

Flying Objects Classification Using Pretrained Model

İrem Hatice DOĞAN^{1*} 

¹ Department of Computer Engineering, Iskenderun Technical University, Hatay, Türkiye.
iremdogan.lee24@iste.edu.tr

ABSTRACT

The accurate and rapid classification of flying objects is of great importance in the field of aviation for security, traffic management, and defense applications. In this study, pre-trained deep learning models were utilized for the classification of objects such as birds, airplanes, helicopters, parachutes, and drones. The models used include AlexNet, EfficientNet-B0, MobileNetV2, and ResNet18. These models were structured using the transfer learning method, where only the final classification layer was trained, and they were trained for 10 epochs. This approach integrated the powerful feature extraction capabilities of the pretrained models into the classification process. The performance of the models was evaluated on the test dataset, and their accuracy rates were compared. The highest test accuracy of 99.10% was achieved by the EfficientNet-B0 model, followed by MobileNetV2 with 98.74% accuracy, and ResNet18 and AlexNet both with 96% accuracy. Furthermore, additional performance analyses were conducted by classifying the feature vectors obtained from the intermediate layers of the pretrained models using traditional machine learning algorithms (K-Nearest Neighbors, Support Vector Machines, Multi-Layer Perceptron, Random Forest, and Decision Tree). The dataset used in the study is an original dataset created from images collected from Kaggle, Roboflow, Google, and various search engines.

ARTICLE INFO

Received 19.10.2025,
Accepted 19.11.2025,
Available online 20.11.2025
Publication Date 20.11.2025

Keywords:

Earthquake, Survey,
Incorrect Information,
Disaster, Iskenderun

Distributed Under CC-BY 4.0



*Corresponding Author: İrem Hatice DOĞAN, E-mail: iremdogan.lee24@iste.edu.tr

Önceden Eğitilmiş Modeller Kullanılarak Uçan Objelerin Sınıflandırılması

ÖZET

Uçan cisimlerin doğru ve hızlı bir şekilde sınıflandırılması, havacılık alanında güvenlik, trafik yönetimi ve savunma uygulamaları açısından büyük önem taşımaktadır. Bu çalışmada, kuş, uçak, helikopter, paraşüt ve dron cisimlerin sınıflandırılması amacıyla, önceden büyük veri kümeleri üzerinde eğitilmiş (pretrained) derin öğrenme modellerinden yararlanılmıştır. Kullanılan modeller arasında AlexNet, EfficientNet-B0, MobileNetV2 ve ResNet18 yer almakta olup, bu modeller transfer öğrenme yöntemiyle yalnızca son sınıflandırma katmanı eğitilecek şekilde yapılandırılmış ve 10 epoch boyunca eğitilmiştir. Böylece pretrained modellerin güçlü öznetelik çıkarım yetenekleri sınıflandırma sürecine entegre edilmiştir. Modellerin performansı test veri kümesi üzerinde değerlendirilmiş ve doğruluk oranları karşılaştırılmıştır. En yüksek test doğruluğu %99,10 ile EfficientNet-B0 modeli tarafından elde edilmiş; bunu %98,74 doğruluk oranı ile MobileNetV2 ve %96 doğruluk oranlarıyla ResNet18 ve AlexNet takip etmiştir. Ayrıca pretrained modellerin ara katmanlarından elde edilen öznetelik vektörleri, geleneksel makine öğrenmesi algoritmaları (K-En Yakın Komşu, Destek Vektör Makineleri, Çok Katmanlı Algılayıcı, Rastgele Orman ve Karar Ağacı) ile sınıflandırılarak ek performans analizleri yapılmıştır. Çalışmada kullanılan veri seti ise Kaggle, Roboflow, Google ve çeşitli arama motorlarından toplanan görsellerle oluşturulmuş özgün bir veri kümesidir.

MAKALE BİLGİSİ

Keywords:

Nesne Sınıflandırması,
Pretrained Modeller,
Görüntü İşleme.

Distributed Under CC-BY 4.0



GİRİŞ

Günümüzde hava sahasında farklı türde uçan nesnelerin yaygınlaşmasıyla birlikte, bu nesnelerin otomatik olarak tespit edilip sınıflandırılması önemli bir araştırma alanı haline gelmiştir. İnsansız hava araçları (drone), helikopterler, uçaklar, kuşlar ve paraşütler gibi nesnelerin benzer görsel özelliklere sahip olması, özellikle uzaktan algılama sistemleri için sınıflandırma sürecini zorlaştırmaktadır. Bu zorluk, güvenlik, hava trafik kontrolü, gözetim sistemleri ve çevresel izleme gibi pek çok uygulama açısından kritik öneme sahiptir [1], [3].

İnsansız hava aracı/kuş tespiti ve sınıflandırması, farklı boyut, hız ve davranışlara sahip bu nesnelerin benzerlikleri nedeniyle zorlu bir görev olarak kabul edilmektedir [makale3]. Küçük İHA'ları otomatik olarak tespit edip tanımlayacak etkili tekniklerin benimsenmesi, hem kamu hem de özel sektördeki birçok paydaş için hayati öneme sahiptir [14]. Kuşlar ve dronlar gibi nesneler arasındaki farkların düşük çözünürlüklü ya da karmaşık arka plana sahip görüntülerde ayırt edilmesi güç hale gelmektedir. Uçan nesnelerin tespiti, nesne mekansal boyutları/oranları, hız farklılıkları, engellenme ve kümelenmiş arka planlar gibi değişkenler sebebiyle hâlâ teknik zorluklar içermektedir [7].

Bu nedenle klasik görüntü işleme yöntemleri çoğu zaman yetersiz kalmakta, bu sorunların üstesinden gelmek için derin öğrenme tabanlı yaklaşımlar ön plana çıkmaktadır. Özellikle önceden eğitilmiş (pretrained) modeller, sınırlı veriyle dahi yüksek performans göstererek sınıflandırma başarımını artırmaktadır [4]. Derin öğrenme ile havadan veya kara görüntülerinden nesne tespiti, son yıllarda popüler bir araştırma konusu haline gelmiş ve birçok farklı disiplinde yaygın şekilde uygulanmaya başlanmıştır [9].

Bu çalışmada, uçak, helikopter, drone, kuş ve paraşüt olmak üzere beş farklı uçan nesne sınıfı kullanılarak, farklı mimari yapı ve karmaşıklıklara sahip olan AlexNet, MobileNetV2, ResNet18 ve EfficientNet-B0 gibi yaygın olarak kullanılan dört pretrained derin öğrenme modeli tercih edilmiştir. Bu modeller, düşük hesaplama maliyeti, başarılı genel doğruluk oranları ve farklı parametre derinlikleri sayesinde transfer öğrenme için uygunlukları nedeniyle seçilmiştir. Böylece, farklı derinlik ve parametre sayısına sahip bu modellerin uçan nesne sınıflandırma performansları kapsamlı şekilde karşılaştırılmıştır. Transfer öğrenme yaklaşımıyla model eğitilmiş ve sınıflandırma doğruluğu analiz edilmiştir. Çalışmanın temel amacı, farklı türdeki uçan cisimleri görüntüler üzerinden güvenilir bir şekilde ayırt edebilen, düşük maliyetli ve yüksek doğruluklu bir yapay zeka tabanlı sınıflandırma sistemlerini karşılaştırmaktır.

Bu bağlamda çalışmada, transfer öğrenme yaklaşımıyla eğitilen derin öğrenme tabanlı sınıflandırıcıların çıktıları kullanılarak, aynı zamanda geleneksel makine öğrenmesi algoritmalarının başarımı da analiz edilmiştir. Özellikle AlexNet, MobileNetV2, ResNet18 ve EfficientNet-B0 gibi güçlü mimarilerin en son tam bağlı katmanlarından elde edilen öznitelik vektörleri çıkarılmış ve bu vektörler; K-En Yakın Komşu (k-NN), Destek Vektör Makineleri (SVM), Çok Katmanlı Algılayıcı (MLP), Random Forest ve Decision Tree gibi yaygın olarak kullanılan makine öğrenmesi sınıflayıcılarına giriş olarak verilmiştir.

Bu yöntemle derin öğrenme modellerinin temsil gücünden faydalanılırken, aynı zamanda geleneksel algoritmaların karar mekanizmalarıyla uçan nesne sınıflandırma problemi farklı bir boyutta ele alınmıştır. Her bir modelin öznitelik çıkarım kapasitesi ve buna karşılık gelen sınıflayıcı doğrulukları kıyaslanarak, sadece uçan uca derin öğrenme çözümlerinin değil, aynı zamanda hibrit yaklaşımların da bu tür görevler için potansiyel barındırdığı ortaya konmuştur. Böylece, hem düşük

donanım kaynaklarına sahip sistemlerde uygulanabilirlik hem de sınıflandırma başarımı açısından alternatif yöntemlerin karşılaştırmalı bir şekilde değerlendirilmesi sağlanmıştır.

İlk incelenen çalışma, 2022 yılında Sudharsan Ramesh tarafından gerçekleştirilmiştir ve kuşlar ile dronların ayrımında YOLOv7 nesne tanıma teknolojisinin etkinliğini değerlendirmeyi amaçlamaktadır. Bu çalışmada, YOLOv7 modeli; derin öğrenme temelli, tek geçişli (single-pass) ve unipolar bir teknik kullanılarak nesne tespiti gerçekleştirmektedir. YOLO mimarisinden türetilen bu yöntem, özellikle görüntüleri tek bir işlemde analiz etme yeteneğiyle öne çıkmaktadır. Araştırma, karmaşık çevresel koşullarda kuş ve drone nesnelerinin doğru bir şekilde ayırt edilmesini hedeflemiş ve bu bağlamda YOLOv7'nin selefi olan YOLOv5'e kıyasla sağladığı gelişmeleri ortaya koymuştur. Çalışmada kullanılan veri setleri, halka açık olarak Kaggle platformu üzerinden temin edilmiş ve iki farklı kaynağın sentezi ile model eğitimi gerçekleştirilmiştir. Detaylı bir karşılaştırmalı performans analizi sonucunda, YOLOv7 modelinin başlıca metriklerde önemli gelişmeler gösterdiği belirlenmiştir. YOLOv7 için Precision ve Recall değerleri sırasıyla 0.97 ve 0.93 olarak raporlanmıştır; bu değerler YOLOv5'in 0.918 ve 0.875 olan sonuçlarına kıyasla anlamlı bir iyileşme göstermektedir. Ek olarak, YOLOv7'nin F1 Skoru 0.99 ve ortalama doğruluk (mAP) değeri 0.973 olarak hesaplanmış; bu metrikler, YOLOv5'in sırasıyla 0.896 ve 0.904 olan sonuçlarına üstünlük sağlamaktadır [1].

İkinci çalışma, hava sahasında yer alan uçan nesnelerin —özellikle drone ve kuşların— yapay zekâ teknikleriyle tespit edilmesini amaçlamaktadır. Bu çalışmanın temel hedeflerinden biri, kuş sınıfı için yeterli sayıda örnek içeren dengeli veri setleri oluşturmak amacıyla birden fazla açık kaynak veri setinin birleştirilmesidir. Çalışmada kullanılan açık kaynaklı veri setleri [<https://anti-uav.github.io/dataset/>] bağlantısından temin edilmiştir. Bu veri setinde toplam 140 video yer almakta olup, bunlar [<https://github.com/KostadinovShalon/UAVDetectionTrackingBenchmark.git>] adresinde yer alan araçlar yardımıyla 152.567 adet kızılötesi (IR) görüntüye dönüştürülmüş ve COCO formatında anotasyonları oluşturulmuştur. Ayrıca, 77 videodan oluşan farklı bir veri seti de wosdetc@googlegroups.com adresi üzerinden erişim sağlanarak edinilmiştir. Bu videolar 105.055 adet RGB görüntüsüne dönüştürülmüş ve aynı şekilde COCO formatında anotlanmıştır. Çalışmada, derin öğrenme yaklaşımlarının yanı sıra klasik makine öğrenimi algoritmaları olan Support Vector Machines (SVM), Random Forest (RF) ve Shallow Neural Network (NN) yöntemleri de uygulanmıştır. Sınıflandırma performansları aşağıdaki gibidir:

- SVM: Accuracy 0.999, Precision 0.967, Recall 0.944 ,F1 Score 0.953
- Random Forest: Accuracy 0.9974, Precision 0.930, Recall 0.887 ,F1 Score 0.910
- Shallow Neural Network: Accuracy 0.995, Precision 0.813, Recall 0.803 ,F1 Score 0.810

Bu sonuçlara göre, en yüksek sınıflandırma başarımı Support Vector Machines (SVM) algoritmasıyla elde edilmiştir [2].

Bir diğer çalışma, kuşlar ile dronların uçuş mekaniği ve hareket davranışlarını radar izleri üzerinden analiz ederek bu nesnelerin sınıflandırılmasını hedeflemektedir. Çalışmada, hedef hareket özelliklerini temsil eden beş farklı tanımlayıcı dan oluşan bir özellik vektörü kullanılmış ve sınıflandırma modeli olarak Rastgele Orman (Random Forest) yöntemi tercih edilmiştir. Bu yöntem, havaalanı çevresine yerleştirilen kuş gözetim radarlarıyla toplanan gerçek saha verileriyle test edilmiştir. Model, kuşlar, quadcopter dronlar ve dinamik yağış koşulları gibi farklı hedef türleri arasında sınıflandırma yapmıştır. Özellikle insansız hava araçları ile yağış yörüngeleri arasındaki yanlış sınıflandırma oranı çok düşük bulunmuştur. Üç hedef türü için ortalama doğru sınıflandırma oranı %85'in üzerinde gerçekleşmiş ve bu sonuçlar, önerilen yöntemin yeterli sınıflandırma doğruluğuna ve uygulama potansiyeline sahip olduğunu göstermektedir. Ayrıca, rastgele orman modelinin Gini önem ölçütleri, hareket özelliklerinin ayırt ediciliğini değerlendirmede ek fayda sağlamaktadır [3].

Bir diğer çalışmada, kuşlar ve dronların sınıflandırılması için konvolüsyonel sinir ağı (CNN) temelli bir yöntem sunulmuştur. Bu yöntemde, mikro-Doppler spektrogram görüntülerinden elde edilen büyük ve çeşitli bir veri seti oluşturulmuş; biri RGB, diğeri gri tonlamalı olmak üzere iki ayrı görüntü veri seti hazırlanmıştır. RGB veri seti, GoogLeNet mimarisi ile eğitilirken; gri tonlamalı görüntüler, çalışmada geliştirilen özel CNN mimarisi ile işlenmiştir. Her iki veri seti, dört sınıflı (drone, kuş, karmaşa ve gürültü) ve iki sınıflı (drone ve drone değil) olarak ayrılmıştır. Eğitim sürecinde verilerin %20'si doğrulama amacıyla kullanılmış, eğitim sonrası ise daha önce görülmemiş etiketsiz verilerle test gerçekleştirilmiştir. Sonuçlara göre, geliştirilen özel mimari ile dört sınıf için doğrulama ve test doğrulukları sırasıyla %99.6 ve %94.4, iki sınıf için ise %99.3 ve %98.3 olarak elde edilmiştir. GoogLeNet modeli ise tüm sınıflandırma senaryolarında yaklaşık %99 doğruluk sağlamıştır [4].

Bu çalışma, radar sistemlerinde kullanılan makine öğrenimi temelli bir sınıflandırıcı geliştirmek amacıyla, küçük hedeflerin (örneğin drone ve kuş) yer-gerçek verilerinin Google Earth üzerinden toplanması ve görüntülenmesine dayalı bir yöntem sunmaktadır. Radar, doğruluk ve yer-doğruluk verilerinin elde edilmesinden sonra, karar ağacı tabanlı denetimli öğrenme algoritması ile iki sınıflı (drone ve drone değil) bir sınıflandırıcı geliştirilmiştir. Eğitim dosyası, radar tarafından izlenen hedeflere ait örneklerden oluşmuş ve her örnek, ilgili özellik parametreleri ile birlikte etiketlenmiştir. Özellikler arasında yükseklik, türevsel konumsal bilgiler (hız, ivme, jerk), mikro-Doppler bileşenleri sayısı, iz yaşı, hedefin radar kesit alanı (RCS) gibi anlık ve istatistiksel analizler kullanılmıştır. MATLAB ortamında "fitctree" fonksiyonu ile oluşturulan karar ağacı, k-katlı çapraz doğrulama ve budama seçenekleriyle aşırı öğrenmenin önüne geçmeyi hedeflemiştir. Sonuçlar, sınıflandırıcının %94,3 doğruluk ve %0,5 yanlış sınıflandırma oranına ulaştığını göstermiştir. Ayrıca yöntem, iki sınıflı sınırlı kalmayıp çok sınıflı sınıflandırma için de genişletilebilir niteliktedir[5].

Bu çalışma, mikro-Doppler spektrogram imzalarının kullanımıyla drone ve kuş gibi uçan hedeflerin uzaktan sınıflandırılmasına yönelik bir yaklaşım sunmaktadır. Özel olarak geliştirilen 10 GHz sürekli dalga (CW) radar sistemi aracılığıyla çeşitli senaryolarda farklı hedeflerden veri toplanmış ve bu verilerle bir görüntü sınıflandırma veri seti oluşturulmuştur. Mikro-Doppler analizleri kapsamında, birden fazla drone ve kuş türü için elde edilen zaman-hız spektrogramları, hedef tanıma ve hareket sınıflandırması amacıyla TensorFlow platformunda değerlendirilmiştir. Destek Vektör Makineleri (SVM) ile yapılan sınıflandırma analizlerinde; drone boyutlarının ayrımı için %90, kuş ve drone ayrımı için %96, beş ayrı sınıf arasında (birden fazla drone ve kuş türü) ayrım için ise yaklaşık %85 doğruluk elde edilmiştir. Veriler, toplamda 700'ün üzerinde mikro-Doppler görüntüsünden oluşan bir veri setiyle toplanmış ve sınıflandırma başarı oranları yüksek güvenilirlik seviyeleriyle raporlanmıştır. Bununla birlikte, kuş verilerinin kafesli ve doğal olmayan ortamlarda elde edilmesi, uçuş davranışlarının sınırlı gözlemlenebilmesine neden olmuş; ayrıca drone verileri sadece belirli yönlerde (radara doğru ya da radardan uzak) düz uçuş senaryolarıyla sınırlandırılmıştır. Gelecekte, daha doğal ortamlarda gözlemler, radar manevra verilerini de kapsayan genişletilmiş uçuş profilleri ve düşük güçlü SDR sistemleriyle hedef tespitin otomatikleştirilmesi gibi yönlerde iyileştirmeler planlanmaktadır. Böylece, daha etkin ve gerçek zamanlı mikro-Doppler temelli hedef tanıma sistemlerinin geliştirilmesi hedeflenmektedir[6].

Bu çalışmada, uçan cisimlerin gerçek zamanlı tespiti için YOLOv8 mimarisi kullanılarak iki aşamalı bir model geliştirilmiştir. İlk aşamada, 40 farklı uçan cisim sınıfını içeren ve sınıf dengesizliği barındıran 15.064 görüntülük geniş bir veri kümesinde eğitim yapılmış[12], bu sayede modelin soyut özellikleri öğrenmesi hedeflenmiştir. Eğitilen genelleştirilmiş model, 1080p çözünürlükte 50 FPS hızla çalışmakta olup, %79.2 mAP@50 ve %68.5 mAP@50-95 başarımına ulaşmıştır. İkinci aşamada, bu modelin ağırlıkları daha gerçekçi koşulları (küçük nesneler, uzaktan çekim, örtüşme, döndürme vb.) içeren, 11.998 görüntüden oluşan daha dengeli ve sınırlı bir veri kümesine aktarılmış [13], böylece refined (iyileştirilmiş) model elde edilmiştir. Bu model de 50 FPS hızını koruyarak %99.1 mAP@50 ve %83.5 mAP@50-95 başarımına ulaşmıştır. Sonuçlar, modelin hem genel hem de gerçek dünya senaryolarında yüksek doğrulukla çalışabildiğini ve transfer öğrenmenin etkili bir şekilde uygulandığını göstermektedir[7].

Bu çalışmada, video görüntülerine dayalı bir insansız hava aracı (İHA) tespit çerçevesi önerilmektedir. Kullanılan video kayıtlarının sabit veya hareketli kameralardan elde edilmesine bağlı olarak, öncelikle medyan arka plan çıkarımı veya derin öğrenmeye dayalı nesne öneri yöntemleri ile potansiyel nesne bölgeleri belirlenmiştir. Bu bölgeler, konvolüsyonel sinir ağı (CNN) tabanlı bir sınıflandırıcı aracılığıyla İHA, kuş veya arka plan (clutter) olarak sınıflandırılmıştır. Sınıflandırıcı eğitimi için 3.386 İHA, 3.500 kuş ve 3.500 arka plan görüntüsünden oluşan özel bir veri seti oluşturulmuştur. İHA görüntüleri hem web'den taranarak hem de yazarlar tarafından farklı uzaklık ve çözünürlüklerde toplanmıştır. Kuş görüntüleri ise kamuya açık Wild Birds in a Wind Farm veri setinden elde edilmiştir. Arka plan görüntüleri ise

farklı sahneler ve çözünürlüklerde web üzerinden toplanmıştır. Bu veri seti ile, eğitim sırasında hedef veri seti ile kaynak veri seti arasındaki alan farklılıkları dikkate alınmıştır. Sistem, kuşlar ve arka plan hareketleri içeren altı zorlu video sekansında değerlendirilmiştir. Eğitim verisinin sınırlı olduğu durumlarda, önceden eğitilmiş ağların ince ayar yapılarak kullanılmasının sınıflandırma performansını artırabileceği gösterilmiştir. Deneysel sonuçlar, özellikle 64×64 piksel giriş boyutlarında olmak üzere, yüksek doğrulukta sınıflandırma performansı elde edildiğini göstermiştir. Örneğin, 64×64 giriş boyutunda İHA sınıfı için doğruluk %99.7'ye ulaşırken, kuş sınıfında bu oran %86.4 olarak gerçekleşmiştir. Sonuçlar, giriş boyutları arttıkça sınıflandırma başarısının da iyileştiğini ortaya koymaktadır[8].

Literatürde YOLO mimarileriyle gerçekleştirilen hava görüntüsü tabanlı nesne tespiti çalışmaları da dikkat çekmektedir. Bu kapsamda yapılan bir çalışmada, DOTA (Dataset for Object Detection in Aerial Images) veri seti kullanılarak, Google Colaboratory bulut platformunda Python programlama dili ile YOLOv2 ve YOLOv3 algoritmalarının eğitimi gerçekleştirilmiştir. Değerlendirme sürecinde, büyük araç, küçük araç, uçak, liman, depolama tankı, gemi, basketbol sahası, tenis kortu ve yüzme havuzu olmak üzere dokuz farklı sınıf içeren toplam 43 hava görüntüsü kullanılmıştır. Her iki algoritmanın performansı geri çağırma, kesinlik ve F1-skora metriğine göre analiz edilmiştir. Elde edilen sonuçlara göre, YOLOv2 dokuz sınıfın beşinde daha başarılı olurken, YOLOv3 özellikle küçük nesneleri tanımda üstünlük göstermiştir. YOLOv2 ile uçak sınıfında %99 F1-skora ulaşılırken, YOLOv3 en iyi sonucu yüzme havuzu sınıfında %83 F1-skor ile vermiştir. Ayrıca, YOLOv3 ortalama 2.5 saniyelik nesne tespit süresiyle, YOLOv2'nin 43 saniyelik süresine kıyasla çok daha hızlı bir performans sergilemiştir. Bu çalışma, hem doğruluk hem de işlem süresi açısından farklı YOLO sürümlerinin hava görüntülerindeki nesne tespiti başarımını karşılaştırmalı olarak ortaya koymuştur[9].

MATERYAL VE METHOD


Veri Seti

Bu çalışmada hava nesnelerinin sınıflandırılmasına yönelik derin öğrenme tabanlı bir model eğitimi amacıyla, beş farklı sınıfa (kuş, drone, uçak, helikopter, paraşüt) ait görsel veriler toplanmıştır. Veri seti, çeşitli açık kaynaklardan manuel olarak derlenmiş ve sınıflar dengeli olacak şekilde organize edilmiştir. Öncelikli veri kaynağı olarak Kaggle platformunda yer alan "Drone vs Bird: Aerial Object Classification Dataset" [10] kullanılmıştır. Bu veri seti, özellikle kuş ve drone sınıfları için zengin ve çeşitli örnekler sunmaktadır. Ayrıca, uçak sınıfına ait görsellerin elde edilmesi için yine Kaggle üzerinde yer alan "Ticari Uçak Veri Seti" [11] kullanılmıştır.

Bunlara ek olarak, sınıf çeşitliliğini artırmak amacıyla Pexels platformundan manuel şekilde ve Google Görseller' den Selenium kütüphanesi kullanarak görseller toplanmış ve sınıflandırılmıştır.

Görsellerin seçiminde, her sınıfın gerçek dünya koşullarını yansıtacak şekilde farklı açılar, ortamlar ve çözünürlüklerde olmasına dikkat edilmiştir. Veri toplama sürecinin sonunda, toplam 11.121 etiketli görselden oluşan bir veri seti oluşturulmuştur. Bu veri seti, modelin farklı hava nesnelerini ayırt etme yeteneğini artırmak üzere çeşitli kaynaklardan elde edilen örneklerle zenginleştirilmiştir.

Şekil 1. Örnek Görseller



Veri Hazırlama

Veri kümesi üzerinde modelin daha başarılı ve genellenebilir sonuçlar verebilmesi için eğitim öncesinde çeşitli dönüşümler uygulanmıştır. Tüm mimarilerde ortak olarak kullanılan bu dönüşümler sayesinde model, farklı açılardan ve koşullardan gelen görselleri tanımda daha yetkin hale gelmiştir. Eğitim verileri üzerinde, görsellerin boyutu 224×224 olacak şekilde yeniden ölçeklendirilmiş, ardından rastgele yatay çevirme, 15 dereceye kadar döndürme, parlaklık ve kontrastta rastgele değişiklikler ile %85 ila %100 arasında rastgele kırpma işlemleri uygulanmıştır. Bu artırma yöntemleri, modelin fazla ezber yapmadan daha esnek öğrenmesini sağlamak amacıyla tercih edilmiştir. Test verileri ise yalnızca yeniden boyutlandırılmış ve tensöre dönüştürülerek modele verilmiştir.

Pretrained Modeller

Bu çalışmada, kuş, dron, helikopter, uçak ve paraşüt gibi uçan cisimlerin sınıflandırılması amacıyla yaygın olarak kullanılan dört farklı önceden eğitilmiş derin öğrenme mimarisi test edilmiştir: AlexNet, ResNet18, EfficientNetB0 ve MobileNetV2. Daha sonra her modelden

çıkarılan öznitelikler (feature vectors) çeşitli makine öğrenmesi algoritmaları ile sınıflandırılmıştır. Çıkarılan öznitelikler kullanılarak KNN, SVM, MLP, Random Forest ve Decision Tree algoritmaları ile sınıflandırma gerçekleştirilmiştir.

MobileNetV2

Çalışmada, sınıflandırma görevini gerçekleştirmek üzere önceden ImageNet veri kümesi üzerinde eğitilmiş olan MobileNetV2 mimarisi kullanılmıştır. Modelin son katmanı, problem tanımına uygun olacak şekilde 5 çıktı birimine sahip yeni bir tam bağlı katman (fully connected layer) ile değiştirilmiş ve transfer öğrenme yaklaşımıyla yalnızca son katman eğitilecek şekilde yapılandırılmıştır. Eğitim süreci 10 epoch boyunca sürdürülmüş, nihai olarak %99.08 eğitim doğruluğu ve %98.74 test doğruluğu elde edilmiştir. Modelin performansı ayrıca karışıklık matrisi (confusion matrix) ile değerlendirilmiştir.

Model eğitildikten sonra, gömülü özellik çıkarım modülü kullanılarak test verisi üzerinde öz nitelik çıkarımı (feature extraction) gerçekleştirilmiştir. Bu işlem kapsamında, son sınıflandırma katmanı hariç olmak üzere modelin geri kalan bölümü dondurularak, giriş görüntülerine karşılık gelen 1280 boyutlu ara katman temsilleri (embedding'ler) elde edilmiştir. Öznitelikler ve karşılık gelen etiketler, aşağıdaki yapıya uygun biçimde çıkarılmış ve .npy formatında kaydedilmiştir. Elde edilen bu öznitelikler daha sonra klasik makine öğrenmesi algoritmaları üzerinde kullanılmış ve sınıflandırma performansları karşılaştırılmıştır.

Table 1. Sınıflandırma performans karşılaştırması **MobileNetV2** için

Model	Accuracy	Precision (Macro)	Recall (Macro)	F1-Score (Macro)
KNN	0.82	0.86	0.75	0.77
SVM	0.89	0.86	0.86	0.86
MLP	0.90	0.89	0.88	0.89
Random Forest	0.85	0.87	0.79	0.81
Decision Tree	0.67	0.61	0.61	0.60

Precision, Recall ve F1-score değerleri "macro average" olarak hesaplanmıştır.

ResNet18

Çalışmada transfer öğrenme kapsamında kullanılan bir diğer evrimsel sinir ağı mimarisi ResNet18'dir. Bu model, görüntü sınıflandırma alanında derin yapısı ve artık bağlantıları (residual connections) ile dikkat çeken başarılı bir mimaridir. Model, PyTorch kütüphanesi aracılığıyla önceden ImageNet üzerinde eğitilmiş ağırlıklarla yüklenmiş ve son katmanı çıkarılarak öz nitelik çıkarımı amacıyla kullanılmıştır. Bu bağlamda, modelin tam bağlı katman öncesindeki çıktıları, her bir görüntünün yüksek boyutlu vektörel temsilleri olarak ele alınmıştır. ResNet18 modeli, 10 epoch boyunca eğitimden geçirilmiş ve eğitim süreci sonunda %99.33 eğitim doğruluğu ve %96.53 test doğruluğu elde

edilmiştir. Modelin performansı ayrıca karışıklık matrisi (confusion matrix) ile değerlendirilmiştir. Eğitim işlemi tamamlandıktan sonra, test veri kümesi üzerinde modelden elde edilen öznitelikler çıkarılmış ve bu öznitelikler, beş farklı klasik makine öğrenmesi algoritmasına giriş olarak verilmiştir: k-NN, SVM, MLP, Random Forest ve Decision Tree. Sınıflandırma performansları karşılaştırılmıştır.

Table 2. ResNet18 için Sınıflandırma performans karşılaştırması

Classifier	Accuracy	Precision (macro)	Recall (macro)	F1-score (macro)
KNN	0.88	0.89	0.85	0.86
SVM	0.92	0.92	0.90	0.91
MLP	0.93	0.93	0.91	0.92
Random Forest	0.88	0.90	0.85	0.86
Decision Tree	0.71	0.67	0.67	0.67

Precision, Recall ve F1-score değerleri "macro average" olarak hesaplanmıştır.

AlexNet

Bu çalışmada, önceden eğitilmiş AlexNet mimarisi kullanılarak görüntü sınıflandırma problemi ele alınmıştır. Model, transfer öğrenme yöntemiyle 10 epoch boyunca eğitilmiş ve eğitim süreci sonucunda %98.52 doğruluk ve 11.66 hata (loss) değeri elde edilmiştir. Test kümesi üzerinde yapılan değerlendirme sonucunda modelin doğruluğu %96.65 olarak hesaplanmıştır. Aşağıda modelin test kümesi üzerindeki karışıklık (confusion) matrisi verilmiştir.

Modelin derin katmanlarından elde edilen özellik temsilleri, son sınıflandırma katmanı hariç tutularak çıkarılmış ve klasik makine öğrenmesi algoritmalarıyla yeniden değerlendirilmiştir. Özellik çıkarımı işlemi sonucunda her bir test verisi için özellik vektörleri elde edilmiş, karşılık gelen etiketlerle birlikte .npy formatında saklanmıştır. Bu temsiller daha sonra çeşitli klasik sınıflayıcılar ile eğitilerek performans analizleri gerçekleştirilmiştir.

Farklı makine öğrenmesi algoritmalarının doğruluk, precision, recall ve F1-score değerleri aşağıdaki tabloda özetlenmiştir:

Table 3. AlexNet için sınıflandırma performans karşılaştırması

Classifier	Accuracy	Precision (macro)	Recall (macro)	F1-score (macro)
k-NN	0.83	0.84	0.80	0.81
SVM	0.88	0.86	0.86	0.86
MLP	0.90	0.89	0.88	0.89
Random Forest	0.83	0.83	0.78	0.80
Decision Tree	0.67	0.65	0.62	0.63

Precision, Recall ve F1-score değerleri "macro average" olarak hesaplanmıştır.

EfficientNet-B0

EfficientNet-B0 modeli, yalnızca sınıflandırma katmanının eğitildiği bir fine-tuning süreciyle, 10 epoch boyunca eğitim verisi üzerinde optimize edilmiştir. Eğitim sonucunda modelin eğitim doğruluğu %99.60 seviyesine ulaşırken, test veri kümesi üzerindeki genel doğruluk %99.10 olarak elde edilmiştir. Eğitim sırasında gözlemlenen kayıp (loss) değeri 3.45 olarak kaydedilmiştir. Her bir sınıflandırıcı için, sınıflar arasındaki ayırım yeteneğini daha iyi analiz edebilmek amacıyla karışıklık matrisleri (confusion matrix) oluşturulmuştur. Bu matrisler, sınıflar arası karışıklık oranlarını ve modelin hangi sınıflarda daha başarılı olduğunu açıkça göstermektedir.

Eğitilen EfficientNet-B0 modelinden çıkarılan öznitelikler, test veri kümesi için ayrı ayrı elde edilmiş ve .npy formatında saklanmıştır. Bu öznitelikler, geleneksel makine öğrenimi algoritmaları olan k-NN, SVM, MLP, Random Forest ve Decision Tree sınıflandırıcıları ile değerlendirilmiştir. Aşağıda, her bir sınıflandırıcının doğruluk ve diğer istatistiksel ölçütlere göre performansı özetlenmiştir.

Table 4. EfficientNet-B0 için sınıflandırma performans karşılaştırması

Classifier	Accuracy	Precision (macro)	Recall (macro)	F1-score (macro)
KNN	0.90	0.92	0.87	0.89
SVM	0.93	0.93	0.91	0.92
MLP	0.93	0.93	0.92	0.92
Random Forest	0.90	0.91	0.86	0.87
Decision Tree	0.76	0.74	0.72	0.73

Precision, Recall ve F1-score değerleri "macro average" olarak hesaplanmıştır.

SONUÇLAR ve TARTIŞMA

Bu çalışma, uçan nesnelerin (kuş, drone, helikopter, uçak, paraşüt) görüntü tabanlı sınıflandırması için farklı pretrained derin öğrenme mimarilerinin performansını karşılaştırmalı olarak analiz etmiştir. Transfer öğrenme yöntemiyle yalnızca son katmanları yeniden eğitilen AlexNet, ResNet18, MobileNetV2 ve EfficientNet-B0 modelleri; sınırlı epoch ve düşük hesaplama maliyetiyle yüksek doğruluk oranlarına ulaşmıştır. En yüksek test doğruluğu %99,10 ile EfficientNet-B0 modeli tarafından elde edilmiş; bunu %98,74 ile MobileNetV2 ve %96 civarında doğruluk oranlarıyla AlexNet ve ResNet18 modelleri izlemiştir. Ayrıca, derin modellerin öznetelik çıkarım yeteneği, geleneksel makine öğrenmesi algoritmalarıyla birleştirildiğinde %95'in üzerinde başarılı sınıflandırmalar yapılabileceği görülmüştür.

Elde edilen bulgular, pretrained modellerin uçan nesne sınıflandırma problemlerinde etkili ve uygulanabilir çözümler sunduğunu, hibrit yaklaşımların ise alternatif ve düşük maliyetli sistemler için güçlü bir seçenek olabileceğini göstermiştir. Gelecek çalışmalarda, çok modlu veri kullanımı, uzun süreli eğitim süreçleri ve gerçek zamanlı sistem uygulamalarıyla bu yaklaşımın daha ileri düzeyde geliştirilmesi önerilmektedir.

Bu çalışmada, farklı pretrained derin öğrenme mimarilerinin uçan nesne sınıflandırmadaki etkinliği transfer öğrenme yaklaşımı ile sistematik biçimde incelenmiştir. Elde edilen bulgular, EfficientNet-B0 ve MobileNetV2 gibi modern ve verimli mimarilerin, hem yüksek doğruluk hem de düşük hesaplama maliyeti sunarak bu tür sınıflandırma problemleri için güçlü adaylar olduğunu ortaya koymuştur.

Elde edilen sonuçlar göstermektedir ki, EfficientNet-B0 %99,10 test doğruluğuyla en başarılı model olmuştur. Bu yüksek performans, EfficientNet mimarisinin ölçeklendirme stratejisinin ve parametre verimliliğinin transfer öğrenme altında ne denli etkin çalıştığını kanıtlamaktadır. Özellikle sınırlı epoch sayısı ve düşük hesaplama maliyetiyle sağlanan bu başarı, modelin hava sahası gözetim sistemleri gibi gerçek zamanlı ve kaynak kısıtlı uygulamalarda kullanılabilirliğini desteklemektedir.

MobileNetV2, %98,74 test doğruluğuyla ikinci sırada yer almış ve hesaplama yükü düşük bir model olarak kaynak kısıtlı kenar cihazlar ya da gömülü sistemler için uygulanabilir bir alternatif olduğunu ortaya koymuştur. ResNet18 ve AlexNet, %96 civarındaki doğrulukları ile özellikle veri setindeki sınıf çeşitliliği ve görüntü koşullarına rağmen makul bir performans sergilemiştir; ancak bu modellerin daha eski mimari yapıları ve daha yüksek parametre yükü nedeniyle EfficientNet ve MobileNet mimarilerine göre daha düşük bir doğruluk oranına ulaştığı gözlenmiştir.

Çalışmada sadece uçtan uca derin öğrenme değil, aynı zamanda derin modellerden çıkarılan özneteliklerin geleneksel makine öğrenmesi algoritmalarıyla sınıflandırılması da incelenmiştir. Bu hibrit yaklaşımda k-NN, SVM, MLP, Random Forest ve Decision Tree algoritmalarıyla %95'in üzerinde doğruluk oranları elde edilmiş, böylece derin öğrenme modellerinden çıkarılan özelliklerin güçlü ve ayrıştırıcı bir temsil sunduğu ortaya konmuştur. Bu sonuçlar, uçtan uca derin öğrenme çözümlerine ek olarak hibrit sistemlerin de pratik ve uygulanabilir çözümler sunabileceğini göstermektedir.

Bununla birlikte, çalışma bazı sınırlılıklar da taşımaktadır. Modellerin yalnızca 10 epoch boyunca eğitilmiş olması, daha uzun eğitim süreçlerinde elde edilebilecek performans artışlarının gözlenmesini engellemiştir. Ayrıca, veri seti farklı kaynaklardan dengeli şekilde oluşturulmuş olsa da, gerçek zamanlı sistemler için gerekli olan çeşitli hava koşulları (örneğin düşük ışık, kötü hava, farklı açılar) gibi çevresel değişkenler test edilmemiştir. Gelecekte, çok modlu veri (ör. termal, radar, kızılötesi) kullanımı ve gerçek zamanlı testler ile sistemlerin saha koşullarındaki dayanıklılığı değerlendirilebilir.

Sonuç olarak, çalışma EfficientNet-B0 ve MobileNetV2 gibi modern ve hafif pretrained mimarilerin uçan nesne sınıflandırmasında yüksek doğruluk ve temsil gücü sunduğunu göstermiştir. Ayrıca hibrit yaklaşımlar, geleneksel makine öğrenmesi algoritmalarıyla derin öğrenmeden elde edilen özneliklerin güçlü bir şekilde işlenebileceğini ortaya koymuş; düşük donanım gereksinimleriyle bile başarılı sınıflandırma sistemleri geliştirilebileceğine işaret etmiştir.

KAYNAKÇA

- [1] Ramesh, S. (2023). Improvements in Aerial Object Detection: Comparing YOLOv7 with YOLOv5 for Fine Drone and Bird Detection in Volatile Environments (Doctoral dissertation, Dublin, National College of Ireland).
- [2] Zitar, R. A., Kassab, M., El Fallah, A., & Barbaresco, F. (2023). Bird/Drone Detection and Classification using Classical and Deep Learning Methods. Authorea Preprints
- [3] Liu, J., Xu, Q. Y., & Chen, W. S. (2021). Classification of bird and drone targets based on motion characteristics and random forest model using surveillance radar data. IEEE Access, 9, 160135-160144.
- [4] Rahman, S., & Robertson, D. A. (2020). Classification of drones and birds using convolutional neural networks applied to radar micro-Doppler spectrogram images. IET radar, sonar & navigation, 14(5), 653-661.
- [5] Sim, J., Jahangir, M., Fioranelli, F., Baker, C. J., & Dale, H. (2019, September). Effective ground-truthing of supervised machine learning for drone classification. In 2019 International Radar Conference (RADAR) (pp. 1-5). IEEE.
- [6] Narayanan, R. M., Tsang, B., & Bharadwaj, R. (2023). Classification and discrimination of birds and small drones using radar micro-Doppler spectrogram images. Signals, 4(2), 337-358.
- [7] Reis, D., Kupec, J., Hong, J., & Daoudi, A. (2023). Real-time flying object detection with YOLOv8. arXiv preprint arXiv:2305.09972.
- [8] Schumann, A., Sommer, L., Klatte, J., Schuchert, T., & Beyerer, J. (2017, August). Deep cross-domain flying object classification for robust UAV detection. In 2017 14th IEEE International Conference on Advanced Video and Signal Based Surveillance (AVSS) (pp. 1-6). IEEE.
- [9] Atik, M. E., Duran, Z., & Özgünlük, R. (2022). Comparison of YOLO versions for object detection from aerial images. International journal of environment and geoinformatics, 9(2), 87-93.
- [10] Drone ve Kuş: Hava Nesnesi Sınıflandırma Veri Seti:
<https://www.kaggle.com/datasets/muhammadsaoodsarwar/drone-vs-bird>
- [11] Ticari Uçak Veri Seti
<https://www.kaggle.com/datasets/nelyg8002000/commercial-aircraft-dataset>

-
- [12] new-workspace dataset. 0k81p. f lying object dataset https://universe.roboflow.com/new-workspace-0k81p/flying_object_dataset, mar 2022. visited on 2023-05-03. 2, 5
- [13] AhmedMohsen. drone-detection-new dataset. <https://universe.roboflow.com/ahmedmohsen/drone-detection-new-peksv>, apr 2022. visited on 2023-05-03. 2, 6
- [14] Coluccia, A., Fascista, A., Schumann, A., Sommer, L., Dimou, A., Zarpalas, D., ... & Rajashekar, S. (2021). Drone vs. bird detection: Deep learning algorithms and results from a grand challenge. *Sensors*, 21(8), 2824.