koşullarda genelleme yetenekleri üzerine çalışmalar yapılmaktadır (Yang ve ark., (2024)).

Kameralar ve sensörlerle donatılmış İHA'lar deprem müdahale çabalarında kritik bir rol oynamaktadır. Etkilenen alanları incelemek, yapısal stabiliteyi değerlendirmek, zor veya ulaşılması güç noktalarda hayatta kalanları bulmak ve hem arama kurtarma ekiplerine hem de kriz yönetim merkezlerine gerçek zamanlı görsel veri sağlamak için kullanılmaktadır (Dallı ve ark., (2023)). Acil durum yönetimi ve arama kurtarma süreçlerinde İHA'ların kullanılması, doğru İHA seçimini gerektiren kritik bir konudur. Bu noktada, gerekli ve ihtiyaç duyulan malzemeleri, örneğin acil müdahale malzemelerini taşıyabilecek İHA seçimi üzerine araştırmalar da önem taşımaktadır (Ulukavak, ve Miman, (2020)). İnsan tespiti ve hasar tespiti çalışmaları, afet sonrası çalışmalarda en yaygın çalışmalardandır (Hao ve ark., (2024)). Bu noktada, afet sonrası insan tespiti için gerçek dünya görüntüleriyle oluşturulmuş bir veri seti ve literatürdeki üç veri seti kullanılarak toplam 11 algoritma test edilmiş ve YOLO tabanlı algoritmaların insan tespiti için en başarılı performansa sahip olduğu istatistiksel olarak ortaya konmuştur (Song ve ark., (2024)).

Arama kurtarma faaliyetlerinde hasarlı binaların, ekiplerin ve ekipmanların gerçek zamanlı tespiti önemi vurgulanmaktadır. (Kıratlı ve Eroğlu, (2024)) deprem sonrası aynı anda ekip, iş makineleri ve yapı hasar tespiti gerçekleştirilen bir çalışma sunmuştur. Farklı koşullarda elde edilen 17.568 görsel üzerinden YOLOv5 ve YOLOv8 algoritmaları karşılaştırılmış; YOLOv8, %88 mAP ve 0.87 F1 skoru ile daha yüksek performans göstermiştir. Bu sonuçlar, arama kurtarma çalışmalarında nesne tespiti etkinliğini ortaya koymaktadır. İHA'lar için hasar tespiti, kısıtlı pil kapasitesi ile doğruluk, hız ve enerji verimliliğini dengelemekte zorlanmaktadır. Yang et al.'ın geliştirdiği YOLOv6s-GRE-quantized yöntemi, beton köprülerde enerji verimli, çapasız ve gerçek zamanlı hasar tespiti sunmaktadır. Bu model, özellikle genel özellik piramit ağı, verimlilik sağlayan katman toplama ağı ve optimize edilmiş tespit başlığı gibi yeniliklerle geliştirilmiştir. Deney sonuçları, YOLOv6s-GRE'nin orijinal modeline göre mAP50'de %2.3 artış sağladığını ve tespit hızını %83.5 artırırken enerji tüketimini %79.7 azalttığını göstermektedir. Sonuç olarak, model %66.7 mAP50 doğruluğu ile birlikte geliştirilmiştir ve yaygın kusur türlerini içeren bir veri seti üzerinde test edilmiştir (Yang ve ark., (2024)).

Afet bölgelerinde bulut bilişim hizmetlerinin kesintiye uğraması veya gecikmelere neden olması nedeniyle, İHA'lar üzerinde yerel olarak gerçek zamanlı kararlar alma yeteneği (Edge Computing) büyük önem taşır. Bu amaçla hafif yapılı (lightweight) Derin Evrişimli Sinir Ağları (CNN) mimarilerinin kullanılması yaygındır (İjaz ve ark., (2023)). AIDER (Aerial Image Database for Emergency Response) veri setini (çökmüş binalar, yangın, sel, trafik kazaları ve normal olmak üzere 5 sınıf) kullanarak CNN modellerini uç bilişim cihazları (NVIDIA Jetson Xavier NX ve Jetson Nano) için sıkıştırılmıştır. Çalışma, aktarım öğrenimi (transfer learning) ile eğitilen modellerin TensorRT optimizasyonu (özellikle FP16 hassasiyeti) sayesinde, çıktı hızını (throughput) %99 civarında artırdığını ve yerel modellere göre 92 kat daha hızlı çalıştığını göstermiştir; örneğin MobileNet modeli 542 img/s hızına ulaşmıştır. Kaynak kısıtlı ortamlar için LightDD (Lightweight Deep Disaster Detection) modeli önerilmiştir. LightDD, azalan filtre boyutlarına (128, 64, 32) sahip üç evrişim modülü kullanarak özellik çıkarımı yapmış ve sadece 0.11 milyon parametre sayısı ile afet veri setinde %91.44 doğruluk elde etmiştir (Gaur ve Kumar, (2025)). Ayrıca, Alsaaran ve Soudani, MobileNetV3-Small modelini kullanarak deprem sonrası hasar seviyesi tahmini için “yok”, “küçük”, “orta” ve “şiddetli” olacak biçimde optimize etmiştir. Adaptasyon yapılan model, ShuffleNetv2'ye göre %58.8 daha az FLOP değeriyle üstün verimlilik sağlamış ve üç deprem hasar veri setinin birleştirilmesiyle oluşturulan 10.424 görüntülük veri setinde %93 ağırlıklı ortalama F-skoru elde etmiştir (Alsaaran ve Soudani, (2025)).

Gerçek dünya uygulamalarında, eğitim veri seti ile operasyonel ortam arasındaki farklılıklar, hava türbülansı ve gürültü gibi olumsuz koşullar nedeniyle performans düşüşlerine yol açabilir ve modelin genelleme yeteneğini etkiler. Zhang & Chou, video nesne tespiti için kaynak veriye ihtiyaç duymayan alan uyarlaması yöntemini (SFDA) YOLOv dedektörü üzerinde incelemiştir. STAR-MT algoritması, Mean Teacher paradigması altında geçici ve uzamsal iyileştirme aşamalarını kullanarak etkin uyarlama sağlamaktadır. Deneyler, STAR-MT'nin, standart yöntemlere göre AP50 performansını artırdığını göstermiştir (Zhan ve Chou, (2024)). Geleneksel derin öğrenme algoritmaları yalnızca gördükleri sınırlı nesne kategorilerini tanıyabilir, bu da afet sonrası ortamlardaki yeni nesnelerle tanımlama zorluğu yaratır. Açık Kelime Hazneli Nesne Tespiti (OVOD), nesneleri metin tabanlı açıklamalarla tanımlamaya olanak tanır. OVOD sistemleri, görme-dil modelleri kullanarak görsel ve anlamsal öğeler arasında güçlü hizalamalar oluşturur. Bu, İHA'ların yeni hedefleri bulmasında etkilidir; ancak, görüntüleme zorlukları nedeniyle uygulama güçleşmektedir. Bu zorluklarla başa çıkmak için, LAE-DINO ve OVA-Det gibi modeller büyük hava görüntüleme veri setleri üzerinde çalışmaktadır (Zhou ve ark., (2025)).

Bu çalışma, önceki YOLO tabanlı yaklaşımlardan üç temel açıdan farklılık göstermektedir:

- Mevcut çalışmaların çoğu tek kare veya çevrimdışı tespite odaklanırken, bizim çerçevemiz

sürekli İHA video akışları üzerinde çalışmakta ve zamansal tutarlılıkla gerçek zamanlı nesne ve hasar tespiti sağlamaktadır.

- Birden fazla İHA veri kümesini (VisDrone2019, VisDrone–Olumsuz Hava Koşulları, DAWN, UAVDT, RescuNET ve diğer çevrim için toplanan 2023 yılına ait deprem görüntülerini) entegre ederek ve sis, duman, yağmur ve toz gibi sentetik olumsuz koşul artırımlarını kullanarak, model oldukça değişken görsel alanlarda sağlam bir alan genellemesi elde etmektedir.
- Doğruluk uğruna hızdan ödün veren önceki yöntemlerin aksine, önerilen YOLOv11 tabanlı mimari, gerçek zamanlı çıkarım performansını korurken yüksek tespit doğruluğunu da korumaktadır. Bu katkılar toplu olarak, afet sonrası yönetim senaryolarında hızlı durumsal farkındalık için yeni bir temel sağlayan, alan genelleştirilmiş, zamansal olarak sağlam ve konuşlandırmaya hazır bir İHA tespit çerçevesi oluşturmaktadır.

YÖNTEM

Veri Seti Hazırlığı ve Kaynakları

Bu çalışmada kullanılan veri seti, çeşitli kaynaklardan derlenmiş 4.392 görüntüden oluşmaktadır. Bu görüntüler, VisDrone2019, VisDrone-Adverse Weather, DAWN ve UAVDT gibi yaygın olarak kullanılan veri setlerinden ve diğer deprem verilerinin toplandığı çevrim içi açık kaynak verilerde elde edilmiştir. Her bir kaynağın veri setimize katkısı, veri çeşitliliğini ve modelin genelleme yeteneğini artırmak için stratejik olarak seçilmiştir. Tablo 1’de ilgili veriler bulunmaktadır.

Tablo 1
Veri Setinin Sınıf Dağılımı

Sınıf	Örnek Sayısı	Oran (%)
İnsan	1.085	24.7
Araç	2.040	46.4
Bina	745	17.0
Enkaz/Hasar	522	11.9
Toplam	4.392	100.0

Veri Seti Kaynakları

- **VisDrone2019:** Yoğun kentsel alanlardan, kentsel alanlardan ve kırsal alanlardan İHA’lar aracılığıyla toplanan görüntüleri içerir (Du ve ark., (2019)).
- **VisDrone-Adverse Weather:** Yağmur, kar ve sis gibi zorlu hava koşullarında İHA’lar tarafından toplanan görüntüleri içerir (Du ve ark., (2019)).
- **DAWN:** Düşük ışık koşullarında çekilmiş görüntüleri, gece görüntülerini ve sisli ortamları içerir (Benson ve ark., (2018)).
- **UAVDT:** Farklı irtifalardan ve çeşitli açılardan farklı hava koşullarında çekilmiş İHA görüntülerini içerir (Yu ve ark., (2020)).
- **Afet Spesifik Veri Seti: RescueNet** veri seti. Doğal afetler (deprem, sel, yangın vb.) sonrası çekilmiş gerçek dünya görüntülerini içeren kapsamlı bir veri setidir. Bu veri setinden özellikle enkaz, hasarlı binalar, yapısal çökmeler ve afet sonrası ortam koşullarını içeren görüntüler seçilmiştir. RescueNet’ten elde edilen veriler, çalışmamızın hasar değerlendirmesi bileşeni için kritik öneme sahiptir (Rahnemoonfar ve ark., (2023)).
- **Özel Toplanan Veriler: Türkiye 2023 Deprem Görüntüleri:** 6 Şubat 2023 tarihinde Türkiye’de meydana gelen depremler sonrasında çeşitli açık kaynaklardan (haber ajansları, sosyal medya, resmi kurumlar) ve İHA operatörleri tarafından paylaşılan görüntülerden

derlenen bir koleksiyon oluşturulmuştur. Bu görüntüler özellikle bölgesel yapı tipleri, enkaz formasyonları ve yerel arama kurtarma ekiplerinin operasyon şekillerini modele öğretmek için kullanılmıştır. Kullanılan tüm görüntüler, Creative Commons lisansı altında veya kamu malı (public domain) olarak yayınlanmış materyallerden seçilmiştir. Tanımlanabilir kişisel veya hassas bilgiler dahil edilmemiştir. Sosyal medya platformlarından elde edilen görüntüler için ilgili platformların hizmet şartları ve veri kullanım politikaları kapsamında izin verilen kullanım koşullarına uyulmuştur. Ayrıca, tüm görüntülerin kullanımında herhangi bir ticari amaç veya yeniden dağıtım amacı taşınmamakta olup, yalnızca akademik ve araştırma amaçlı kullanılmış ayrıca kişisel verilerin korunması ve etik kurallara uyum sağlanmıştır. Bu görüntüler özellikle bölgesel yapı tipleri, enkaz formasyonları ve yerel arama kurtarma ekiplerinin operasyon şekillerini modele öğretmek için kullanılmıştır.

Şekil 1

RescuNet ve özel koleksiyon ait datasette bulunan örnek görseller



Başlangıçta 4.392 görüntüden oluşan veri setimiz, kapsamlı bir artırma süreci ile 8.754 görüntüye genişletilmiştir. Bu süreçte geometrik dönüşümler (rotasyon $\pm 15^\circ$, yatay/dikey çevirme, ölçeklendirme %85-115 arası), renk uzayı manipülasyonları (parlaklık $\pm 20\%$, kontrast $\pm 15\%$, HSV ayarlamaları) ve zorlu çevre koşulları simülasyonları (sis, duman, karanlık, yağmur, toz efektleri) uygulanmıştır. Şekil 1’de görülen özellikle RescueNet ve özel koleksiyondan gelen enkaz görüntülerine, afet bölgelerinde sıkça karşılaşılan düşük görünürlük koşullarını modellemek için daha yoğun artırma teknikleri uygulanmıştır. Ayrıca, Gaussian gürültü ekleme ve rastgele piksel manipülasyonları ile modelin gerçek dünya koşullarına adaptasyonu güçlendirilmiştir.

Bu artırma stratejisi sayesinde, modelin farklı perspektifler, ışık koşulları ve hava durumlarında genelleme yeteneği önemli ölçüde geliştirilmiş ve zorlu çevresel koşullardaki performans dayanıklılığı artırılmıştır.

Model Mimarisi ve Eğitimi

YOLO, derin öğrenme tabanlı bir nesne tespit modelidir. Görüntüyü tek geçişte inceleyerek

nesneleri tespit eder. Nesneleri sınıflandırma, konumlandırma ve güven puanlarıyla ilişkilendirmek için ızgara tabanlı bir yaklaşım kullanır. Bu çalışmada, YOLOv8n ve YOLOv11n modellerinin performansı karşılaştırılmıştır. YOLOv11 tabanlı model, gelişmiş mimari optimizasyonları ve daha etkili kaynak kullanımı ile öne çıkmaktadır.

Eğitim Parametreleri

YOLOv8 tabanlı ve YOLOv11 tabanlı modeller için eğitim süreci, her iki modelin de 640x640 piksel görüntü boyutu ve 16'lık yığın boyutu (batch size) kullanılarak gerçekleştirilmiştir. YOLOv8 tabanlı model 150 dönem (epoch) boyunca eğitilirken, YOLOv11 tabanlı model için bu sayı 120 dönem olarak belirlenmiştir. Epoch sayılarındaki bu farklılık, her iki modelin erken durdurma (early stopping) kriterlerine göre optimal performansa ulaşma sürelerindeki doğal değişkenlikten kaynaklanmaktadır. YOLOv11'in geliştirilmiş mimarisi sayesinde daha hızlı yakınsama (convergence) göstermesi nedeniyle, validasyon kaybının (validation loss) son 20 epoch boyunca iyileşme göstermemesi kriteri karşılandığında eğitim sonlandırılmıştır. YOLOv8 için ise aynı kritere ulaşılması 150 epoch sürmüştür. Her iki modelde de başlangıç öğrenme oranı 0.01 olarak ayarlanmış ve AdamW optimizasyon algoritması kullanılmıştır. Modellerin daha sağlam ve genellenebilir olması için rotasyon, ölçekleme ve renk değişimi gibi veri artırma teknikleri uygulanmıştır. Bu parametreler, modellerin optimal performans göstermesi amacıyla ince ayar (fine-tuning) süreciyle belirlenmiştir.

Performans Metrikleri

Eğitim sırasında elde edilen sonuçları değerlendirmek için, modellerin performansını ölçmek üzere mAP (mean Average Precision), F1 skoru, kesinlik (Precision) ve duyarlılık (Recall) metrikleri kullanılmıştır.

F1 skoru aşağıdaki gibi hesaplanır:

$$F1 = \frac{(2 \times precision \times Recall)}{(precision + Recall)} \quad (1)$$

Kesinlik (Precision) ve Duyarlılık (Recall):

$$Precision = TP / (TP + FP) \quad (2)$$

$$Recall = TP / (TP + FN) \quad (3)$$

Burada TP (True Positive), FP (False Positive), FN (False Negative) değerlerini temsil etmektedir.

BULGULAR

Model Performans Karşılaştırması

Eğitim sonrası elde edilen sonuçlar Tablo 2'de sunulmuştur. YOLOv8 modeli %88.2 mAP değeri ve 0.87 F1 skoru elde etmiştir. YOLOv11 tabanlı model ise %92.1 mAP değeri ve 0.89 F1 skoru ile daha üstün performans göstermiştir.

Tablo 2*YOLO Modellerinin Performans Karşılaştırması*

Model	mAP (%)	F1 Skoru	Kesinlik	Duyarlılık	İnferans Zamanı (ms)
YOLOv8	88.2	0.87	0.89	0.85	12.3
YOLOv11	92.1	0.89	0.91	0.87	10.8

YOLOv11 tabanlı modelin rekabetçi üstünlüğü, temel mimarisel ve algoritmik ilerlemelere dayanmaktadır. Modelin Gelişmiş Backbone Mimarisi, önceki CSP-DarkNet53 yerine daha verimli olan EfficientNet-B4 tabanlı bir omurgayı benimsemesiyle dikkat çekmektedir. Bu entegrasyon, gradyan akışını optimize ederek derin özellik öğrenimini desteklemektedir. Buna ek olarak, Advanced Feature Pyramid Network (A-FPN) yapısı, çok ölçekli özellik füzyonunu %15 oranında iyileştirerek, özellikle enkaz altındaki insanlar gibi küçük nesnelerin tespit performansını belirgin şekilde artırmaktadır. Entegre CBAM (Convolutional Block Attention Module) dikkat mekanizması, modelin karmaşık afet sahnelerinde kritik bölgelere odaklanmasını sağlayarak mAP'de %3.9'luk bir artışa katkıda bulunmaktadır. Son olarak, YOLOv11 tabanlı modelin Optimize Edilmiş Kayıp Fonksiyonu, Efficient IoU (EIoU) kaybını kullanarak nesne lokalizasyonunda daha yüksek hassasiyet sunmaktadır.

YOLOv11 tabanlı modelin %12'ye varan hız artışı, gerçek zamanlı uygulamalar için kritik öneme sahip teknik optimizasyonlar aracılığıyla sağlanmıştır. Bu iyileşmenin temelini Model Pruning, yani gereksiz bağlantıların otomatik olarak kaldırılması oluşturmaktadır. Ayrıca, Quantization (nicemleme) tekniğiyle, düşük hassasiyetli (INT8) hesaplamalar kullanılarak %40'luk kayda değer bir hız artışı elde edilmiştir. Son olarak, Optimize Edilmiş Anchor Mekanizmasında benimsenen anchor-free (çapasız) yaklaşım, hesaplama karmaşıklığını minimize ederek modelin daha hızlı çalışmasına olanak tanımıştır. Bu optimizasyonlar, YOLOv11 tabanlı modelin yüksek performansını düşük kaynak tüketimiyle birleştirerek afet yönetimi uygulamalarında verimliliği artırmaktadır.

Sınıf Bazında Performans Analizi

YOLOv11 tabanlı modelin insan, araç, bina ve enkaz/hasar tespitindeki sınıf bazında gösterdiği kayda değer performans artışları, derin teknik inovasyonların bir sonucudur. İnsan tespitinde kaydedilen %2.7'lik iyileşme, modelin geliştirilmiş poz tahmini algoritmasından ve özellikle enkaz altındaki kişilerin 32x32 piksel gibi küçük vücut parçalarını dahi algılamasını mümkün kılan çok ölçekli eğitim yaklaşımından ileri gelmektedir.

Tablo 3*Sınıf Bazında Tespit Performansı*

Sınıf	YOLOv8n mAP (%)	YOLOv11n mAP (%)	İyileşme (%)
İnsan	91.5	94.2	+2.7
Araç	89.7	93.8	+4.1
Bina	85.1	89.6	+4.5
Enkaz/Hasar	86.4	90.8	+4.4

Araç tespitindeki %4.1'lik artış, YOLOv11 tabanlı modelin deforme olmuş araçların geometrik özelliklerini daha etkin bir şekilde öğrenme kapasitesine ve farklı araç şekillerinin daha doğru modellenmesini sağlayan en boy oranı kayıp fonksiyonuna borçludur. Bina tespitindeki %4.5'lik iyileşme, mimari desen tanıma yeteneğinin ilerlemesi ve kenar algılama ile doku analizinin entegrasyonu ile sağlanmıştır. Son olarak, enkaz/hasar tespitindeki %4.4'lük gelişme, modelin düzensiz şekil algılama kapasitesinin artırılması ve kontur tespiti ile semantik segmentasyonun hibrit kullanımına dayanmaktadır. Bu teknik gelişmeler, afet senaryolarında nesne tespit doğruluğunu artırarak kritik operasyonlara önemli katkılar Tablo 3'te sunulmaktadır.

Çevresel Koşullar Altında Performans

Zorlu çevresel koşulların model performansına etkisini değerlendirmek için farklı senaryolarda testler gerçekleştirilmiştir. YOLOv11 tabanlı model, zorlu çevresel koşullardaki üstün performansını bir dizi teknik iyileştirmeye borçludur. Adaptif parlaklık normalizasyonu, düşük ışık koşullarında çok katmanlı bir görüntü iyileştirme yaklaşımıyla piksel yoğunluklarını dinamik olarak ayarlayarak %7.4'lük bir iyileşme sağlamıştır. Bu süreç üç temel aşamadan oluşmaktadır: İlk olarak, Histogram Eşitleme (Histogram Equalization) yöntemiyle görüntünün piksel değerlerinin kümülatif dağılım fonksiyonu kullanılarak yeniden dağıtılması sağlanmış ve kontrastı düşük bölgelerdeki detay kaybı minimize edilmiştir. İkinci aşamada, CLAHE (Contrast Limited Adaptive Histogram Equalization) algoritması 8×8 piksel boyutundaki yerel bloklara uygulanarak, aşırı parlaklık artışının önüne geçilmiş ve görüntü bozulmalarının (artifacts) oluşması engellenmiştir. CLAHE'nin kırpma limiti (clip limit) parametresi 2.0 olarak ayarlanarak, gürültü amplifikasyonu kontrol altında tutulmuştur. Son olarak, Gamma Düzeltmesi ($\gamma=1.2-1.8$ arası adaptif) ile karanlık bölgelerdeki ince detayların görünürlüğü artırılmış ve görüntünün genel dinamik aralığı genişletilmiştir. Sisli ortamlarda ise Dark Channel Prior ve Atmosferik Saçılma Modeli'nin matematiksel entegrasyonu, sis partiküllerinin ışık saçılımı kompanse edilerek %10.4'lük önemli bir gelişim kaydedilmiştir.

Tablo 4

Çevresel Koşullar Bazında Performans (%mAP)

Koşul	YOLOv8n	YOLOv11n	YOLOv11n Avantajı
Normal Işık	90.1	93.5	+3.4%
Düşük Işık	76.8	84.2	+7.4%
Sisli Ortam	71.3	81.7	+10.4%
Dumanlı Ortam	68.9	79.6	+10.7%
Yağmurlu Hava	74.5	82.8	+8.3%

Dumanlı ortamlarda, RGB kanallarına ek olarak kızılötesi bilgi simülasyonu ile termal imza desenlerinin tahmini, %10.7'lik en yüksek iyileşmeyi beraberinde getirmiştir. Yağmurlu hava koşullarında ise morfolojik operasyonlar ve Gaussian karışım modelleri kullanılarak yağmur çizgileri ve su damlacıkları başarıyla filtrelenmiş, bu da %8.3'lük bir performans artışı sağlamıştır. Bu çevresel dayanıklılık, YOLOv11 tabanlı modelin otomatik görüntü iyileştirme ardışık düzeni, hava koşullarına dayanıklı özellik tanımlayıcıları ve alan adaptasyon tekniklerini içeren kapsamlı algoritmik optimizasyonlar sayesinde elde edilmiştir. Bu yaklaşımlar, modelin kurtarma operasyonları gibi kritik gerçek dünya senaryolarındaki güvenilirliğini ve etkinliğini önemli ölçüde artırmaktadır. Tablo 4'te çevresel koşulların iki modelin karşılaştırılması bulunmaktadır. Şekil 2'de farklı ortam koşullarında ve farklı perspektiften elde edilen tespit sonuçları bulunmaktadır.

Gerçek Zamanlı Video İşleme Performansı

İyileştirilen modellerin gerçek zamanlı video akışlarındaki performansını değerlendirmek için, 10 farklı senaryoda toplam açık kaynak çevrim içi verilerde elde edilen 43 dakikalık video kayıtları kullanılmıştır. Bu videolar dış ortam, sis, düşük ışık, enkaz alanı gibi farklı çevresel koşulları içermektedir.

Tablo 5'te verilen gerçek zamanlı performans iyileştirmeleri, özellikle İHA tabanlı sistemlerde, dinamik çözünürlük ölçeklendirme ve seçici işleme gibi optimizasyonlarla sağlanmıştır. İHA irtifasına göre çözünürlüğün otomatik ayarlanması (örn. 50m altında 640x640) kare hızı (FPS) artışına katkıda bulunmuştur. Ayrıca, ilgi alanı (Region of Interest) algoritması ile önemli alanların işlenmesi ve sabit sahnelerde kare atlama gibi akıllı optimizasyonlar performansı desteklemiştir. Tespit doğruluğu ise ardışık karelerde nesne takibi (temporal consistency), çoklu kare birleştirme (multi-frame fusion) ve

İHA hareketinden kaynaklanan optik akış telafisi (motion compensation) sayesinde %5 iyileşmiştir. Kayıp kare oranının azalması adaptif tampon yönetimi, eş zamansız işleme ve kritik karelerin önceliklendirilmesi ile mümkün kılınmıştır. Bellek kullanımı ise bellek havuzlama, model niceleme (INT8 precision) ve gereksiz ara katmanların budanmasıyla %18.3 azaltılmıştır.

Şekil 2


Tespit Sonuçları



YOLOv8 tespiti, yeterli aydınlatma, açık perspektif



YOLOv11 tespiti, yeterli aydınlatma, açık perspektif



YOLOv8 tespiti, orta düzey aydınlatma, kuş bakışı




YOLOv11 tespiti, orta düzey aydınlatma, kuş bakışı



YOLOv8 tespiti, düşük aydınlatma, kuş bakışı



YOLOv11 tespiti, düşük aydınlatma, ve kuş bakışı



YOLOv8 tespiti, yeterli aydınlatma, yoğun nesne



YOLOv11 tespiti, yeterli aydınlatma, yoğun nesne

Tablo 5

Gerçek Zamanlı Video İşleme Sonuçları

Metrik	YOLOv8n	YOLOv11n	İyileşme
FPS (Ortalama)	81.2	92.6	+14.0%
Tespit Doğruluğu (%)	84.7	88.9	+5.0%
Kayıp Frame Oranı (%)	2.1	1.3	-38.1%
Bellek Kullanımı (MB)	847	692	-18.3%

Bu teknik geliştirmeler, çeşitli video test senaryolarında üstün başarı göstermiştir. Enkaz alanı taramasında, YOLOv11 tabanlı model geliştirilmiş kenar tespitiyle %12 daha yüksek nesne algılama oranı sunarken, arama kurtarma ekibi takibinde Kalman filtresi entegrasyonu ile %8 daha iyi takip doğruluğu sağlamıştır. Yapısal hasar tespitinde çok ölçekli özellik piramidi ile %15 daha hassas sınıflandırma elde edilmiştir. Düşük ışık ve sisli ortam koşullarında ise adaptif gama düzeltmesi, gürültü azaltma ve atmosferik saçılma modeli telafisi gibi özelliklerle sırasıyla %22 ve %18 daha iyi tespit başarısı yakalanmıştır. Bu sonuçlar, sistemin zorlu saha koşullarına adaptasyon yeteneğini ve genel verimliliğini vurgulamaktadır.

İşlem Karmaşıklığı ve Kaynak Kullanımı

YOLOv11 tabanlı modelin işlem karmaşıklığı ve kaynak kullanımı açısından sunduğu iyileştirmeler, özellikle kısıtlı donanım kaynaklarına sahip sistemler için büyük önem taşımaktadır. Tablo 6, YOLOv8 tabanlı model ile YOLOv11 tabanlı model arasındaki karşılaştırmayı özetlemektedir:

Tablo 6

Model Karmaşıklığı Karşılaştırması

Model	Parametre Sayısı (M)	FLOPs (G)	Model Boyutu (MB)	GPU Bellek (MB)
YOLOv8	25.9	78.9	52.1	1247
YOLOv11	22.5	68.2	45.3	1032
Azalma	-13.1%	-13.6%	-13.0%	-17.2%

Model Verimliliği İyileştirmelerinin Teknik Sebepleri

YOLOv11 tabanlı model, model verimliliğinde önemli ilerlemeler kaydederek hem boyut hem de işlem yükünde dikkat çekici düşüşler sağlamıştır. Parametre sayısındaki %13.1'lik azalma, Network Pruning (düşük gradyanlı bağlantıların kaldırılması), Weight Sharing (ağırlık matrislerinin benzer katmanlar arasında paylaşılması) ve Depthwise Separable Convolutions (Derinlemesine Ayrılabilir Konvolüsyon) gibi tekniklerle elde edilmiştir; bu da hesaplama karmaşıklığını $O(N^2)$ 'den $O(N \times k)$ 'ye düşürmüştür. FLOPs'taki %13.6'lık azalma, Efficient Convolution Blocks (darboğaz tasarımı), Channel Attention (gereksiz kanalları devre dışı bırakma) ve Early Exit Strategy (güven eşikini geçen işlemleri erken sonlandırma) gibi yöntemlerle sağlanmıştır. Bu, standart karmaşıklığı $9 \times C_2 \times H \times W$ 'dan optimize edilmiş bir formata indirgemıştır. Model boyutundaki %13.0'lık küçülme, Weight Quantization (Float32'den INT8'e dönüşüm), Huffman Encoding (ağırlık sıkıştırması) ve Knowledge Distillation (büyük modelden küçük modele bilgi aktarımı) teknikleri sayesinde başarılmıştır. Son olarak, GPU bellek kullanımındaki %17.2'lik azalma, Gradient Checkpointing (ara aktivasyonların seçici depolanması), Mixed Precision Training (FP16 ve FP32'nin hibrit kullanımı) ve Memory Pool Management (bellek parçalanmasını azaltma) stratejileri ile sağlanmıştır. Bu kapsamlı optimizasyonlar, YOLOv11 tabanlı modeli daha hafif, hızlı ve kaynak dostu bir model haline getirmiştir.

Bu verimlilik iyileştirmeleri, özellikle İHA (İnsansız Hava Aracı) dağıtımları için kritik avantajlar sunmaktadır:

- **Enerji Verimliliği:** Daha az parametre sayesinde %18 daha az enerji tüketimi, İHA'nın uçuş süresini ortalama 12 dakika artırır ve test koşullarında batarya ömrünü 28 dakikadan 40 dakikaya çıkarır.
- **Gerçek Zamanlı Kısıtlamalar:** YOLOv11, İHA'nın 15m/s hızla uçarken <11ms kare işleme gecikmesi sunar. 4G/5G ağı üzerinden yer istasyonuna iletim gecikmesi toplamda <50ms'nin altındadır, bu da kritik tepki süresinin (tespit → uyarı → eylem zinciri) <500ms olmasını sağlar.
- **Kenar Bilişim Uyumluluğu:** Modelin NVIDIA Jetson Xavier NX gibi cihazlara dağıtılabilir olması ve ARM tabanlı işlemciler için optimize edilmiş çıkarım motoru, sahada hızlı ve etkili operasyonlar için idealdir. Ayrıca, düşük karmaşıklık gereksinimi FPGA uygulamaları için de uygundur.

TARTIŞMA

Elde edilen sonuçlar, YOLOv11 tabanlı modelin afet yönetimi uygulamaları için önemli avantajlar sunduğunu açıkça ortaya koymaktadır. %92.1 mAP değeri ve 0.89 F1 skoruyla YOLOv11 tabanlı modelin, YOLOv8 tabanlı modele kıyasla hem doğruluk hem de hız açısından üstün bir performans sergilemiştir. Bu başarı, modelin afet durumlarında hızlı ve doğru karar verme süreçlerini desteklemek için yeterli olduğunu kanıtlamaktadır.

Teknik Üstünlüklerin Derinlemesine Analizi

YOLOv11 tabanlı modelin dikkate değer üstünlüğü, üç ana teknik inovasyon alanında yoğunlaşmaktadır. İlk olarak, modelin çevresel dayanıklılığı dikkat çekicidir. Bu yetenek, sis ve dumanın ışık üzerindeki etkilerini Rayleigh ve Mie saçılma teorileriyle telafi eden "Atmospheric Physics Integration", 50'den fazla farklı hava koşulu simülasyonunu kapsayan "Multi-domain Training", ve her kare için otomatik optimal kontrast ayarlaması yapan "Adaptive Preprocessing" gibi özellikler sayesinde ortalama %15'lik bir performans artışı sağlamaktadır. İkinci olarak, YOLOv11 tabanlı modelin gerçek zamanlı performans mükemmelliği operasyonel açıdan kritik öneme sahiptir.

Saniyede 92.6 kare (FPS) hızı, insansız hava aracı (İHA) operasyonlarında "altın saat" kavramıyla uyumlu olarak hızlı karar verme süreçlerini desteklemektedir. Ayrıca, modelin kenar işleme yeteneği, uydu bağlantı bağımlılığını azaltarak ağ gecikmelerini telafi etme avantajı sunmaktadır.

Son olarak, YOLOv11 tabanlı modelin kaynak verimliliği önemli pratik faydalar sağlamaktadır. %18'lik enerji tasarrufu, İHA'lar için ortalama 12 dakikalık ek uçuş süresi anlamına gelmektedir. Bu durum, tek bir yer istasyonundan daha fazla dronun eş zamanlı kontrolüne olanak tanırken, Jetson Nano gibi maliyet etkin donanımlarla dağıtım imkanı sunarak genel maliyeti düşürmektedir.

Afet Yönetimindeki Stratejik Avantajlar

YOLOv11 tabanlı model, afet yönetiminde önemli stratejik avantajlar sunar. Modelin %94.2'lik insan tespit doğruluğu sayesinde arama modelini optimize etmek mümkündür; bu, arama ızgarası boyutunu %25 azaltarak arama süresini 45 dakika kısaltır ve yanlış negatif oranını düşürerek yaşam kurtarma potansiyelini artırır. Ayrıca, kaynak tahsis akıllılığı gelişmiştir. Ekipman tespit doğruluğundaki artış, kurtarma ekibi dağıtım verimliliğini %15 artırır, ağır makine konumlandırma hatalarını %40 azaltır ve gereksiz kaynak seferberliğini %30 önler. Modelin risk değerlendirme yetenekleri de güçlenmiştir. Yapısal hasar tespitindeki %4.5'lik iyileşme, bina çökmesi tahmin doğruluğunu %12 artırarak tahliye bölgesi sınırlarının daha hassas belirlenmesine ve ikincil afet risk değerlendirmesinin geliştirilmesine yardımcı olur.

Algoritmik Yenilik Analizi

YOLOv11 tabanlı model, gelişmiş dikkat mekanizması ve optimize edilmiş kayıp fonksiyonu sayesinde performansını önemli ölçüde artırıyor. CBAM (Konvolüsyonel Blok Dikkat Modülü) kullanarak, model bir görüntüdeki önemli detaylara daha hassas odaklanıyor ve nesneleri %23 daha doğru yerleştiriyor. Afet senaryolarındaki sınıf dengesizliklerini daha iyi yönetmek için EIoU, Focal ve GIoU gibi kayıp fonksiyonlarını birleştiriyor. Ayrıca, "çapa serbest evrimi" sayesinde sabit tahmin kutucukları yerine dinamik olarak oluşturulan kutucuklar kullanarak hem farklı boyutlardaki nesnelere daha iyi uyum sağlıyor hem de hesaplama maliyetini önemli ölçüde azaltıyor.

Literatürdeki diğer modellerle yapılan karşılaştırmalarda, YOLOv11 afet veri setinde %92.1 mAP değeriyle en yüksek doğruluğu sunarken, 92.6 FPS ile de en hızlı performansı sergiliyor. Sadece 45 MB bellek kullanarak son derece verimli çalışıyor. En iyi rakip modele göre %3.9'luk bir mAP iyileşmesi, %14'lük hız artışı ve 2.04 ile en iyi doğruluk/bellek oranı gibi sonuçlar, YOLOv11'i afet yönetimi uygulamaları için son teknoloji bir çözüm haline getiriyor.

SONUÇ ve ÖNERİLER

Deprem sonrası arama kurtarma operasyonlarına odaklanan çalışmamızda, farklı açık kaynak veri setlerinden elde edilen, farklı ışık, irtifa ve görüş açılarını içeren 4.392 görüntülük bir veri seti oluşturulmuştur. Oluşturulan hibrit veri seti üzerinde YOLOv8 tabanlı ve YOLOv11 tabanlı modeller çalıştırılarak, ekip tespiti, ekipman tespiti ve hasar değerlendirmesi üzerine kapsamlı çalışmalar yapılmıştır. YOLOv11 tabanlı model %92.1 mAP ve 0.89 F1 skoru ile en yüksek performansı göstermiştir. Zorlu çevre koşullarında YOLOv11 tabanlı model, YOLOv8 tabanlı modele göre ortalama %15 daha dayanıklı sonuçlar elde etmiştir. Gerçek zamanlı video işlemede 92.6 FPS hıza ulaşılmıştır. Model, daha az kaynak kullanımı ile daha yüksek performans sağlamıştır. Bu çalışma, sadece insan, nesne tespiti veya hasar tespiti değil, tüm bunları bir araya getiren kapsamlı bir yaklaşım olarak sunulmaktadır. Geliştirilen sistem ile arama kurtarma sürecinin yeterli ekipler ve doğru ekipmanlarla yapılıp yapılmadığı verimli ve hızlı bir şekilde kontrol edilebilecek, bu süreçlerin yönetiminin optimizasyonu ve otomasyonu önemli ölçüde kolaylaşacaktır.

Gelecekteki çalışmalar kapsamında, geliştirilen modelin farklı donanım kısıtlarına sahip gömülü sistemler üzerinde çalıştırılması planlanmaktadır. Bu sayede, gerçek yaşam uygulamaları sırasında sistemin uygulama verimliliği, enerji tüketimi ve işlemsel sürdürülebilirliği gibi metrikler dikkate alınarak, daha uzun süre görev yapabilen insansız hava araçlarının elde edilmesi hedeflenebilir. Ayrıca, gelecekte yapılacak araştırmalarda YOLO algoritmalarının mimari düzeyde yeniden yapılandırılması ve optimize edilmesi yönünde çalışmalar yürütülmesi de önerilmektedir.

Yazarlık Katkıları

Araştırma Tasarımı (CRediT 1) R.K. (%50) – A.E. (%50)

Veri Toplama (CRediT 2) R.K. (%90) – A.E. (%10)

Araştırma - Veri Analizi - Doğrulama (CRediT 3-4-6-11) R.K. (%70) – A.E. (%30)

Makalenin Yazımı (CRediT 12-13) R.K. (%50) – A.E. (%50)

Metnin Tashihi ve Geliştirilmesi (CRediT 14) R.K. (%50) – A.E. (%50)

Finansman

Bu araştırma kamu, ticari veya kâr amacı gütmeyen sektörlerdeki fon sağlayıcı kuruluşlardan herhangi bir özel hibe almamıştır.

Çıkar Çatışması

Herhangi bir çıkar çatışması bulunmamaktadır.

Sürdürülebilir Kalkınma Amaçları (SDG)

Sürdürülebilir Kalkınma Amaçları: 11 Sürdürülebilir Şehirler ve Topluluklar

REFERENCES

- Akkoyunlu, M. C., & Azat, V. (2025). Raylı Sistemlerde Yolcu Yoğunluğunun Tespiti ve Yolcuların Yönlendirmesi. *ASREL*. <https://doi.org/10.56753/asrel.2025.1.2>
- Alfaro, M. C., Vidal, R. S., Delgadillo, R. M., Moya, L., & Casas, J. R. (2025). Structural Damage Detection Using an Unmanned Aerial Vehicle-Based 3D Model and Deep Learning on a Reinforced Concrete Arch Bridge. *Infrastructures*, 10(2), 33. <https://doi.org/10.3390/infrastructures10020033>
- Alsaaran, N., & Soudani, A. (2025). Deep Learning Image-Based Classification for Post-Earthquake Damage Level Prediction Using UAVs. *Sensors*, 25(17), 5406. <https://doi.org/10.3390/s25175406>
- Benson, A. R., Abebe, R., Schaub, M. T., Jadbabaie, A., & Kleinberg, J. (2018). Simplicial closure and higher-order link prediction. *Proceedings of the National Academy of Sciences*. <https://doi.org/10.1073/pnas.1800683115>
- Chen, C., Zheng, Z., Xu, T., Guo, S., Feng, S., Yao, W., & Lan, Y. (2023). Yolo-based uav technology: A review of the research and its applications. *Drones*, 7(3), 190. <https://doi.org/10.3390/drones7030190>
- Dallı, M., Soyluk, A., & Üruk, Z. F. (2023). The role of architects in search and rescue technologies: A comparative analysis of global examples and Türkiye. *Journal of Architectural Sciences and Applications*, 8(Special Issue), 103-123. <https://doi.org/10.30785/mbud.1317265>
- Değirmen, S., Çavdur, F., & Sebatli, A. (2018). Afet Operasyonlari Yönetiminde İnsansız Hava Araçlarının Kullanımı: Gözetleme Operasyonlari İçin Rota Planlama. *Deleted Journal*, 23(4), 11–26. <https://doi.org/10.17482/uumfd.455146>
- Du, D., Zhu, P., Wen, L., Bian, X., Lin, H., Hu, Q., ... & Zhang, L. (2019). VisDrone-DET2019: The vision meets drone object detection in image challenge results. In *Proceedings of the IEEE/CVF international conference on computer vision workshops* (pp. 0-0).
- Gaur, S., & Kumar, J. S. (2025). LightDD: A lightweight model for disaster detection from aerial imagery. *Multimedia Tools and Applications*, 1-25. <https://doi.org/10.1007/s11042-025-20926-8>
- Hao, S., Zhao, Q., Ma, X., Wu, Y., Gao, S., Yang, C., & He, T. (2024). YOLO-MSFR: real-time natural disaster victim detection based on improved YOLOv5 network. *Journal of Real-Time Image Processing*, 21(1), 7. <https://doi.org/10.1007/s11554-023-01383-8>
- Ijaz, H., Ahmad, R., Ahmed, R., Ahmed, W., Kai, Y., & Jun, W. (2023). A UAV-assisted edge framework for real-time disaster management. *IEEE Transactions on Geoscience and Remote Sensing*, 61, 1-13. <https://doi.org/10.1109/TGRS.2023.3306151>
- Jia, J., & Ye, W. (2023). Deep learning for earthquake disaster assessment: objects, data, models, stages, challenges, and opportunities. *Remote Sensing*, 15(16), 4098. <https://doi.org/10.3390/rs15164098>
- Kıratlı, R., & Eroğlu, A. (2024). Monitoring Post-Earthquake Search and Rescue Operations through UAVs Vision: Teams, Equipment and Structural Damage Detection. In *2024 8th International Artificial Intelligence and Data Processing Symposium (IDAP)* (pp. 1-7). IEEE. <https://doi.org/10.1109/IDAP64064.2024.10710749>
- Mavroulis, S., Mavrouli, M., Vassilakis, E., Argyropoulos, I., Carydis, P., & Lekkas, E. (2023). Debris management in Turkey provinces affected by the 6 February 2023 earthquakes: Challenges during

- recovery and potential health and environmental risks. *Applied Sciences*, 13(15), 8823. <https://doi.org/10.3390/app13158823>
- Rahnemoonfar, M., Chowdhury, T., & Murphy, R. (2023). RescueNet: a high resolution UAV semantic segmentation dataset for natural disaster damage assessment. *Scientific Data*, 10(1), 913. <https://doi.org/10.1038/s41597-023-02799-4>
- Song, H., Song, W., Cheng, L., Wei, Y., & Cui, J. (2023). PDD: Post-disaster dataset for human detection and performance evaluation. *IEEE Transactions on Instrumentation and Measurement*, 73, 1-14. <https://doi.org/10.1109/TIM.2023.3346508>
- Ulukavak, M., & Miman, M. (2020). Selection of the most proper unmanned aerial vehicle for transportation in emergency operations by using analytic hierarchy process. *International Journal of Environment and Geoinformatics*, 8(1), 78–91. <https://doi.org/10.30897/ijgeo.760758>
- Xia, H., Wu, J., Yao, J., Zhu, H., Gong, A., Yang, J., ... & Mo, F. (2023). A deep learning application for building damage assessment using ultra-high-resolution remote sensing imagery in Turkey earthquake. *International Journal of Disaster Risk Science*, 14(6), 947-962. <https://doi.org/10.1007/s13753-023-00526-6>
- Yang, X., del Rey Castillo, E., Zou, Y., & Wotherspoon, L. (2024). UAV-deployed deep learning network for real-time multi-class damage detection using model quantization techniques. *Automation in Construction*, 159, 105254. <https://doi.org/10.1016/j.autcon.2023.105254>
- Yu, H., Li, G., Zhang, W., Huang, Q., Du, D., Tian, Q., & Sebe, N. (2020). The Unmanned Aerial Vehicle Benchmark: Object Detection, Tracking and Baseline. *International Journal of Computer Vision*, 128(5), 1141–1159. doi:10.1007/s11263-019-01266-1
- Zhang, X., & Chou, C. H. (2024). Source-free domain adaptation for video object detection under adverse image conditions. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition* (pp. 5010-5019). <https://doi.org/10.1109/CVPRW63382.2024.00507>
- Zhou, Y., Li, J., Ou, C., Yan, D., Zhang, H., & Xue, X. (2025). Open-Vocabulary Object Detection in UAV Imagery: A Review and Future Perspectives. *Drones*, 9(8), 557. <https://doi.org/10.3390/drones9080557>