

Atf İçin: Şatır, E., Demirtaş, E., Ağdemir, H. ve Yıldız, F. (2025). Hava Araçları için Otonom İniş Sistemi: Derin Öğrenme ve Bilgisayarlı Görü Tabanlı Bir Yaklaşım. *İğdır Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 15(3), 726-743.

To Cite: Şatır, E., Demirtaş, E., Ağdemir, H. & Yıldız, F. (2025). Autonomus Landing System for Aircraft: A Deep Learning and Computer Vision Based Approach. *Journal of the Institute of Science and Technology*, 15(3), 726-743.

Hava Araçları için Otonom İniş Sistemi: Derin Öğrenme ve Bilgisayarlı Görü Tabanlı Bir Yaklaşım

Emre ŞATIR^{1*}, Elif DEMİRTAŞ², Halim AĞDEMİR³, Fatma YILDIZ⁴

Öne Çıkanlar:

- Hava araçları için iniş sistemi geliştirimi
- YOLOv8 ile nesne tespiti
- İniş alanlarının güvenlik analizi
- Veri artırma teknikleri uygulaması
- Bilgisayarlı görü teknikleri entegrasyonu

Anahtar Kelimeler:

- Nesne tespiti
- Hava araçları için otonom iniş
- Derin öğrenme
- Görüntü işleme
- Veri artırma

ÖZET:

Son yıllarda, kullanım alanlarının genişlemesiyle birlikte, insanlı ve insansız hava araçları için güvenli park ve iniş sistemlerine duyulan ihtiyaç artmıştır. Bu çalışmada, hava araçlarının iniş süreçlerini optimize etmek ve iniş alanlarının güvenliğini değerlendirmek için YOLOv8 tabanlı bir nesne tespit modeli önerilmektedir. Geliştirilen sistem, görüntü işleme teknikleri ve yapay zeka algoritmalarını kullanarak potansiyel engelleri belirlemekte ve iniş alanlarının uygunluğunu analiz etmektedir. Çalışmada, çeşitli veri setleri kullanılmış ve veri artırma teknikleriyle modelin genelleme yeteneği güçlendirilmiştir. Deneysel sonuçlar, önerilen sistemin hava araçları için güvenli iniş bölgelerini yüksek doğrulukla belirleyebildiğini göstermektedir. Bu çalışma, havaalanlarında ve kentsel hava mobilitesi uygulamalarında güvenli ve otonom hava aracı iniş süreçlerini desteklemek için önemli bir katkı sunmaktadır.

Autonomus Landing System for Aircraft: A Deep Learning and Computer Vision Based Approach

Highlights:

- Development of landing system for aircraft
- Object detection with YOLOv8
- Safety analysis of landing areas
- Application of data augmentation techniques
- Integration of computer vision techniques

Keywords:

- Object detection
- Autonomous landing for aircraft
- Deep learning
- Image processing
- Data augmentation

ABSTRACT:

In recent years, the need for safe parking and landing systems for manned and unmanned aerial vehicles has increased with the expansion of their usage areas. In this study, a YOLOv8-based object detection model is proposed to optimize aircraft landing processes and evaluate the safety of landing areas. The developed system uses image processing techniques and artificial intelligence algorithms to identify potential obstacles and analyze the suitability of landing areas. In the study, various data sets are used, and the generalization capability of the model is enhanced by data augmentation techniques. Experimental results show that the proposed system can identify safe landing zones for aircraft with high accuracy. This study makes an important contribution to support safe and autonomous aircraft landing processes at airports and urban air mobility applications.

¹ Emre ŞATIR ([Orcid ID: 0000-0002-1950-5549](#)), İzmir Katip Çelebi Üniversitesi, Mühendislik ve Mimarlık Fakültesi, Bilgisayar Mühendisliği Bölümü, İzmir, Türkiye

² Elif DEMİRTAŞ ([Orcid ID: 0009-0006-0978-0287](#)), İzmir Katip Çelebi Üniversitesi, Mühendislik ve Mimarlık Fakültesi, Bilgisayar Mühendisliği Bölümü, İzmir, Türkiye

³ Halim AĞDEMİR ([Orcid ID: 0009-0003-8889-1089](#)), İzmir Katip Çelebi Üniversitesi, Mühendislik ve Mimarlık Fakültesi, Bilgisayar Mühendisliği Bölümü, İzmir, Türkiye

⁴ Fatma YILDIZ ([Orcid ID: 0009-0004-2605-6456](#)), İzmir Katip Çelebi Üniversitesi, Mühendislik ve Mimarlık Fakültesi, Bilgisayar Mühendisliği Bölümü, İzmir, Türkiye

***Sorumlu Yazar/Corresponding Author:** Emre ŞATIR, e-mail: emre.satir@ikcu.edu.tr

GİRİŞ

Son yıllarda hava araçlarının kullanım alanlarının genişlemesi ve çeşitlenmesi, akıllı park ve iniş sistemlerine duyulan ihtiyacı önemli ölçüde artırmıştır. Özellikle insansız hava araçlarının (İHA) askeri, lojistik, tarım ve kargo gibi sektörlerde yaygınlaşması, bu araçların güvenli ve etkili bir şekilde iniş yapabilmesini sağlayacak çözümlerin geliştirilmesini zorunlu kılmıştır. Buna benzer biçimde insanlı hava araçlarının (örneğin, hafif uçaklar veya hava taksiler) yoğun sivil bölgelerde veya sınırlı araziye sahip havaalanlarında park edilmesi ve yönlendirilmesi kritik bir lojistik problem hâline gelmiştir (Choi ve ark., 2022). Geleneksel yöntemlerde pilotlar veya yer kontrol operatörleri, hava araçlarını elle yönlendirerek park sürecini yönetmektedir. Bu durum, hem insan hatasına açık olmakta hem de operasyonel verimi düşürmektedir (Harris, 2015).

İniş süreçleri, hava araçlarının en hassas aşamalarından biri olarak kabul edilir ve iniş sırasında karşılaşılabilecek olası tehlikelerden kaçınmak için iniş pistlerinin güvenli bir şekilde analiz edilmesi gerekmektedir. Bu çalışmada, hava araçlarının iniş süreçlerini iyileştiren ve güvenli iniş bölgelerinin tespitini mümkün kılan bir sistem önerilmektedir. Önerilen sistem, nesne tespiti (object detection), görüntü işleme (image processing) ve yapay zeka (artificial intelligence) algoritmaları kullanarak hava araçlarının iniş pistlerini analiz etmekte ve potansiyel engelleri önceden tespit ederek güvenli iniş onayı sağlamaktadır. Çeşitli deneyler ve testlerle doğrulanan bu sistem, hava araçlarının otonom iniş yeteneklerini geliştirme noktasında önemli bir adım olarak değerlendirilmektedir.

Derin öğrenme (deep learning) mimarileri ile birlikte yapay zeka problemlerinin çözümü için pek çok derin öğrenme yaklaşımları geliştirilmiştir (Doğan ve Türkoğlu, 2019). Derin öğrenme mimarileri nesne tanımda olağanüstü sonuçlar elde etmiştir. Ayrıca örüntü tanıma, algılama, sınıflandırma, tahmine dayalı analitik, ilaç geliştirme, sözlük oluşturma, sinyal işleme, tıp, finans ve savunma sektörlerindeki uygulamalarda da kullanılmaktadır (Pacal, 2022), (Veziroğlu ve ark., 2023), (Pacal, 2023), (Pacal ve Alaftekin, 2023), (Kunduracıoğlu ve Paçal, 2024). Derin öğrenme ve görüntü işleme teknolojilerinin son yıllarda kaydettiği ilerlemeler, bu alandaki otomasyon ihtiyaçlarına etkin çözümler sunmaktadır (LeCun ve ark., 2015). Bilgisayarlı görü (computer vision) alanında en çok tercih edilen yaklaşımlardan biri olan YOLO (You Only Look Once) ailesi, gerçek zamanlı nesne tespiti ve sınıflandırma alanında önemli başarılar elde etmiştir (Redmon ve ark., 2016). YOLOv8 sürümü, önceki sürümlere kıyasla daha yüksek tespit doğruluğu ve düşük gecikme (latency) avantajı sunarak otonom sistemlerde kullanım için cazip bir seçenek hâline gelmiştir (Jocher ve ark., 2023). Ayrıca veri artırma (data augmentation) teknikleri yardımıyla modelin, farklı çevre koşulları ve hava şartlarında dahi yüksek doğrulukta sonuçlar verebilmesi sağlanabilmektedir (Shorten ve Khoshgoftaar, 2019).

Bu çalışma, insanlı ve insansız hava araçlarının güvenli ve otonom park süreçlerini yönetmeyi hedefleyen bir akıllı park sistemi geliştirmeyi amaçlamaktadır. Çalışmada, YOLOv8 gibi modern nesne tespiti algoritmaları ve OpenCV (Bradski, 2000) gibi görüntü işleme kütüphanelerinin yanı sıra, PyTorch (Paszke ve ark., 2019) altyapısı kullanılmıştır. Çalışmada ayrıca, farklı boyut ve yapılarıdaki hava araçlarının yer aldığı çok çeşitli veri setleri ve veri artırma yöntemleri tercih edilmiştir.

Bu çalışmanın literatüre sağladığı başlıca katkılar şu şekilde özetlenebilir:

- Hava Araçları İçin Özel Otonom Park Sistemi: Literatürde mevcut akıllı park sistemlerinin çoğu kara araçlarına yöneliktir. Bu çalışma, insanlı ve insansız hava araçları için özelleştirilmiş bir park ve iniş analiz sistemi sunarak önemli bir boşluğu doldurmaktadır.

- Gelişmiş Nesne Tespiti ve İniş Güvenliği Analizi: YOLOv8 tabanlı nesne tespit modeli kullanılarak, iniş alanlarında potansiyel engellerin tespiti ve iniş güvenliği değerlendirilmesi yapılmıştır.

Bu sayede otonom hava araçlarının güvenli iniş yapabilmesi için ileri düzey bir karar destek mekanizması sunulmaktadır.

- Çoklu Veri Seti Entegrasyonu ve Veri Artırma Teknikleri: Modelin farklı çevresel koşullarda yüksek doğrulukla çalışmasını sağlamak için geniş kapsamlı veri setleri kullanılmış ve veri artırma yöntemleri uygulanmıştır. Bu sayede modelin genelleme yeteneği güçlendirilmiştir.

- Gerçek Zamanlı Uygulamalara Uygunluk: Geliştirilen sistem, düşük gecikme süresiyle çalışacak şekilde optimize edilmiştir. Bu, otonom hava araçları ve havaalanı yönetim sistemleri için gerçek zamanlı entegrasyon imkanı sunmaktadır.

- İleri Düzey Görüntü İşleme ve Yapay Zeka Kullanımı: Çalışmada, OpenCV ve PyTorch gibi güçlü araçlar kullanılarak hava araçlarının iniş sürecini iyileştiren bir görüntü işleme ve derin öğrenme mimarisi oluşturulmuştur.

Bu katkıların hem akademik araştırmalar hem de endüstriyel uygulamalar açısından otonom hava araçlarının iniş ve park süreçlerini iyileştirmeye yönelik önemli bir adım teşkil ettiği düşünülmektedir.

Yapılan çalışmaların anlatıldığı bu yazının ilk bölümünde ayrıca iki alt başlık detaylandırılmıştır. Ön Bilgiler kısmında, çalışmada kullanılan teknolojilere değinilirken, İlgili Çalışmalar başlığında, ilk olarak literatürde var olan mevcut yayınlara değinilmiş ve bölümün ilerleyen kısımlarında bu çalışmanın yarattığı farklardan ve literatüre katkılarından bahsedilmiştir. İkinci bölüm olan Materyal ve Metot'ta, çalışmada kullanılan veri setlerinden ve çalışmanın temel tekniklerinden bahsedilmiştir. Üçüncü bölüm olan Bulgular ve Tartışma'da ise, kullanılan yöntemler ile elde edilen sonuçlar tablolar yardımıyla özetlenmiş ve detaylıca açıklanmıştır. Son bölüm ise, Sonuç kısmıdır ve bu bölümde çalışmada elde edilen bulgulardan kısaca bahsedilmektedir. Bu bölümde ayrıca, gelecek perspektifine de yer verilmiştir.

Ön Bilgiler

Bu çalışmada, insanlı ve insansız hava araçları için bir akıllı park sistemi geliştirilmiştir. Bunun için yapay zeka ve görüntü işleme teknolojilerinden yararlanılmıştır. Çalışmanın temelinde nesne tespiti yer almaktadır ve bunun için YOLOv8 algoritması (Talib ve ark., 2024) kullanılmıştır. Nesne tespiti, bilgisayarlı görüde görüntülerdeki nesneleri tanımlamayı ve yerelleştirmeyi içeren temel bir görevdir. Otonom sürüş, gözetim sistemleri, robotik ve artırılmış gerçeklik dahil olmak üzere çeşitli uygulamalarda çok önemli bir rol oynar (Tekin ve Bozkır, 2024). Görüntülerdeki nesnelerin yüksek doğrulukta tespit edilmesi gerçek zamanlı uygulamalar başta olmak üzere birçok uygulama alanı için önemli bir konudur. Evrişimli Sinir Ağları (Convolutional Neural Network - CNN) ise son yıllarda nesne tespiti uygulamalarında kullanılan ve yüksek doğrulukta başarılar elde edilebilen derin öğrenme tabanlı yöntemlerdir (Taşyürek ve Gül, 2023). YOLO algoritması, Evrişimli Sinir Ağlarını kullanarak nesne tespiti yapmayı amaçlayan bir algoritmadır. Literatürde, YOLO algoritmasının diğer alternatiflere göre daha iyi performans sergilediği gösterilmiştir (Kılıç ve ark., 2022). YOLO algoritması, sınırlayıcı kutuların (bounding box) içindeki nesnelere NMS (Non max suppression) uygulayarak düşük güvenilirlikli nesneleri değerlendirmeden çıkarır ve aynı bölgede yüksek güvenilirlikli bir sınırlayıcı kutu arar. Nesnenin orta noktası, yüksekliği ve genişliği bulunursa, bu verilere dayanarak bir sınırlayıcı kutu çizilir. Her bölge için bir tahmin vektörü oluşturulur ve bu vektörler içinde bir güven puanı hesaplanır. Sonuç olarak, güven puanı 0 ise nesne mevcut değildir; güven puanı 1 ise nesne mevcuttur (Eği, 2023).

Model eğitimi için Python programlama dili tercih edilmiştir. Python, özellikle derin öğrenme ve görüntü işleme alanlarındaki güçlü kütüphane desteği sebebiyle bu tip projelerde yaygın olarak kullanılmaktadır. Görüntü işleme görevlerinde ise OpenCV kütüphanesinden yararlanılmıştır. OpenCV

bir bilgisayarlı görü kütüphanesidir (Erişti, 2010). OpenCV, görüntülerin ön işlenmesi (preprocessing), nesne sınırlarının belirlenmesi gibi görüntü işleme görevleri için kritik bir rol oynamıştır. Çalışmada ayrıca faydalanılan diğer bir teknoloji de model eğitiminde kullanılan PyTorch çatısıdır.

Çalışmada, YOLOv8'in uygulanmasında "Ultralytics" kütüphanesinden faydalanılmıştır. Ocak 2023'te tanıtılan YOLOv8 kullanıcılara kapsamlı bir dizi geliştirme ve çok yönlü yetenekler sunarak YOLO serisinde önemli bir gelişme göstermiştir (Tekindemir ve Şenel, 2024). YOLOv8, Ultralytics tarafından geliştirilen ve gerçek zamanlı nesne tespitinde öne çıkan Evrişimli Sinir Ağı tabanlı bir modeldir. Mimari olarak üç ana bileşenden oluşur: "backbone", "neck" ve "head". Backbone katmanı, "CSPDarknet53" yapısını temel alarak görüntülerden özellik çıkarımını gerçekleştirir. Bu katman, derin öğrenme modellerinde yaygın kullanılan "Cross Stage Partial (CSP)" bloklarını içerir ve hesaplama verimliliği sağlarken özellik haritalarını zenginleştirir. Neck katmanı, özellikleri birleştirmek ve farklı ölçeklerdeki nesneleri algılamak için "PANet (Path Aggregation Network)" yapısını kullanır. Bu sayede hem küçük hem de büyük nesnelerin tespitinde yüksek doğruluk elde edilir. Head katmanı ise, tespit edilen nesnelerin sınırlayıcı kutularını ve sınıf tahminlerini üretir. YOLOv8, önceki sürümlere kıyasla "anchor-free" bir yaklaşım benimseyerek modelin karmaşıklığını azaltmış ve doğrudan piksel tabanlı tahminlerle daha hızlı sonuçlar sunmaktadır. Ayrıca, "mosaic data augmentation" ve "label smoothing" gibi tekniklerle eğitim sürecini optimize ederek genelleme yeteneğini artırmıştır. Bu teknikler, modelin farklı çevresel koşullarda (örneğin, sis, yağmur) ve değişen ışık şartlarında bile kararlı performans sergilemesini sağlar.

YOLOv8'in tercih edilmesinin temel nedeni, gerçek zamanlı uygulamalarda düşük gecikme süresiyle yüksek doğruluk sunmasıdır. Özellikle hava araçlarının iniş süreçleri gibi kritik uygulamalarda, hızlı ve güvenilir karar destek sistemleri gereklidir. YOLOv8, saniyede 160 kare (FPS) işleme kapasitesiyle bu gereksinimi karşılar. Ayrıca, OpenCV ve PyTorch gibi popüler kütüphanelerle uyumlu olması, modelin entegrasyonunu kolaylaştırmıştır. Son olarak, YOLOv8'in açık kaynaklı ve aktif bir geliştirici topluluğuna sahip olması, sürekli iyileştirmeler ve teknik destek imkanı sunmaktadır (Tekin ve Bozkır, 2024).

Modelin olabildiğince farklı ortamlara uyum sağlayabilmesi için çeşitli veri setleri kullanılmıştır. Ayrıca, eksik veri sorununu çözmek ve modelin özel veri senaryolarına uyum sağlayabilmesi amacıyla yeni veri setleri oluşturulmuştur ve bu veri setleri manuel olarak etiketlenmiştir. Bu veri setleri, hava araçları farklı yapı ve boyutlarda olduğunda, sistemin verimini olabildiğince yüksekte tutmak için gereklidir.

Eğitimden (training) elde edilen verileri artırmak amacıyla veri artırma yöntemleri uygulanmıştır. Bu teknikler arasında döndürme, renk değiştirme, ölçeklendirme gibi yöntemler yer almaktadır. Böylece farklı yapılarla ve boyutlarda olan hava araçlarının, yine farklı alanlarda verimli bir şekilde park edilmesini sağlayan bir sistem oluşturulmuştur.

İlgili Çalışmalar

Nesne tespiti üzerine yapılan erken dönem çalışmalarda, çoğunlukla geleneksel bilgisayarlı görü yöntemleri ve renk veya şekil tabanlı basit öznitelikler kullanılmıştır. Örneğin bir çalışmada, kamera görüntüleri analiz edilerek insanlar algılanır, izlenir ve onların hareketleri sınıflandırılır (Haritaoğlu ve ark., 2000). Ancak bu yaklaşımlar, düşük ışık, kötü hava koşulları veya karmaşık arka plan gibi zorlu senaryolarda istenilen başarıyı elde etmekte yetersiz kalmıştır. Derin öğrenme yöntemlerinin yaygınlaşmasıyla birlikte nesne tespiti ve sınıflandırma alanında önemli gelişmeler kaydedilmiş, CNN tabanlı modellerin otonom sistemlerde kullanımı hız kazanmıştır (Girshick, 2015). Özellikle nesne

tespiti için Faster R-CNN (Ren ve ark., 2015) ve SSD (Single Shot Multibox Detector) (Liu ve ark., 2016) gibi popüler ağ mimarileri, gerçek zamanlı uygulamalar için temel oluşturmuştur.

Çalışmalarda veri seti çeşitliliğinin artırılması, modelin genelleştirme yeteneğini güçlendirerek modelin farklı coğrafyalardaki veya hava koşullarındaki hava araçlarını başarıyla tespit etmesini sağlamaktadır (Wang ve Ma, 2024). Diğer yandan, LIDAR veya radar gibi farklı sensör verilerinden de yararlanmayı öneren araştırmalar, çoklu algılayıcı (multi-sensor fusion) yaklaşımı ile sistemin güvenilirliğini artırmanın mümkün olduğunu göstermektedir (Wang ve ark., 2020).

2020 yılında yayınlanmış olan ilgili çalışmada (Ekmen ve Aydoğdu, 2020) İHA'nın hata payını olabildiğince minimize ederek iniş yapması amacıyla bir sistem geliştirilmeye çalışılmıştır. Bu çalışmada, İHA'nın sistemine yerleştirilen dört adet motor yardımıyla hareket etmesi beklenmektedir ve iniş algılama sistemi ile iniş yapılacak yer başarıyla hedeflenmektedir. 2024 yılındaki diğer bir çalışmada (Karaköse ve Aksu, 2024) ise, İHA'ların iniş süreçlerinde karşılaşılan zorlukları azaltmak amacıyla, iniş pistinin görüntü işleme teknikleriyle tespiti ve pist üzerindeki engellerin nokta bulutu yöntemiyle analizi ele alınmıştır. Bu kapsamda, çevresinde çeşitli engeller bulunan bir iniş pisti tasarlanmış ve dört rotorlu bir İHA ile farklı yükseklik ve açılardan gerçek görüntüler elde edilmiştir. Toplanan verilerle oluşturulan veri seti, YOLOv8 derin öğrenme ağı kullanılarak işlenmiş ve iniş pisti tespiti gerçekleştirilmiştir. Ardından, pist üzerindeki engellerin varlığı nokta bulutu yöntemiyle analiz edilerek, derinlik haritaları oluşturulmuştur. Bir başka çalışmada genel park durumuna göre dinamik park yeri tahsisi sağlanmaktadır (Elfaki ve ark., 2023). Bu çalışmada yapay zeka tabanlı uygulama kullanılarak arabalar için park sistemi geliştirilmiştir.

DETR (DEtection TRansformer) (Carion ve ark., 2020), nesne tespiti için Transformer tabanlı bir modeldir. Geleneksel bölge tabanlı (region-based) yaklaşımlardan farklı olarak DETR, CNN tabanlı R-CNN veya YOLO gibi yöntemlere alternatif olarak, saf bir Transformer mimarisini kullanarak doğrudan uçtan uca (end-to-end) nesne tespiti yapar. DETR, geleneksel R-CNN veya Faster R-CNN gibi aşamalı işlem adımları içermez. Transformer tabanlı olduğu için özellikle büyük görüntülerde hesaplama karmaşıklığı YOLO veya Faster R-CNN gibi modellere kıyasla daha yüksektir.

Hava görüntülerinden nesne tespiti üzerine yapılan bir çalışmada (Atik ve ark., 2022), YOLOv2'nin ortalama %78 F1-skoru ve YOLOv3'ün %72 ortalama F1-skoru elde ettiğini göstermiştir. Bu sonuçlar, bu çalışmada tercih edilen YOLOv8 mimarisinin, önceki versiyonlara kıyasla beklenen performans artışını nicel olarak desteklemektedir. Özellikle, YOLOv8'in daha gelişmiş mimarisi ve eğitim teknikleri sayesinde, doğruluk ve hız açısından önemli kazanımlar sunması öngörülmektedir. Otonom hava aracı iniş sistemleri alanında yapılan bir çalışmada ise, özel olarak tasarlanmış bir CNN modeli ile farklı aydınlatma, dönme ve ölçekleme koşullarında %96'nın üzerinde bir başarı oranı elde edilmiştir (Cabrera-Ponce ve Martinez-Carranza, 2020). İlgili çalışma, belirli bir görev için optimize edilmiş CNN mimarilerinin yüksek performans potansiyelini ortaya koyarken, bizim YOLOv8 tabanlı yaklaşımımızın daha genel nesne tespiti yetenekleriyle birlikte hızlı ve etkin bir çözüm sunma potansiyelini vurgulamaktadır.

Ayrıca, (Shen ve ark., 2025) tarafından sunulan LandNet çalışması, sabit kanatlı hava araçlarının yaklaşma ve inişi için kamera pozisyonu tahminine odaklanmakta ve CNN ile Transformer katmanlarını birleştirerek gerçek dünya senaryolarında konum için 0,24 metre ve yönelim için 1,29 derece medyan hata gibi hassas sonuçlar elde edildiğini ortaya koymuştur. İlgili çalışma, bizim doğrudan iniş alanı tespiti üzerine kurulu YOLOv8 modelimizden farklı bir metodoloji izlese de otonom inişin başarısı için kritik olan kamera pozisyonu bilgisinin elde edilmesinde hibrit modellerin etkinliğini göstermektedir. Dolayısıyla, bu çalışmaların sayısal verileri ve yaklaşımları, bizim

YOLOv8 modelimizin performansını ve özgünlüğünü daha kapsamlı bir şekilde değerlendirmemize ve literatürdeki yerine daha sağlam bir şekilde oturtmamıza olanak tanımaktadır.

Bu doğrultuda bakıldığında, literatürdeki çalışmalar derin öğrenme teknikleriyle geliştirilen akıllı park sistemlerinin, insan faktörünü önemli ölçüde azaltarak operasyonel verimlilik ve güvenlik sağladığını doğrulamaktadır. Ancak zorlu hava koşulları (sis, kar, yağmur, yoğun bulutlanma vb.) ve farklı açılardan çekilmiş görüntülerde hâlâ iyileştirmeye ihtiyaç duyulduğu anlaşılmaktadır. Bu nedenle sunulan bu çalışmada, çok çeşitli veri setleri ve gelişmiş veri artırma teknikleri kullanılarak daha geniş bir uygulama yelpazesinde yüksek doğruluk seviyelerine ulaşılması hedeflenmiştir.

Bu çalışmanın literatürdekilerden en belirgin farklarından biri, önerilen sistemin hava araçlarına özel olması ve hedefini, radar gibi başka cihazlara ihtiyaç duymadan gerçekleştirebilmesidir. Bu çalışmada hava araçları için ortak bir çözüm aranırken diğer birçok çalışma genelde kara araçlarına yönelik olarak yapılmıştır. Çalışmada, park alanlarının değişebilecek olan boyut ve yapısı göz önünde bulundurularak her alana olabildiğince uyum sağlanması amaçlanmıştır. Bu amaç doğrultusunda, olabildiğince fazla veri seti toplanıp, bunlar veri artırma yöntemi ile çoğaltılmıştır.

MATERYAL VE METOT


Bu çalışmada tespit edilmesi hedeflenen sınıflar ve bu sınıfları temsil eden örnek görüntüler, Şekil 1, Şekil 2, Şekil 3 ve Şekil 4'te sunulmuştur. Modelin yalnızca ilgili sınıfları öğrenebilmesi amacıyla, eğitim veri setine bazı nesne içermeyen veya çalışmada yer verilen sınıflardan herhangi birine ait olmayan görüntüler de dahil edilmiştir. Bu görüntüler için herhangi bir etiket (sınırlayıcı kutu) tanımlanmamış, yani etiket dosyaları bilinçli olarak boş bırakılmıştır. Bu sayede YOLO tabanlı nesne tespit modelimiz, bu tür görüntülerde herhangi bir nesne tespit edilemediğinde bu alanları otomatik olarak “background” (arka plan) olarak değerlendirmiştir.




Şekil 1. Sınıf 0 – Taşıt



Şekil 2. Sınıf 1 – İnsan



Şekil 3. Sınıf 2 – Uçan Araba Park Alanı (UAP)



Şekil 4. Sınıf 3 – Uçan Ambulans İniş Alanı (UAI)

YOLO modellerinin tercih edilmesinin temel nedenlerinden biri bunların gerçek zamanlı nesne tespitindeki yüksek başarımıdır. Bazı çalışmalarda YOLO'nun diğer algoritmalara nazaran daha hızlı sonuçlar verdiği de görülmektedir (Tan ve ark., 2021). Birden fazla YOLO modeli mevcuttur ve her birinin farklı avantajları bulunmaktadır (Jiang ve ark., 2022). Sayısız sektörde kullanılabilecek olan bu algoritma, trafikte insan, araç, plaka gibi nesne tespiti görevlerinde yararlanılmaktadır. Aynı zamanda sağlık sektöründe tümörler, organlar ve kan damarları gibi çeşitli yapıları tespit etmek için tıbbi görüntüleme başarıyla uygulanmaktadır (Aldughayfiq ve ark., 2023). Mimarisi, doğruluk, hafiflik gibi konularda yüksek uyumluluğu nedeniyle diğer algoritmalara nazaran yüksek ilgi kazanmaktadır (Hussain, 2023). Tek aşamalı mimarisi sayesinde nesne tespit sürecini hızlandırarak çok aşamalı modellere kıyasla daha hızlı sonuçlar elde etmektedir. Bütün bu bilgiler ışığında, bu çalışmada YOLO modelinin tercih edilmesine karar verilmiştir.

Veri Setleri

Bu çalışmadan modelin olabildiğince farklı ortamlara uyum sağlaması için çeşitli veri setleri kullanılmıştır. Çizelge 1'de, kullanılan veri setleri ve özellikleri özetlenmiştir. Bu veri setleri, yerden maksimum 100 metre yükseklikten çekilmiş, yere dik açıyla bakan görüntülerden oluşmaktadır. Görüntüler, farklı çevresel koşulları ve sahneleri temsil ederek modelin genelleme yeteneğini artırmak amacıyla seçilmiştir.

Çizelge 1. Çalışmada kullanılan veri setleri

Veri Seti Adı	Örnek Sayısı	Kullanım Amacı	İçerdiği Sınıflar	Kullanılan Sınıflar
Aerial Maritime (Roboflow, 2024)	508	Deniz araçları tespiti	Dock, jetski, lift, boat, car	Dock, jetski, boat
PKLot (Roboflow, 2024)	12416	Taşıt tespiti	space_occupied, space_empty	space_occupied
VAID (Roboflow, 2024)	1247	Taşıt tespiti	1,2,3,4,5(farklı türde taşıtlar)	1,2,3,4,5
Datalagi (Kaggle, 2024)	8778	İnsan tespiti	human	human
Vehicle detection from satellite Computer Vision Project (Roboflow, 2024)	2059	Taşıt tespiti	boat, camping car, car, motorcycle, other, pickup, plane, tractor, truck, van	tümü
CARPK (Roboflow, 2024)	1567	Taşıt tespiti	0(taşıt)	0
İniş alanı simülasyonu veri seti	200	İniş alanları tespiti	UAI ve UAP	UAI ve UAP

Veri setleri, modele uygun hale getirilebilmesi ve daha iyi performans sağlayabilmesi amacıyla kapsamlı bir ön işleme sürecinden geçirilmiştir. Bu süreç iki ana aşamadan oluşmaktadır: etiket dosyalarının düzenlenmesi ve veri artırma.

Etiket dosyalarının düzenlenmesi

Veri setleri, farklı kaynaklardan toplandığı için bazen gereksiz veya hatalı etiketler içerebilir. Bu durum modelin eğitim performansını olumsuz etkileyebilir. Bu nedenle öncelikle etiket dosyalarının temizlenmesi ve düzenlenmesi sağlanmıştır. Python'un "os" modülü kullanılarak YOLO formatındaki etiket dosyaları işlenmiştir. Bu işlem sırasında, her bir etiket dosyasındaki sınıf ID'leri (class ID) kontrol edilerek gereksiz olanlar silinmiş ve doğru sınıflara yeniden atanmıştır. Ek olarak, çalışma kapsamında kendi oluşturduğumuz özel veri seti, "makesense.ai" (MakeSense, 2024) platformu kullanılarak etiketlenmiştir. Belirlenen sınıfların dışındaki etiketler (örneğin, modelin hedeflemediği sınıflar) otomatik olarak tespit edilip dosyalardan çıkarılmıştır. Bu, modelin gereksiz karmaşıklıkla karşılaşmasını önlemek için kritik bir adımdır. Farklı veri kaynaklarından gelen etiketler, tek bir formatta birleştirilmiştir. Örneğin, aynı sınıfa ait farklı isimlendirmeler (ör. "human" yerine "person") düzenlenerek tüm veri setinde bir tutarlılık sağlanmıştır.

Veri artırma

Modelin çevresel faktörlerden etkilenmeden genelleme yeteneğini artırabilmesi için veri artırma işlemleri uygulanmıştır. Veri artırma işlemleriyle, mevcut veri setleri çeşitlendirilmiş ve modelin farklı hava koşullarında dahi doğru sonuç verebilmesi sağlanmıştır. Bu süreçte, Python ve OpenCV kütüphanesi kullanılarak görüntüler üzerinde çeşitli filtreler uygulanmıştır.

Görüntüye farklı yoğunluklarda kar tanecikleri eklenerek, modelin kış koşullarında çalışabilirliği artırılmıştır. Görüntüye yapay yağmur damlaları eklenerek, yağışlı hava koşullarındaki performans test edilmiştir. Görüntüye farklı yoğunluklarda sis eklenerek modelin düşük görüş mesafesinde de çalışabilirliğini artırılmıştır. Rastgele piksellerin parlaklığı değiştirilerek görüntülere gürültü eklenmiş ve modelin gürültülü veri üzerinde genelleme yeteneği artırılmıştır. Görüntülere hareket bulanıklığı (motion blur) veya Gaussian bulanıklığı uygulanarak, bulanık verilere karşı dayanıklılık test edilmiştir. Görüntüler üzerinde kenarların keskinliğini koruyarak pürüzsüzleştirme işlemi gerçekleştirilerek, modelin nesne kenarlarını doğru algılamasına yardımcı olunmuştur. Farklı aydınlatma koşullarını simüle etmek için görüntünün gamma değerleri değiştirilmiştir. Örneğin, düşük ışııkta ve parlak gün ışığında algılama başarısı artırılmıştır. Bu görsel manipülasyonlar, modelin farklı ışık, hava ve çevre koşullarına karşı daha dayanıklı hale gelmesini sağlamıştır. Efektlerin uygulanmış olduğu görüntüler Şekil 5'te gösterilmiştir.



Şekil 5. Efektlerin uygulandığı çeşitli görüntüler

Veri seti, modelin doğru bir şekilde öğrenmesini sağlamak amacıyla %80 eğitim (train) ve %20 doğrulama (validasyon) olarak ikiye bölünmüştür. Bu ayırım, modelin eğitim sırasında öğrendiği bilgileri, doğrulama veri seti üzerinde test ederek performansını ölçmeyi mümkün kılmıştır. Veri setinin her iki kısmı, sınıf dengesini koruyacak şekilde dikkatlice hazırlanmıştır.

Model Eğitim Süreci ve Altyapısı

Bu çalışmada YOLOv8l (Large) modeli, yüksek performanslı bir donanım altyapısı üzerinde eğitilmiştir. Eğitim sürecinde kullanılan donanım bilgileri Çizelge 2'de verilmiştir. Yüksek işlemci ve GPU gücü, eğitim sürecinin hızlandırılmasını ve büyük veri setleriyle çalışmayı mümkün kılmıştır. Bu altyapı sayesinde, daha küçük YOLOv8 modellerine göre daha yüksek doğruluk oranlarına sahip olan ancak daha fazla hesaplama gücü gerektiren YOLOv8l modelinin tercih edilmesi mümkün olmuştur.

Performans karşılaştırmalarına göre, YOLOv8l modeli %52.9 mAPval başarıyla “small” ve “medium” versiyonlara göre daha yüksek tespit doğruluğu sunarken; daha büyük olan YOLOv8x modeline kıyasla daha düşük hesaplama maliyetiyle daha dengeli bir yapı sergilemektedir (Jocher ve ark., 2023). Eğitim süreci boyunca yüksek hızlı bir internet bağlantısı kullanılmıştır. İnternet hızına dair bilgiler Çizelge 3’te verilmiştir.

Çizelge 2. Donanım bilgileri

Sistem Birimi	Bilgi
İşlemci	AMD Ryzen Threadripper PRO 5995WX (64 çekirdek, 2.70 GHz)
RAM	256 GB
GPU	NVIDIA RTX A6000 (CUDA desteği aktif)
İşletim Sistemi	Window 11 Pro (64 bit)

Çizelge 3. İnternet hızı bilgileri

Ölçekler	Bilgi
İndirme Hızı	738 Mbps
Yükleme Hızı	469 Mbps
Ping Süresi	22ms

Eğitim parametreleri ve yapılandırma

Modelin öğrenme kapasitesini optimize etmek, aşırı öğrenme (overfitting) riskini azaltmak, kayıp değerlerini stabilize etmek ve eğitim süresini makul bir seviyede tutmak için “epoch” sayısı 50 olarak seçilmiştir. Bu seçim, veri setinin boyutu, modelin yapısı ve donanımın performansına göre yapılmıştır. Eğitim sırasında epoch bazında modelin performansı Çizelge 4’te verilmiştir.

Çizelge 4. Eğitim sürecinde epoch bazında performans

Epoch	Box Loss	Class Loss	mAP@50	Görüntü Sayısı	GPU Bellek(GB)
12	0.6445	0.3061	0.799	19935	16.8
13	0.6316	0.3004	0.800	19935	16.6
14	0.6230	0.2961	0.801	19935	16.5
15	0.6155	0.2923	0.802	19935	16.6
16	0.6103	0.2883	0.801	19935	16.5


Eğitim sırasında bir seferde işlenecek görüntü sayısı (batch size) 16, görüntü boyutu ise 640 piksel olarak belirlenmiştir. Bu değerler, eğitim performansını artırmak için GPU belleği dikkate alınarak optimize edilmiştir. Eğitim süreci toplamda 28 saat 20 dakika sürmüştür. Her epoch, ortalama olarak 34 dakika içerisinde tamamlanmıştır. Eğitim süresinin güçlü donanımın etkin şekilde kullanılması sayesinde makul bir zaman diliminde tutulduğu gözlemlenmiştir.

BULGULAR VE TARTIŞMA


Eğitim süreci ve model performansı, çeşitli metriklerle analiz edilmiş ve deneysel sonuçlarla değerlendirilmiştir. Bu bölümde eğitimden elde edilen çıktılar, ölçüm metrikleri ve grafiklerle açıklanarak modelin etkinliği ortaya konmuştur.

Sınıf Performansları ve Karmaşıklık Matrisi

Modelin tahmin performansı, Şekil 6 ve Şekil 7’de yer alan karmaşıklık matrisleri ile analiz edilmiştir. "Taşıt" sınıfı hem yüksek doğru tahmin oranı hem de düşük yanlış sınıflandırma oranı ile modelin en başarılı olduğu sınıftır. "UAİ ve UAP alanları", yüksek doğruluk oranları ile dikkat çekmektedir. Ancak, bu iki sınıf arasında sınırlı bir karışıklık olduğu gözlenmiştir. "İnsan" sınıfı ve "background" sınıfı arasında karışıklık daha yüksektir. Bunun sebebi, insan ve çevre özelliklerinin benzer görünebilmesidir.



Şekil 6. Modelin karmaşıklık matrisi (normalize edilmiş veriler)




Şekil 7. Modelin karmaşıklık matrisi (ham veriler)


Doğruluk ve F1 Puanı Analizi

Modelin genel performansı Şekil 8, Şekil 9 ve Şekil 10 grafiklerinde analiz edilmiştir. F1 eğrisine bakıldığında, model genelleme yeteneğini ortaya koymuş ve özellikle UAI ve UAP sınıflarında %99'un üzerinde F1-puanı yakalamıştır. Tüm sınıflar için kesinlik (precision) ve duyarlılık (recall) değerleri oldukça yüksektir. Bu, modelin hem pozitif sınıfları doğru şekilde algılayabildiğini hem de yanlış pozitif oranını düşük tuttuğunu göstermektedir.


Duyarlılık-güven skoru (confidence) eğrisi bize modelin tüm sınıflarda yüksek güvenle tahmin yaptığını ve yanlış tahminlerin düşük olduğunu göstermektedir.



Şekil 8. F1 puanı-güven skoru eğrisi




Şekil 9. Kesinlik-duyarlılık eğrisi




Şekil 10. Duyarlılık-güven skoru eğrisi

Veri Dağılımı

Şekil 11 ve Şekil 12’deki grafikler, modelin verileri nasıl algıladığını ve hangi özniteliklerin model performansına en fazla katkıda bulunduğunu anlamak için kritik bilgiler sağlar. Ayrıca, veri setindeki dengesizliklerin veya sınıflar arasındaki benzerliklerin model üzerinde olumsuz etkileri olup olmayacağını belirlemek için kullanılabilir. “Taşıt” sınıfının fazla örnek sayısı, modelin bu sınıfta üstün performans göstermesini sağlamıştır. “İnsan” sınıfı, daha az örneğe sahip olduğu ve “background” sınıfına benzediği için karışıklık oranı daha yüksek olmuştur. Homojenlik, verilerin dengeli dağılımı, genelleme yeteneğini olumlu etkiler. Ancak, örnek sayılarındaki dengesizlikler, belirli sınıfların model tarafından daha iyi öğrenilmesine sebep olabilir.



Şekil 11. Özellik korelasyon grafiği




Şekil 12. Sınıf dağılımı grafiği

Model Performansı

Modelin eğitim süreci ve kayıp eğrileri Şekil 13’te gösterilmiştir. Eğitim Kayıplarının (train/box_loss, train/cls_loss ve train/df_l_loss) eğitim sırasında sürekli olarak azaldığı gözlemlenmiştir. Bu durum, modelin veriye daha iyi uyum sağladığını ve öğrenme sürecinin etkili bir şekilde ilerlediğini göstermektedir. Doğrulama Kayıpları (val/box_loss, val/cls_loss ve val/df_l_loss) da benzer bir azalma eğilimi göstermiştir. Eğitim ve doğrulama kayıpları arasında büyük bir fark olmaması, modelin aşırı öğrenme yapmadığını ve genelleme yeteneğinin iyi olduğunu işaret etmektedir (Boros, 2023). Kesinlik değerleri (metrics/precision(B)), hem eğitim hem de doğrulama sırasında sürekli artış göstermiştir. Bu, modelin doğru tahmin yapma başarısının her geçen epoch’ta iyileştiğini göstermektedir. Duyarlılık (metrics/recall(B)) değerlerinin de artış göstermesi, modelin tüm pozitif örnekleri yakalama başarısını artırdığını ortaya koymaktadır.

Eğitim sürecinin sonlarına doğru kesinlik ve duyarlılık değerleri istikrar kazanmış, bu da modelin artık daha fazla iyileşmeye gerek duymadığını ve eğitim sürecinin sonlandırılmasının uygun olduğunu işaret etmektedir. Modelin genel doğruluk seviyesini gösteren mAP50 (metrics/mAP50(B)) metriği, %96 seviyesine ulaşmıştır. Bu, modelin belirlenen nesneleri yüksek doğrulukla algılayabildiğini kanıtlamaktadır. mAP50-95 (metrics/mAP50-95(B)) metriği ise %82 seviyesine ulaşmıştır. Bu durum, modelin farklı IoU eşiklerinde de başarılı performans sergilediğini ve farklı nesneler üzerinde etkili bir şekilde çalıştığını göstermektedir. Elde edilen sonuçlar, modelin tüm sınıflar için yüksek doğruluk ve genelleme yeteneği sergilemiştir. Özellikle UAİ ve UAP alanlarında mükemmel bir başarı sağlanmış, bu da modelin gerçek hayattaki uygulamalar için güvenilir olduğunu göstermektedir. İnsan sınıfında hafif bir karışıklık gözlemlenmiş, ancak kesinlik ve duyarlılık oranları tatmin edici düzeydedir. Eğitim sürecinde herhangi bir aşırı öğrenme belirtisi görülmemiştir, bu da veri artırma ve model seçiminin etkili bir şekilde yapıldığını kanıtlamaktadır.




Şekil 13. Modelin eğitim ve doğrulama kayıp eğrileri

Hava Araçları için Otonom İniş Sisteminin Algoritması ve Çıktıları

Geliştirilen sistem, görüntülerden aldığı verileri analiz ederek, iniş alanlarının uygunluk durumunu belirler ve bu bilgiyi görselleştirir. Algılanan nesneler arasında iniş alanı sınıfında olanlar (UAP (sınıf numarası = 2) ve UAİ (sınıf numarası = 3)) belirlenir. İniş alanlarının sınırlayıcı kutu koordinatları belirlenir. İniş alanlarının, insan (sınıf numarası = 1) veya taşıt (sınıf numarası = 0) gibi nesnelerin sınırlayıcı kutuları ile ortak alana sahip olup olmadığı (çakışma) kontrol edilir. İniş alanı bir insan veya taşıt sınırlayıcı kutusuyla çakışıyorsa, bu alan tehlikeli olarak işaretlenir, iniş durumu 0 değerini alır. Çakışma yoksa iniş alanı güvenli olarak kabul edilir, iniş durumu 1 değerini alır. Eğer bir insan veya taşıt bölgesi algılanırsa, bu alan inişe uygun olmayan alan olarak değerlendirilir, iniş durumu -1 değerini alır.

Algılama ve analiz sonuçları, görselleştirme adımı ile kullanıcıya Şekil 14, Şekil 15 ve Şekil 16'da gösterilmektedir. Tespit edilen nesneler ve iniş alanları, sınırlayıcı kutuları yer kontrol ekranına çizilmektedir. Her nesne, sınıfına özgü bir renk etiket ile gösterilir. İnsanlar mavi, taşıtlar yeşil, UAP kırmızı ve UAİ alanı mavi renkli sınırlayıcı kutularla işaretlenir. İniş alanlarının güvenli olup olmadığı, her sınırlayıcı kutu üzerinde belirtilen iniş değeri etiketiyle ifade edilir (1, 0 veya -1).


Şekil 14'te algılanan iniş alanında bir insan bulunduğunu göstermektedir. Bu durum inişin güvensiz olduğunu işaret etmektedir ve iniş değeri 0 olarak görülmektedir. Şekil 15'te, tehlikesiz bir iniş alanını gösterilmektedir. İniş alanında herhangi bir engel veya tehlike unsuru bulunmamaktadır. Şekil 16'da taşıtların algılandığı gösterilmektedir. Bu durum, iniş alanında engel oluşturabileceği için değerlendirilmesi gereken bir durumu ifade eder.



Şekil 14. Güvensiz durum (iniş alanında nesne bulunma durumu)



Şekil 15. Güvenli durum (inişe uygun tehlikesiz alan)



Şekil 16. Değerlendirilmesi gereken durum (taşıtların algılanması)

Literatürdeki Benzer Çalışmalar ile Karşılaştırma

Literatürde yer alan benzer çalışmalarla yapılan karşılaştırmalar, önerilen sistemin doğruluk, eğitim verimliliği ve genel başarımları açısından güçlü bir performans ortaya koyduğunu göstermektedir. 2023 yılındaki çalışmada (Liu ve ark., 2023) araştırmacılar tarafından geliştirilen, YOLOv8s tabanlı modelde “WIoUv3” kayıp fonksiyonu ile iyileştirme yapılmasına rağmen, “VisDrone2019” veri kümesi üzerinde “mAP50” değeri %40 olarak raporlanmıştır. Bu çalışmada ise, küçük hedeflerin tespiti için optimize edilmiş “small” modeli yerine daha gelişmiş olan YOLOv8l (Large) modeli kullanılarak, herhangi bir yapısal modifikasyona gerek duyulmadan %96 mAP50 doğruluk değeri elde edilmiştir. 2024 yılındaki bir diğer çalışmada (Yılmaz ve Kutbay, 2024), YOLOv8 ile gerçekleştirilen nesne tespiti uygulamasında %97 kesinlik ve %96 duyarlılık değerleri bildirmiştir. Bu çalışma ile söz konusu çalışmada sunulan mAP grafikleri arasında dikkat çekici bir benzerlik bulunmakta; özellikle “insan” ve “araç” gibi sınıflarda elde edilen yüksek başarımlar, her iki modelin de sınıf ayrımında güçlü olduğunu ortaya koymaktadır. Ayrıca, yalnızca mAP değil; kesinlik ve duyarlılık gibi metrikler açısından da tutarlılık gösterilmesi, önerilen modelin farklı veri kümeleri ve koşullar altında da güvenilir ve dengeli çalıştığını göstermektedir. Öte yandan, diğer bir çalışmada (Arserim ve Çetin, 2023) YOLOv3 tabanlı olarak geliştirilen sistem, ikinci eğitim aşaması sonucunda %70.9 mAP değerine ulaşabilmiştir. Bu çalışmada ise daha güncel ve derin mimariye sahip YOLOv8l modeliyle, daha az eğitim eforuyla daha yüksek doğruluk oranları elde edilmiştir. Tüm bu karşılaştırmalar,

önerilen sistemin yalın yapısına rağmen literatürdeki güncel yaklaşımlarla rekabet edebilecek düzeyde olduğunu ve modelin doğruluk, genelleme ve sınıf ayırım gücü bakımından oldukça başarılı olduğunu göstermektedir.

SONUÇ

Bu çalışmada insanlı ve insansız hava araçlarına yönelik bir akıllı park sistemi geliştirilmiştir. Derin öğrenme yöntemlerinden yararlanılıp tasarlanan sistem, nesne tespiti ve sınıflandırma algoritmaları kullanılarak modellenip başarıyla test edilmiştir. Eğitilen model hem nesne tespiti hem de sınıflandırma açısından yüksek doğruluk oranları elde etmiştir. Elde edilen bu sonuçlar sistemin güvenilir olduğunu ortaya koymaktadır. Deneyler sonucunda elde edilen sonuçlar, önerilen modelin hem hava araçlarının park konumlarını tespit etmede hem de olağan karmaşık görüntü senaryolarında etkili bir performans sergilediğini doğrulamaktadır. Bu sonucun elde edilmesinde çeşitliliği fazla olan veri setlerinin kullanılması etkili olan başlıca sebeplerden biridir. Bu özellikler modelin genelleştirme yeteneğini artırmıştır. Bununla birlikte, veri artırma teknikleri sayesinde modelin farklı senaryolara uyum sağlama kapasitesi güçlendirilmiştir.

Model başarılı sonuçlar verse de, sistemin daha da geliştirilmesi mümkündür. Örneğin, ekstrem hava koşullarında (sis, yoğun yağış, düşük ışık koşulları vb.) ya da değişik kamera açılarında yine benzeri sonuçları almak adına özel veri setleri hazırlanarak çalışmalar devam ettirilebilir. Böylece sistemin bu tür durumlara da uyum sağlama kabiliyeti geliştirilebilir. Aynı zamanda yine modelin performansını, çevre koşullarına göre duyarlılığını artırmak adına YOLOv8 algoritmasının yanı sıra Faster R-CNN, DETR ve benzeri modern nesne tespiti algoritmaları kullanılarak performans karşılaştırmaları yapılabilir. Bu tür denemelerin sistemin en verimli ve başarılı halini bulma konusunda büyük oranda yardımcı olacağı düşünülmektedir.

Buna ek olarak, yalnızca görsel veri değil, LIDAR (McManamon, 2015) veya radar tipi diğer sensörlerden alınan verilerin de kullanılabilmesi sistemin daha güvenilir olmasını sağlayabilir. Ayrıca, bu tür sistemlerin gerçek hayatta uygulanabilmesi için farklı alanlarda test edilmesi oldukça faydalı olacaktır. Örneğin, farklı park alanlarına sahip geniş havaalanlarında gerçek zamanlı olarak test yapılması veya yoğun yağış, sis gibi bahsedilen kritik durumlarda da başarımlı performansının gözlemlenmesi sistemin güvenilirliğini arttıran bir etken olacaktır.

Bu çalışmada geliştirilen akıllı park sistemi, insansız ve insanlı hava araçlarının park süreçlerini otonom hale getirmekte yardımcı olacaktır. Özellikle havaalanları gibi karmaşık ve yoğun trafiğe sahip ortamlarda bu sistemin performansını değerlendirmek, gerçek dünya uygulamalarına geçişte önemli bir adımdır. Sonuç olarak, geliştirilen akıllı park sisteminin, hava araçlarının güvenli, etkili ve otonom şekilde park edilmesini sağlayarak hem kentsel trafikte hem de havaalanı yönetiminde büyük katkı sunacağı düşünülmektedir.

TEŞEKKÜR

Bu çalışma İzmir Katip Çelebi Üniversitesi Bilimsel Araştırma Projesi (İKÇÜ BAP) tarafından 2024-TETAP-MÜMF-0004 proje numarasıyla desteklenmiştir.

Çıkar Çatışması

Makale yazarları aralarında herhangi bir çıkar çatışması olmadığını beyan ederler.

Yazar Katkısı

Yazarlar makaleye eşit oranda katkı sağlamış olduklarını beyan eder.

KAYNAKLAR

- Aldughayfiq, B., Ashfaq, F., Jhanjhi, N. Z., ve Humayun, M. (2023). YOLO-Based Deep Learning Model for Pressure Ulcer Detection and Classification. *Healthcare (Basel, Switzerland)*, 11(9), 1222. Erişim adresi: <https://doi.org/10.3390/healthcare11091222>
- Arserim, M. A. ve Usta, A. (2023). İnsansız hava aracından çekilen videolar kullanılarak derin öğrenme yaklaşımı ile nesne tespiti. *DÜMF Mühendislik Dergisi*, 14(1), 9–15. Erişim adresi: <https://doi.org/10.24012/dumf.1191160>
- Atik, M. E., Duran, Z. ve Ozgunluk, R. (2022). Comparison of YOLO Versions for Object Detection from Aerial Images. *International Journal of Environment and Geoinformatics (IJEgeo)*, 9(2), 281-290. Erişim adresi: <https://doi.org/10.30897/ijegeo.1010741>
- Boros, G. (2023). Do you know overfitting and underfitting? *Medium*. Erişim adresi: <https://medium.com/@datascienceeurope/do-you-know-overfitting-and-underfitting-f27f87ac2f37>
- Cabrera-Ponce, D. A. ve Martinez-Carranza, J. (2020). Onboard CNN-based processing for target detection and autonomous landing for MAVs. *Sensors*, 20(16), 4643. Erişim adresi: https://doi.org/10.1007/978-3-030-49076-8_19
- Carion, N., Massa, F., Synnaeve, G., Usunier, N., Kirillov, A. ve Zagoruyko, S. (2020). End-to-end object detection with transformers. *Proceedings of the European Conference on Computer Vision (ECCV)*. Erişim adresi: <https://arxiv.org/abs/2005.12872>
- Choi, D., Chhabra, A. ve Kim, D. (2022, January 3–7). Collision avoidance of unmanned aerial vehicles using fuzzy inference system-aided enhanced potential field. *AIAA SCITECH 2022 Forum*, San Diego, CA, United States. Erişim adresi: <https://doi.org/10.2514/6.2022-0272>
- Doğan, F. ve Türkoğlu, İ. (2019). Derin Öğrenme Modelleri ve Uygulama Alanlarına İlişkin Bir Derleme. *DÜMF Mühendislik Dergisi*. Erişim adresi: <https://doi.org/10.24012/dumf.411130>
- Eği, Y. (2023). YOLO V7 and computer vision-based mask-wearing warning system for congested public areas. *Journal of the Institute of Science and Technology*, 13(1), 22-32. Erişim adresi: <https://doi.org/10.21597/jist.1243233>
- Ekmen, M. İ. ve Aydoğdu, Ö. (2020). İnsansız hava araçları için görüntü işleme tabanlı otonom iniş. *Avrupa Bilim ve Teknoloji Dergisi*, 297-303. Erişim adresi: <https://doi.org/10.31590/ejosat.804502>
- Elfaki, A. O., Messoudi, W., Bushnag, A., Abuzneid, S. ve Alhmiedat, T. (2023). A smart real-time parking control and monitoring system. *Sensors*, 23, 9741. Erişim adresi: <https://doi.org/10.3390/s23249741>
- Erişti, E. (2010). Görüntü işleme ve OpenCV. *Akademik Bilişim 2010 - XII. Akademik Bilişim Konferansı Bildirileri*. Muğla Üniversitesi.
- Girshick, R. (2015). Fast R-CNN. *Proceedings of the IEEE International Conference on Computer Vision*, 1440-1448.
- Harris, D. (2015). *Decision making in aviation (1st ed.)*. Washington, DC: Routledge. Erişim adresi: <https://doi.org/10.4324/9781315095080>
- Haritaoglu, I., Harwood, D. ve Davis, L. S. (2000). Real-time surveillance of people and their activities. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 22(8), 809-830. Erişim adresi: <https://doi.org/10.1109/34.868683>

- Hussain, M. (2023). YOLO-v1 to YOLO-v8, the Rise of YOLO and Its Complementary Nature toward Digital Manufacturing and Industrial Defect Detection. *Machines*, 11(7), 677. Erişim adresi: <https://doi.org/10.3390/machines11070677>
- Jiang, P., Ergu, D., Liu, F., Cai, Y. ve Ma, B. (2022). A review of YOLO algorithm developments. *Procedia Computer Science*, 199, 1066–1073. Erişim adresi: <https://doi.org/10.1016/j.procs.2022.01.135>
- Jocher, G., Qiu, J. ve Chaurasia, A. (2023). Ultralytics YOLO (Version 8.0.0) [Computer software]. Erişim adresi: <https://github.com/ultralytics/ultralytics>
- Kaggle. (2024). Datalagi Dataset [Veri seti]. Erişim adresi: <https://www.kaggle.com/datasets/papalagiuavteam/datalagi>
- Karaköse, E. ve Aksu, M. (2024). İnsansız hava araçlarında nokta bulutu verisi kullanılarak iniş pisti uygunluk analizi. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 36(2), 535-551. Erişim adresi: <https://doi.org/10.35234/fumbd.1393959>
- Kılıç, Ö., Aydemir, M. ve Öztürk Özdemir, P. (2022). Uçak görüntülerinin sınıflandırılmasında farklı yapay zekâ algoritmalarının performansı. *SETSCI Conference Proceedings*, 14, 84-88. Erişim adresi: <https://doi.org/10.36287/setsci.5.2.018>
- Kunduracioğlu, İ. ve Paçal, İ. (2024). Deep Learning-Based Disease Detection in Sugarcane Leaves: Evaluating EfficientNet Models. *Journal of Operations Intelligence*, 2(1), 321-235. Erişim adresi: <https://doi.org/10.31181/jopi21202423>
- LeCun, Y., Bengio, Y. ve Hinton, G. (2015). Deep learning. *Nature*, 521, 436–444. Erişim adresi: https://www.researchgate.net/publication/277411157_Deep_Learning
- Liu, C., Meng, F., Zhu, Z. ve Zhou, L. (2023). Object detection of UAV aerial image based on YOLOv8. *Frontiers in Computing and Intelligent Systems*, 5(3), 46–50. Erişim adresi: <https://doi.org/10.54097/fcis.v5i3.13852>
- Liu, W., Anguelov, D., Erhan, D., Szegedy, C., Reed, S., Fu, C. Y. ve Berg, A. C. (2016). SSD: Single shot multibox detector. *Proceedings of the European Conference on Computer Vision*, 21-37.
- MakeSense. (2024). MakeSense Annotation Tool [Online araç]. Erişim adresi: <https://www.makesense.ai>
- McManamon, P. (2015). *Field guide to LiDAR*. Washington, DC: SPIE Press.
- Pacal, İ. (2022). Deep Learning Approaches for Classification of Breast Cancer in Ultrasound (US) Images. *Journal of the Institute of Science and Technology*, 12(4), 1917-1927. <https://doi.org/10.21597/jist.1183679>
- Pacal, I. (2023). Göğüs Röntgeni Görüntülerinden Otomatik COVID-19 Teşhisi için Görü Transformatörüne Dayalı Bir Yaklaşım. *Journal of the Institute of Science and Technology*, 13(2), 778-791. <https://doi.org/10.21597/jist.1225156>
- Pacal, I., & Alaftekin, M. (2023). Türk İşaret Dilinin Sınıflandırılması için Derin Öğrenme Yaklaşımları. *Journal of the Institute of Science and Technology*, 13(2), 760-777. <https://doi.org/10.21597/jist.1223457>
- Paszke, A., Gross, S., Massa, F., Lerer, A., Bradbury, J., Chanan, G., ... ve Chintala, S. (2019). PyTorch: An imperative style, high-performance deep learning library. *Advances in Neural Information Processing Systems*, 32, 8026-8037.
- Redmon, J., Divvala, S., Girshick, R. ve Farhadi, A. (2016). You only look once: Unified, real-time object detection. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 779-788.

- Ren, S., He, K., Girshick, R. ve Sun, J. (2015). Faster R-CNN: Towards real-time object detection with region proposal networks. *Proceedings of the 28th International Conference on Neural Information Processing Systems*, 91-99.
- Roboflow. (2024). Aerial Maritime Drone Dataset [Veri seti]. Erişim adresi: <https://public.roboflow.com/object-detection/aerial-maritime>
- Roboflow. (2024). CarPK Dataset [Veri seti]. Erişim adresi: <https://universe.roboflow.com/elpida-eleftheriadi/carpk-xk8e1>
- Roboflow. (2024). VAID Dataset [Veri seti]. Erişim adresi: <https://universe.roboflow.com/chandler-sun/vaid-mnnde>
- Roboflow. (2024). Vehicle Detection from Satellite [Veri seti]. Erişim adresi: <https://universe.roboflow.com/chargepoly/vehicle-detection-from-satellite>
- Roboflow. (2024). PKLot dataset [Veri seti]. Erişim adresi: <https://public.roboflow.com/object-detection/pklot>
- Shen, S., Yu, G., Zhang, L., Yan, Y. ve Zhai, Z. (2025). LandNet: Combine CNN and Transformer to Learn Absolute Camera Pose for the Fixed-Wing Aircraft Approach and Landing. *Remote Sensing*, 17(4), 653. Erişim adresi: <https://doi.org/10.3390/rs17040653>
- Shorten, C. ve Khoshgoftaar, T. M. (2019). A survey on image data augmentation for deep learning. *Journal of Big Data*, 6, 60. Erişim adresi: <https://doi.org/10.1186/s40537-019-0197-0>
- Tan, L., Huangfu, T., Wu, L. ve Chen, W. (2021). Comparison of YOLO v3, Faster R-CNN, and SSD for real-time pill identification. *Research Square*. <https://doi.org/10.21203/rs.3.rs-668895/v1>
- Taşyürek, M. ve Gül, E. (2023). Nesne Tespitinde En Uygun Modelin Seçimi İçin Görüntüler Üzerinde Evrişimli Sinir Ağları ile Çekişmeli Saldırı Tespiti. *Journal of the Institute of Science and Technology*, 13(4), 2353-2363. Erişim adresi: <https://doi.org/10.21597/jist.1281262>
- Tekin, A. ve Bozkır, A. S. (2024). Enhance or Leave It: An Investigation of the Image Enhancement in Small Object Detection in Aerial Images. *Journal of the Institute of Science and Technology*, 14(1), 8-17. Erişim adresi: <https://doi.org/10.21597/jist.1328255>
- Vezıroğlu, E., Pacal, I., & Coşkunçay, A. (2023). Derin Evrişimli Sinir Ağları Kullanılarak Pirinç Hastalıklarının Sınıflandırılması. *Journal of the Institute of Science and Technology*, 13(2), 792-814. <https://doi.org/10.21597/jist.1265769>
- Wang, W. ve Ma, J. (2024). Applications of machine learning and deep learning in aerospace engineering and aero-engine engineering. *Advances in Engineering Innovation*, 6(1), 54-72. Erişim adresi: <https://doi.org/10.54254/2977-3903/6/2024060>
- Wang, Z., Wu, Y. ve Niu, Q. (2020). Multi-sensor fusion in automated driving: A survey. *IEEE Access*, 8, 2847-2868. Erişim adresi: <https://doi.org/10.1109/ACCESS.2019.2962554>
- Yılmaz, H. A. ve Kutbay, M. A. (2024). YOLOv8-based drone detection using hyperparameter optimization and data augmentation techniques. *Computers*, 13(2), 234. Erişim adresi: <https://doi.org/10.3390/computers13020234>