



Kahramanmaraş Sütçü İmam University

Journal of Engineering Sciences



Geliş Tarihi : 07.05.2022
Kabul Tarihi : 11.08.2022

Received Date : 07.05.2022
Accepted Date : 11.08.2022

MEKANSAL PİRAMİT HAVUZLAMA TABANLI EVRİŞİMLİ SİNİR AĞI İLE OTOMATİK DRONE SINIFLANDIRMA

AUTOMATED DRONE CLASSIFICATION WITH A SPATIAL PYRAMID POOLING-BASED CONVENTIONAL NEURAL NETWORK

Deniz KORKMAZ¹* (ORCID: 0000-0002-5159-0659)
Hakan AÇIKGÖZ² (ORCID: 0000-0002-6432-7243)

¹ Malatya Turgut Özal Üniversitesi, Elektrik-Elektronik Mühendisliği Bölümü, Malatya, Türkiye

² Gaziantep İslam Bilim ve Teknoloji Üniversitesi, Elektrik-Elektronik Mühendisliği Bölümü, Gaziantep, Türkiye

*Sorumlu Yazar / Corresponding Author: Deniz KORKMAZ, deniz.korkmaz@ozal.edu.tr

ÖZET

Hava sahalarının önemli olduğu bölgelerde dronları tespit etmek zorlu bir konu haline gelmiştir. Bu insansız hava araçlarının kontrolsüz uçuşları ve konuşlanmaları da istenmeyen bölgelerde çeşitli güvenlik sorunlarına sebep olur. Bu çalışmada, dronları kuşlardan ayırarak etkili bir şekilde sınıflandırabilmek için bir evrişimli sinir ağı (ESA) modeli önerilmiştir. Önerilen model, ön eğitilmiş AlexNet ile mekansal piramit havuzlama (MPH) yapısı kullanılarak tasarlanmıştır. Böylece, ağı evrişimsel katmanlarından gelen yerel öznitelikler birleştirilerek ağı nesne özelliklerini daha kapsamlı bir şekilde öğrenmesi sağlanmış ve önerilen modelin sınıflandırma performansı artırılmıştır. Ayrıca, eğitim görüntülerinde çevrimdışı veri artırma tekniği uygulanarak örnek sayısı artırılmıştır. Önerilen yöntemin performansı AlexNet, ShuffleNet, GoogLeNet ve DarkNet gibi sıklıkla kullanılan ön eğitilmiş ESA mimarileri ile karşılaştırılmıştır. Gerçekleştirilen deneysel çalışmalarda önerilen yöntemin doğruluk, kesinlik, duyarlılık, özgüllük ve F1-skor değerleri sırasıyla %98.89, %97.83, %100, %97.78 ve %98.90 olarak elde edilmiştir. Çalışmada elde edilen tüm sonuçlar incelendiğinde, önerilen yöntemin farklı ortamlara ait drone görüntülerini kuşlardan ayırarak başarıyı yüksek bir şekilde sınıflayabildiğini ortaya koymaktadır.

Anahtar Kelimeler: Drone sınıflandırma, evrişimli sinir ağları, mekansal piramit havuzlama, derin öğrenme

ABSTRACT

Detecting drones in areas with important airspace has become a challenging issue. Uncontrolled flights and deployments of these unmanned aerial vehicles also cause various security problems in undesirable areas. In this study, a convolutional neural network (CNN) model is proposed to effectively classify drones by distinguishing them from birds. The proposed model is designed using a spatial pyramid pooling (SPP) structure with pre-trained AlexNet. Therefore, by combining the local features from the convolutional layers, the network is enabled to learn the object properties more comprehensively and the classification performance of the proposed model is increased. In addition, the number of samples is increased by applying the offline data augmentation technique to the training images. The performance of the proposed method is compared with frequently used pre-trained CNN architectures such as AlexNet, ShuffleNet, GoogLeNet, and DarkNet. In the experimental studies, the accuracy, precision, sensitivity, specificity, and F1-score values of the proposed method are obtained as 98.89%, 97.83%, 100%, 97.78%, and 98.90%, respectively. When all obtained results are examined, it is revealed that the proposed method can classify drone images and birds in different environments with high performance.

Keywords: Drone classification, convolutional neural networks, spatial pyramid pooling, deep learning

GİRİŞ

Teknolojik gelişmeler, havacılık sektöründe birçok olumlu gelişmenin yaşanmasına sebep olmuş ve farklı amaçlarda kullanılmak üzere çeşitli insansız hava araçları (İHA) üretilmeye başlanmıştır. Drone olarak adlandırılan küçük boyutlu İHA'lar gelişmiş elektronik, kontrol ve iletişim teknolojileri ile donatılmaktadır. Bu teknolojilerin sağladığı haberleşme yetenekleri ile dronlar çeşitli alanlarda ilerlemeyi de beraberinde getirmeye başlamıştır (Uddin vd., 2020). Dronlar genel olarak sinematografi, çiftçilik, gözetleme, denetim ve eğlence alanlarında sıklıkla kullanılırken son zamanlarda afet ve ilkyardım gerektiren durumlarda gözetleme ile askeri alanlarda da kullanılmaktadır (Basak vd., 2022; Lykou vd., 2020; Hassanalıan & Abdelkefi, 2017). Sivil Havacılık Genel Müdürlüğü'nün (SHGM) 2020 verilerine göre, ülkemizde kayıtlı olan drone sayısı 39 bini geçmiş iken Amerika Federal Havacılık İdaresi'nin 2021 kayıtlarına göre ABD'de 368 binden fazla insansız uçak sistemi veya drone bulunmaktadır (Sivil Havacılık Genel Müdürlüğü, 2022; Singha & Aydın, 2021). Bu veriler, drone endüstrisinin ülkemizde ve dünyada hızla geliştiğini ve drone sistemlerinin daha erişilebilir bir hal aldığı göstermektedir.

Dronların çok çeşitli uygulama alanları olmasına rağmen, kontrolsüz uçuşları ve konuşlanmaları ciddi güvenlik sorunlarına neden olabilir (Kim vd., 2021; Uddin vd., 2020). Dronların, nispeten yavaş hızları ve düşük uçuş irtifaları nedeniyle tespit edilmesi güçtür. Alçak irtifa gözetleme radarları, uzun menzilli İHA'ları izlemek için uygun bir teknik çözüm olarak kabul edilmektedir. Bu radarlar, yavaş hareket eden hedefler için gerekli olan yüksek hassasiyeti sağlayabilir ve yenileme hızının etkin bir şekilde bekleme süresi tarafından ayarlandığı durumlarda, sürekli veri sağlama ve tüm hava koşullarında operasyonel işlevsellik gibi avantajlara sahiptir. Bununla birlikte, geleneksel hedeflerin aksine, dronlar küçük boyutludur ve metalik olmayan malzemelerden yapılabilir. Bu durumda, küçük radar kesit değerleri oluşur ve düşük uçuş irtifaları nedeniyle çok düşük radar algılanabilirliği meydana gelir. Ayrıca yüksek duyarlılığın bir sonucu olarak, düşük radar kesitleri diğer yavaş hareket eden hedeflerin algılanmasına sebep olur. Dronlara en yakın radar benzerliklerini ise kuşlar göstermektedir. Dronların ve kuşların radar kesitleri arasındaki bu benzerlik, kuşların genellikle drone gözetim perspektifinden kafa karıştırıcı bir hedef olarak görülmesi anlamına gelir (Dale vd., 2022; Liu vd., 2021; Coluccia vd., 2020). Böylece, kuşlar dronlara ek olarak başlıca düşük hızlı ve küçük boyutlu benzer hedefler haline gelir. Konumsal karmaşa, sinyal yansıma etkileri ve yağışlardan kaynaklanan parazitler de, drone hedeflerini kuşlardan ayırarak belirlenmesindeki zorluğu arttırmaktadır (Liu vd., 2021). Bu nedenle, dronların ve kuşların statik ve dinamik dağılımı gibi çevresel faktörler arasında etkili ve otomatik bir gözetleme sistemi ile tespiti ve sınıflandırılması önemli bir konu haline gelmiştir (Wojtanowski vd., 2021; Zhang vd., 2020; Taha & Shoufan, 2019).

Literatürde, dronların tespit edilmesi ve sınıflandırılması üzerine yapılan çalışmalar son zamanlarda ivme kazanmaya başlamıştır. Anwar ve ark. (2019) gürültülü bir ortamda kuşlar, uçaklar ve gök gürültülü fırtınalar gibi çeşitli ses sinyallerinden amatör drone sinyallerinin tespiti ve sınıflandırılması için bir makine öğrenme yaklaşımı sunmuşlardır. Sınıflandırıcı olarak DVM yöntemi kullanılmış ve %96.70 doğruluk elde edilmiştir. Uddin ve ark. (2020) akustik sinyaller yardımıyla kuşların, uçakların, gök gürültülü fırtınaların, yağmurun, rüzgârın ve İHA'ların seslerini tespit etmek için bağımsız bileşen analizini ile verimli bir denetimsiz makine öğrenimi yaklaşımı geliştirmişlerdir. Yöntemde, Mel Frekans Cepstral katsayıları, güç spektral yoğunluğu ve güç spektrum analizi ile ortalama kare değeri gibi öznitelikler çıkartılmıştır. Zhang ve ark. (2020) ise tüm hava şartlarında daha iyi sonuçlar elde etmek için klasik etkileşimli çoklu model izleme filtresi ve yinelenen sinir ağlarını (YSA) uzun kısa süreli bellek (UKSB) ile birleştirerek yeni bir yaklaşım önermişlerdir. Çoklu model izleme filtresi hedef dronun uçuş yörüngesinin kinematik öznitelikleri elde edilmiş ve geliştirilen ağ ile uçuş yörüngeleri öğrenilmiştir. Liu ve ark. (2021) radar izlerinden hedef hareket karakteristikleri çıkartarak bir kuş ve drone sınıflandırma yöntemi önermişlerdir. Yöntemde, rastgele orman sınıflandırıcısı kullanılmıştır ve elde edilen sonuçlar havalimanı bölgesinde konuşlandırılmış gerçek kuş gözetleme radar sistemleri ile doğrulanmıştır. Başka bir çalışmada, Wojtanowski ve ark. (2021) 5 kg'dan daha hafif dronlar için lazer taramaya dayalı dronları kuşlardan ayırt etme yöntemi sunmuşlardır. Belirtilen yöntem, algılanan nesne üzerinde lazer geri saçılmasının bir sonucu olarak alınan optik yankının basit çapraz polarizasyon oranı analizine dayanmaktadır. Basak ve ark. (2022) sinyal frekans imzalarını kullanarak radyo frekansı (RF) tabanlı drone algılama ve sınıflandırma yöntemi geliştirmişlerdir. Çalışmada, ticari dronları kullanarak yeni bir RF veri seti oluşturulmuş ve iki aşamalı birleşik algılama ve sınıflandırma çerçevesi arasında karşılaştırmalar sunulmuştur. Sonuçlar, YOLO derin ağının eşzamanlı çoklu sinyal senaryosu için spektrum algılamasına kıyasla daha iyi algılama performansı sağladığını göstermiştir. Diğer bir çalışmada, Kılıç ve ark. (2022) radyo frekansı (RF) sinyallerini kullanarak 2, 4 ve 10 sınıflı drone sınıflandırma performanslarını incelemişlerdir. Bu amaçla, RF sinyallerinin spektral öznitelikleri çıkartılarak destek vektör makinası (DVM) ile drone türleri sınıflandırılmış ve 10 sınıf için %95.15 doğruluk elde edilmiştir. Yukarıda bahsi geçen çalışmalar incelendiğinde, küçük boyutlu İHA'ların ve

kuşların genellikle ayırt etmeyi zorlaştıran temel özelliklere sahip olmaları, radar sinyalleri ile sınıflandırılmalarının zorlu bir yöntem olduğunu göstermektedir. Akustik sinyallerin analizinde ise algılama menzilleri yaklaşık olarak 250 m'nin altında kalmaktadır ve bu sistemlerin özellikle kentsel veya gürültülü alanlarda veya rüzgâr koşullarında çevresel gürültüye duyarlılığı algılama performansını olumsuz yönde etkiler (Seidaliyeva vd., 2020). Ayrıca, çeşitli sinyal işleme yöntemlerini içeren ön işleme süreçleri de geliştirilen yöntemlerin karmaşıklığını artırmaktadır.

Evrişimli sinir ağları (ESA) mimarileri, kendi kendine öğrenme yetenekleri ve üstün performansları ile görsel algıya dayalı drone sınıflandırma yaklaşımlarında umut vaat eden çözümler sunabilir. ESA'ya dayalı yöntemler, nesnelere algılamak için derin üst düzey öznelikler çıkararak hedeflenen sınıfları oldukça etkili tahmin edebilirler (Coluccia vd., 2021; Singha & Aydin, 2021). Literatürde, dronların tespit edilmesi ve sınıflandırılması için görüntü tabanlı yaklaşımlar son zamanlarda yer almaya başlamıştır. Oh ve ark. (2019) ise görüntü tabanlı drone ve kuş sınıflandırmada ön eğitilmiş AlexNet, GoogLeNet, Inception-V3 VGG-16, ResNet-18, ResNet-50 ve SqueezeNet mimarilerinin performanslarını incelemiştir. Elde edilen sonuçlarda, AlexNet ve VGG-16 modellerinin %98.53 ve %97.84 doğruluk ile diğer mimarilerden nispeten daha iyi performanslar verdiğini göstermiştir. Grac ve ar. (2020) görüntülerden dronların tespit edilmesi için görüntü işleme yöntemleri kullanmışlar ve %97.30 doğruluk elde etmişlerdir. Seidaliyeva ve ark. (2020) gerçek zamanlı olarak drone tespiti için etkili bir yöntem geliştirmişlerdir. Yöntemde, hareketli nesnelere algılanması ve algılanan nesnenin drone, kuş ve arka plan olarak sınıflandırılması sağlanmıştır. Hareketli nesne algılama arka plan çıkarmaya dayanırken, sınıflandırıcı için ESA yapısı kullanılmıştır. Elde edilen sonuçlar incelendiğinde, %70.10 kesinlik ve %74.20 F1 değerlerine ulaşıldığı görülmüştür. Coluccia ve ark. (2021) ise arka ve ön planda yer alan hareketli kuşların ve diğer nesnelere yer aldığı görüntülerde drone ve kuşları sınıflamak için bir veri seti sunmuşlar ve derin öğrenme algoritmaları ile sınıflandırıcı performanslarını incelemiştir ve ortalama %80 gradyan değerine ulaşmışlardır. Literatürde yer alan bu çalışmalar incelendiğinde, farklı operasyonel koşullar için derin öğrenme yöntemleri kullanılarak dronların ve kuşların görsel olarak sınıflandırılmasının etkili ve hızlı çözümler getirebileceği görülmektedir.

Bu çalışmada, drone ve kuşları doğru ve hızlı bir şekilde sınıflandırmak için derin öğrenme tabanlı otomatik bir görsel algılama yöntemi geliştirilmiştir. Bu kapsamda, transfer öğrenme yaklaşımı kullanılarak AlexNet tabanlı bir ESA mimarisi tasarlanmıştır. Çok seviyeli özneliklerin elde edilebilmesi için ESA mimarisinde bir dizi sabit uzunluklu öznelik vektörü oluşturabilen mekansal piramit havuzlama (MPH) yöntemi kullanılmıştır. MPH yöntemi, çok seviyeli havuzlama işlemlerini gerçekleştirerek önerilen modelin çok boyutlu eğitilmesini ve geliştirilmiş ölçekleme özelliklerini kazanmasını sağlamaktadır. Çalışmada, halka açık veri setleri ve internet ortamından rastgele seçilen görüntüler birleştirilerek oluşturulan bir veri seti kullanılmıştır. Ayrıca, sınıflardaki örnek sayısının yetersizliğini gidermek için görüntülerde çevrimdışı veri artırma tekniği uygulanmıştır. Önerilen yöntemin değerlendirilmesinde, elde edilen sonuçlar bazı etkili ön eğitilmiş ESA mimarileri ile karşılaştırılmıştır. Çalışmada elde edilen sonuçlar, geliştirilen MPH tabanlı ESA mimarisinin farklı ortamlardaki görüntülerden drone ve kuşları etkili ve başarıyı yüksek bir şekilde ayırt ederek sınıflayabildiğini göstermektedir. Çalışmanın geri kalan kısmı; kullanılan veri seti, uygulanan yöntemler, elde edilen bulgular, bulgular doğrultusunda tartışma ve sonuç bölümlerinden oluşmaktadır.

MATERYAL VE YÖNTEM

Drone ve kuşlar arasında uçuş hızları ve radar imzaları büyük benzer özellikler gösterse de, görsel gözlem açısından farklılıklar bulunmaktadır. Bu çalışmanın temel amacı, güvenlik problemleri teşkil edebilecek yerlerde hava sahasını otomatik olarak kontrol edilebilmek için dronları kuşlardan ayırabilen akıllı bir drone sınıflama modelinin geliştirilmesidir. Önerilen model MPH tabanlı bir ESA yapısına dayanmaktadır. MPH yöntemi, kayan pencere havuzlaması yerine çok seviyeli havuzlama yapısını kullanır ve sabit boyuttaki öznelik vektörlerinde rastgele boyutlu özellik haritalarını bir araya getirerek ağırlı sınıflama başarımını artıran etkili bir yaklaşımdır (Yee vd., 2022; Basbug & Sert, 2019). Bu bölümün devamında çalışmada kullanılan veri seti, önerilen MPH tabanlı ESA modeli ve veri artırma yöntemi ayrıntılı olarak açıklanmaktadır.

Kullanılan Veri Seti

Son zamanlarda, teknolojik gelişmeler ve düşük maliyetler sayesinde farklı rotor yapılarına ve boyutlara sahip drone sistemleri geliştirilmiştir. Dronlara en yakın radar benzerliğine sahip kuşlar ise binlerce çeşit türe ayrılmaktadır. Bu nedenle, çalışmanın genelleştirme yeteneğini artırmak için farklı drone ve kuş türlerini içeren halka açık erişimli 2 adet veri seti kullanılmıştır (Jamil, 2022; Walia, 2022). Ayrıca, bu veri setlerindeki gerçek ortamları ve fiziksel yapıyı temsil etmeyen görüntüler oluşturulan veri setinden çıkarılmıştır.

Sınıflara ait dağılımın düzensizliğini ortadan kaldırmak için internet ortamından farklı ortamlara ait yeni örnek görüntüler eklenerek eşit sayıda sınıf dağılımı da sağlanmıştır. Belirtilen şekilde oluşturulan veri setinde 300 drone sınıfını ve 300 kuş sınıfını temsil eden toplam 600 görüntü yer almaktadır. Görüntüler farklı açıları, ortamları ve türleri içeren sınıf örneklerinden oluşmaktadır. Veri setinde, 1553×1021, 275×183, 1280×720 ve 1068×1075 gibi piksel boyutlarında birçok farklı çözünürlükte görüntü bulunmaktadır. Sonuç olarak, farklı hava koşullarında drone ve kuşların uçtuğu çok çeşitli ortamlar ve çeşitli sınıf türlerine ait görüntüler kullanılarak yeni bir veri seti elde edilmiştir. Şekil 1’de veri setinde yer alan farklı örnek görüntüler gösterilmektedir.



Şekil 1. Sınıfları Temsil Eden Örnek Görüntüler

Mekansal Piramit Havuzlama Tabanlı ESA Modeli

AlexNet mimarisi, görüntü işleme problemlerinde sıklıkla kullanılan ön eğitilmiş ESA modellerinden biridir. Bu mimari, Alex Krizhevsky tarafından önerilmiş ve 2012 yılında ImageNet yarışmasında yaklaşık bir milyon görüntü ile eğitilerek 1000 sınıflı bir veri seti için oldukça etkili sonuçlar elde etmiştir (Li vd., 2021). AlexNet, özellikle üstün genelleme performansı, hızlı eğitim süresi ve yüksek dayanıklılık gibi özelliklere sahiptir. Bu çalışmada, belirtilen özellikler dikkate alınarak AlexNet modeline MPH katmanı eklenmiş ve etkili bir ESA modeli tasarlanmıştır.

AlexNet mimarisi genel olarak evrişim, havuzlama ve tam bağlı katmanlardan oluşur ve bu katmanlar, beş adet evrişim, yedi adet aktivasyon, üç adet havuzlama ve üç adet tam bağlı (TB) katmanları içermektedir. Evrişim katmanları sırasıyla 11×11, 5×5 ve 3×3 boyutunda filtrelerden oluşurken havuzlama katmanları adım sayısı 2 olan 1×1 boyutunda filtrelerden meydana gelir. Evrişim katmanlarından sonra, düzeltilmiş doğrusal birim (ReLU) aktivasyon fonksiyonları yer almaktadır. Havuzlama katmanlarında maksimum havuzlama kullanılmıştır ve görüntülerin özelliklerini koruyarak boyutunu ve maliyetlerini azaltır. Son aktivasyon fonksiyonundan sonra, seyreltme katmanı ile birbirlerine bağlanmış üç adet TB katmanları yer alırken softmax katmanı ikili sınıflara ait olasılık dağılımlarını vermektedir (Han vd., 2017). Tasarlanan ağın girişi ise RGB derinlikli 227×227 piksel boyutundadır ve her giriş görüntüsünün boyutu ağın girişine göre yeniden boyutlandırılmıştır.

Tasarlanan ESA modelinde, son havuzlama katmanı yerine Şekil 2’de gösterilen MPH katmanı (Tan vd., 2021; Ouyang vd., 2018) kullanılmıştır. MPH katmanı, evrişimlerden gelen öznitelikleri farklı ölçeklerde ayırarak daha sonra bir araya toplayan bir kelime çantası modelidir ve üç temel özelliği bulunmaktadır. İlk olarak, bu katman giriş özniteliklerinin ölçeklerinden bağımsız olarak sabit uzunluklu bir öznitelik vektörü elde edilmesini sağlar. İkinci olarak, MPH katmanı nesne bozulmalarına karşı daha dayanıklı olan öznitelik haritalarını birleştirmek için tek pencere boyutu yerine çok seviyeli havuzlama pencereleri kullanır. Son olarak, bu yapı ile farklı ölçeklerdeki öznitelikler bir araya getirebilir (Yue vd., 2016). Bu çalışmada MPH katmanı, 1×1, 2×2 ve 3×3 boyutlarında filtrelerle sahip havuzlama katmanlarının birbirine paralel olarak bağlanmasıyla oluşturulmuştur. Havuzlama katmanlarından sonra birleştirme katmanı kullanılarak farklı ölçekte özellik haritaları birleştirilmiş ve sabit uzunluktaki öznitelik vektörü elde edilmiştir (Huang vd., 2020; Han vd., 2017). Tasarlanan bu 3-seviyeli MPH yapısı ile TB katmanına herhangi bir giriş görüntüsü için uzunluğu 14 satır olan bir öznitelik vektörü aktarılmıştır. Böylece, klasik havuzlama katmanına göre daha fazla mekânsal özellikler çıkartılarak ağın dayanıklılığı artırılmış ve farklı giriş görüntülerine karşı daha iyi bir sınıflandırma performansı sağlanmıştır.


MPH katmanında, $v = 1, \dots, V$ herhangi bir ölçekte tek bir öznitelik haritası ile sağlanan katmanın V -seviyesini gösterir ise elde edilen sonuç s_o , V -seviyeli bir MPH işlemi için Denklem (1) ile bulunabilir:

$$s_o = \sum_{v=1}^v G_v^2 \quad (1)$$


Mimarinin i . Evrişim bloğunun l . katmanından elde edilen toplam öznelik vektör uzunluğu ise aşağıdaki denklem ile elde edilir:

$$S_o^i = s_o \times f_l \quad (2)$$

Burada, f_l evrişim bloğu i 'nin l . katmanının toplam özellik haritası sayısını belirtir. Sonuç olarak, önerilen ESA modeli çok seviyeli ölçekleme özelliğine sahip olur. Şekil 3'de, önerilen MPH tabanlı ESA modelinin genel yapısı sunulmuştur.



Şekil 2. Mekansal Piramit Havuzlama Katmanı



Şekil 3. Önerilen MPH Tabanlı ESA Modeli

Veri Artırma

Veri setinde yer alan örnek sayısı geliştirilen derin öğrenme modelinin başarımını etkilemektedir. Çok sayıda parametreye sahip bir ESA modeli, yeterli eğitim örneği olmadan eğitim görüntülerinin genelleştirilemeyen ayrıntılı özelliklerini ezberledikleri için aşırı öğrenme riski ile karşılaşılır. Bu durumda, ağı eğitim örneklerinin çeşitli temsillerine maruz bırakmak, modelin yeni görüntüler için genelleştirilmesini sağlar ve geliştirilen ESA modelini sınıf örneklerinin farklı dönüşümlerine karşı daha az sapmalı, değişmez ve sağlam hale getirir. Veri artırma, yeterli örneklerin toplanamadığı durumlarda yaygın olarak kullanılan yöntemlerden biridir. Veri artırma ile mevcut örneklerden sentetik yeni örnekler üretilerek mevcut veri seti genişletilerek daha iyi bir sınıflandırma performansı ve kararlılığı elde edilir. Aynı zamanda, sınıflar arasındaki düzensiz dağılım en aza indirgenerek tüm sınıflar için eşit sayıda bir kümeleme sağlanır (Lashgari vd., 2020; Takahashi vd., 2020).

Çalışmada kullanılan veri setinde, drone ve kuş sınıfları için toplam 600 adet görüntü bulunmasına rağmen, bu görüntülerin %70'i eğitim için ayrılmıştır. Böylece, eğitim örneklerini temsil eden kümenin boyutunu arttırmak için bu örneklere aynalama işlemi uygulanmıştır. Bu işlemde, her satırdaki elemanlar tersine çevrilmiştir ve toplam 420 adet sentetik eğitim görüntüsü oluşturulmuştur. Şekil 4'de, aynalama işlemine ait örnek görüntüler verilmiştir.



Şekil 4. Sınıflara Ait Örnek Aynalanmış Görüntüler

BULGULAR VE TARTIŞMA

Bu bölümde, dronların tespiti ve sınıflandırılması için deneysel çalışmalar gerçekleştirilmiştir. Bu çalışmalar, MATLAB R2021b ortamında yapılmış ve sonuçlar Intel (R) i7-10750H CPU @2.60 GHz, NVIDIA Quadro P620 GPU ve 16 GB RAM belleğe sahip bir iş istasyonu yardımıyla elde edilmiştir. Veri setindeki görüntüler drone ve kuş olarak 2 sınıfta etiketlenmiştir. Bu sınıflarda bulunan görüntülerin %70'i eğitim, %15'i doğrulama ve %15'i ise test için rastgele olarak ayrılmıştır. Eğitim için seçilen görüntülere veri artırma işlemi uygulanarak derin öğrenme yöntemlerinin performanslarının artırılması amaçlanmıştır. Önerilen yöntemin sınıflandırma başarımı AlexNet, GoogLeNet, ShuffleNet ve DarkNet gibi literatürde sıklıkla kullanılan ön eğitilmiş ESA'lar ile karşılaştırılarak test edilmiştir. Tüm yöntemlere aynı eğitim, doğrulama ve test görüntüleri kullanılarak daha adil bir karşılaştırma amaçlanmıştır. Deneylerde, mini-yığın boyutu ve maksimum döngü sayısı sırasıyla 16 ve 50 olarak belirlenmiştir. Eğitim boyunca başlangıç öğrenme oranı $1e-4$ olarak ayarlanırken optimizasyon yöntemi olarak Momentumlu Stokastik Gradyan İnişi kullanılmıştır.

Performans Değerlendirme Ölçütleri

Bu çalışmada kullanılan tüm derin öğrenme yöntemleri ile elde edilen sonuçların değerlendirilebilmesi için Doğruluk, Kesinlik, Duyarlılık, Özgüllük ve F1-skor gibi ölçütler seçilmiştir. Bu ölçütler Tablo 1'de verilen hata matrisi yardımıyla hesaplanmıştır.

Doğruluk, doğru sınıflandırılan örneklerin toplam örneklere oranı olan sınıflandırma problemlerinde yaygın olarak kullanılan bir değerlendirme göstergesidir. Kesinlik, doğru olarak tahmin edilen negatif örnek sayısının negatif olarak tahmin edilen toplam örnek sayısına oranı olarak ifade edilebilir. Duyarlılık ve Özgüllük ise sırasıyla doğru tahmin edilen negatif örnek sayısının gerçekte negatif olan tüm örnek sayısına oranı ve doğru tahmin edilen negatif olmayan

örnek sayısının gerçekte negatif olmayan tüm örnek sayısına oranı olarak tanımlanabilir. F1-skor ise Duyarlılık ve Kesinlik ölçütlerinin ağırlıklı ortalaması ile hesaplanır.

Tablo 1. Hata Matrisi

Hata Matrisi		Tahmin Edilen Sınıf	
		Pozitif (Drone)	Negatif (Kuş)
Gerçekteki Sınıf	Pozitif (Drone)	Doğru Pozitif (DP)	Yanlış Negatif (YN)
	Negatif (Kuş)	Yanlış Pozitif (YP)	Doğru Negatif (DN)

Yukarıda kısaca açıklanan performans değerlendirme ölçütleri matematiksel olarak aşağıdaki denklemler yardımıyla hesaplanabilir:

$$\text{Doğruluk} = \frac{DP + DN}{DP + DN + YP + YN} \quad (3)$$

$$\text{Kesinlik} = \frac{DP}{DP + YP} \quad (4)$$

$$\text{Duyarlılık} = \frac{DP + YN}{DP + YN} \quad (5)$$

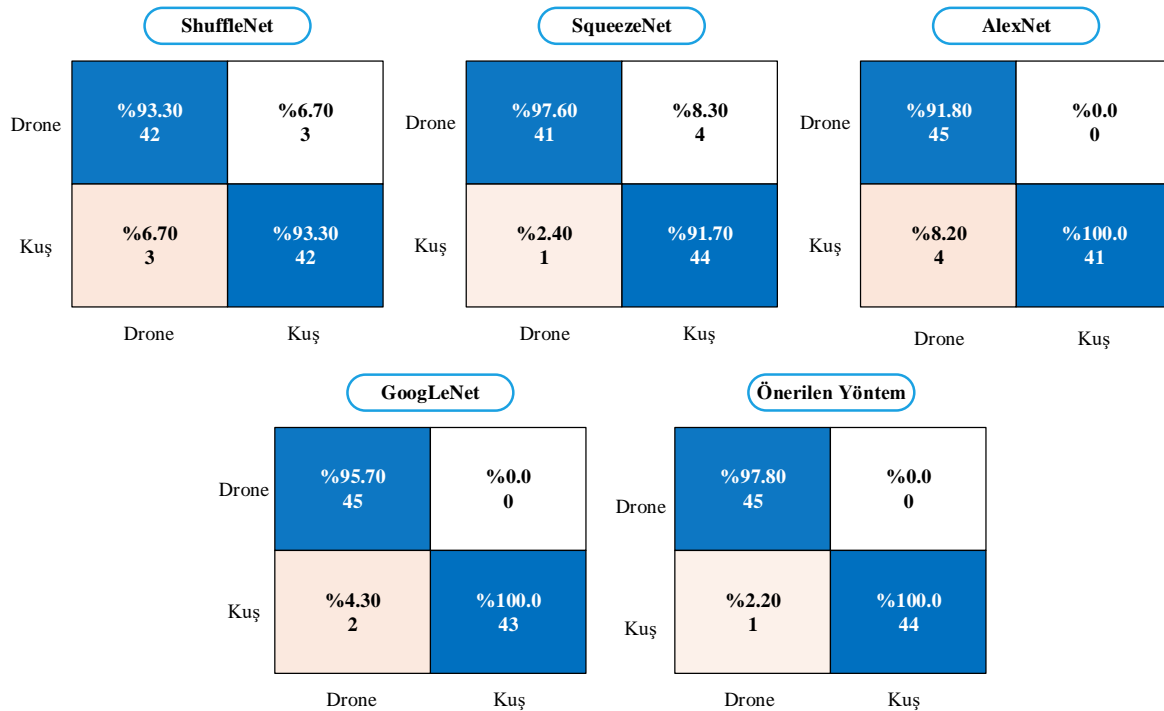
$$\text{Özgüllük} = \frac{DN + YP}{DN + YP} \quad (6)$$

$$\text{F1 - skor} = 2 * \frac{\text{Duyarlılık} * \text{Kesinlik}}{\text{Duyarlılık} + \text{Kesinlik}} \quad (7)$$

Burada, DP doğru sınıflandırılmış pozitif örnekleri, YP yanlış sınıflandırılmış negatif örnekleri, YN yanlış sınıflandırılmış pozitif örnekleri, DN doğru sınıflandırılmış negatif örnekleri ifade eder.

Deneysel Çalışmalar

Deneysel çalışmalar önerilen yöntemin dronların sınıflandırılmasındaki performansını göstermek için gerçekleştirilmiştir. İlk olarak, tüm derin öğrenme yöntemleri eğitildikten sonra test için ayrılan görüntülerden elde edilen hata matrisleri Şekil 5’de her bir model için ayrı ayrı sunulmuştur.

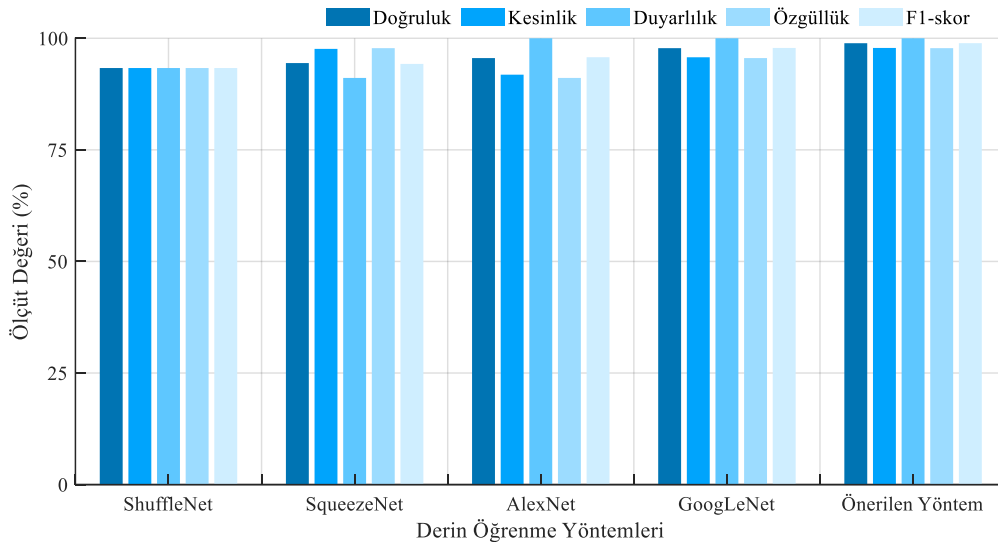
**Şekil 5. Hata Matrisleri**

Hata matrisleri incelendiğinde ShuffleNet'in 6 görüntüyü yanlış sınıflandırdığı görülmektedir. SqueezeNet, AlexNet ve GoogLeNet ise sırasıyla 5, 4 ve 2 görüntüyü yanlış sınıf içerisinde etiketlemiştir. Diğer yandan önerilen derin öğrenme yöntemi ise sadece 1 görüntüyü yanlış etiketleyerek en iyi sınıflandırma performansını göstermiştir. Hata matrisindeki değerler yardımıyla performans değerlendirme ölçütlerinin sayısal değerleri Tablo 2'de sunulmuştur.

Tablo 2. Derin Öğrenme Yöntemlerinden Elde Edilen Performans Ölçütlerinin Sonuçları

Yöntem	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	F1-skor
ShuffleNet	%93.33	%93.33	%93.33	%93.33	%93.33
SqueezeNet	%94.44	%97.62	%91.11	%97.78	%94.25
AlexNet	%95.56	%91.84	%100	%91.11	%95.75
GoogLeNet	%97.78	%95.74	%100	%95.56	%97.83
Önerilen Yöntem	%98.89	%97.83	%100	%97.78	%98.90

Ayrıca Tablo 2'deki değerlerin daha iyi analiz edilebilmesi için Şekil 6'daki grafikler verilmiştir. Tablo 2 ve Şekil 6'dan da görüldüğü üzere, tüm derin öğrenme yöntemlerinden elde edilen Doğruluk ölçütlerinin değerleri karşılaştırıldığında önerilen yöntem %98.89 ile en iyi sonucu sağlamıştır. En kötü sonucu %93.33'lük değer ile ShuffleNet verirken ikinci en iyi sonucu ise GoogLeNet %97.78'lik değer ile sağlamıştır. SqueezeNet ve AlexNet'in Doğruluk değerleri ise sırasıyla %94.44 ve %95.56 olarak hesaplanmıştır.



Şekil 6. Performans Değerlendirme Ölçütlerinin Karşılaştırılması


Diğer bir performans değerlendirme ölçütü olan Kesinlik için tüm derin öğrenme yöntemlerinden elde edilen sonuçlar değerlendirildiğinde yine önerilen yöntem en iyi sonucu sağlamaktadır. Önerilen yöntemin Kesinlik ölçütündeki değeri %97.83 iken en kötü sonucu veren ShuffleNet'in değeri ise %93.33 olarak hesaplanmıştır. SqueezeNet, AlexNet ve GoogLeNet'in değerleri ise sırasıyla %97.62, %91.84 ve %95.74 olarak elde edilmiştir. Bu değerlendirme ölçütündeki sonuçlardan önerilen yöntemin daha güvenilir ve etkin bir sınıflandırma yeteneğine sahip olduğu görülmektedir.

Önerilen yöntem ve diğer karşılaştırma modelleri Duyarlılık ölçütündeki değerleri bakımından analiz edildiğinde, önerilen yöntem ile AlexNet ve GoogLeNet en iyi sonucu %100'lük değer ile sağlarken en kötü sonucu ise SqueezeNet %91.11'lik değer ile göstermiştir. Önerilen yöntem ile AlexNet ve GoogLeNet'in sonuçlarının aynı olmasının sebebi ise Kuş etiketinde bulunan görüntülerin hepsinin doğru olarak bilinmesidir. Diğer bir derin öğrenme yöntemi olan ShuffleNet'in değeri ise %93.33 olarak hesaplanmıştır.

Özgüllük ölçütünde ise ShuffleNet %93.33, SqueezeNet %97.78, AlexNet %91.11, GoogLeNet %95.56 ve önerilen yöntem %97.78'lik değerlere sahiptir. Bu sonuçlardan da önerilen yöntemin en iyi sınıflandırma performansına sahip olduğu görülürken en kötü sonucu ise AlexNet vermiştir. Ön eğitilmiş derin öğrenme yöntemleri arasında önerilen


yönteme en yakın performansı ise bu performans ölçütünde SqueezeNet sağlamıştır. Hesaplanan Özgüllük değerlerinin analiz edilmesi sonucunda önerilen yöntemin üstün bir sınıflandırma kabiliyetine sahip olduğu görülmüştür.

F1-skor sonuçlarının değerlendirilmesinde yine en iyi sonucu önerilen yöntem %98.90'lık değer ile sağlamıştır. En kötü sonucu ise %93.33 ile ShuffleNet göstermiştir. Önerilen yönteme en yakın F1-skor sonucunu %97.83 ile GoogLeNet vermiştir. SqueezeNet, AlexNet'in bu performans ölçütündeki değerleri sırasıyla %94.25 ve %95.75 olarak hesaplanmıştır. Bu performans ölçüt değerlerindeki sonuçlardan göre önerilen yöntem ön eğitilmiş derin öğrenme yöntemlerinden daha iyi sınıflandırma performansına sahip olduğu görülmektedir.



Şekil 7. Performans Değerlendirme Ölçütlerinin Karşılaştırılması

Şekil 7'de ise eğitim ve validasyon süreçlerindeki doğruluk ve kayıplara ilişkin grafikler sunulmuştur. Şekiller yardımıyla önerilen yöntemin doğruluğu hakkında bilgiler gözlemlenebilmektedir.




Şekil 8. Derin Öğrenme Yöntemlerinden Elde Edilen ROC Eğrileri

Yöntemlerden elde edilen alıcı işletim karakteristik (ROC) eğrileri Şekil 8'de verilmiştir. ROC eğrileri Duyarlılık ve Özgüllük ölçütlerinden elde edilen sonuçlara göre çizilmektedir. Şekil 8'de sunulan ROC eğrilerinden de görüldüğü

üzere, önerilen yöntemin dronları sınıflandırma da üstün performansa sahip olduğu görülmektedir. Önerine yönteme ait olan ROC eğrisi incelendiğinde ilgili eğri altında kalan alanların her iki sınıf içinde 1 değerine yakın olduğu görülmektedir. Bu durum sınıflandırmadaki görüntülerin doğru olarak tahmin edildiğini kanıtlamaktadır.

Önerilen yöntemin dronların sınıflandırılmasındaki performansı diğer karşılaştırma yöntemlerine göre iyileştirme yüzdeleri açısından da analiz edilmiştir. Doğruluk performans ölçütünde SqueezeNet için %5.96, ShuffleNet için %4.71, AlexNet için %3.48 ve GoogLeNet için ise %1.14 iyileştirme yüzdeleri elde edilmiştir. Kesinlik ölçütünde ise iyileştirme yüzdeleri %0.22 ile %6.52 arasında değişmektedir. Diğer bir değerlendirme ölçütü olan Duyarlılıkta ise ShuffleNet ve SqueezeNet için iyileştirme yüzdeleri sırasıyla %7.15 ve %9.76 olarak hesaplanmıştır. Özgüllük ölçütünde ise önerilen yöntem ile AlexNet'in performansı %7.32 olarak iyileştirilmiştir. ShuffleNet ve GoogLeNet için iyileştirme yüzdeleri sırasıyla %4.77 ve %2.32 olarak elde edilmiştir. Son değerlendirme ölçütü olan F1-skor değerlerindeki iyileştirme yüzdeleri ise %1.1 ile %5.97 arasındadır. Elde edilen tüm iyileştirme yüzdeleri değerlendirildiğinde önerilen yöntem ile ön eğitilmiş derin öğrenme yöntemlerinin performanslarının artırıldığı kanıtlanmıştır.

Ayrıca, önerilen yöntemin ağ davranışını incelemek için *deepDreamImage* fonksiyonu ile çıkartılan öznetelikler görselleştirilmiştir. Önerilen yöntemin her iki sınıf için BT katmanından öğrenilen özneteliklerin görüntüleri Şekil 9'da verilmiştir.



Şekil 9. Özneteliklerin Görselleştirilmesi

SONUÇ

Bu çalışmada, dronlar ile kuşları sınıflandırmak için ön eğitilmiş derin öğrenme yöntemlerinden biri olan AlexNet mimarisine mekansal piramit havuzlama (MPH) yapısı entegre edilerek etkin bir evrişimli sinir ağı (ESA) modeli geliştirilmiştir. Eğitim için ayrılan örnekler veri artırma işlemi uygulanarak ağın başarımını artırılmıştır. Bu aşamadan sonra ise önerilen yöntemin dronların sınıflandırılmasındaki performansı ShuffleNet, SqueezeNet, AlexNet ve GoogLeNet gibi ön eğitilmiş derin öğrenme yöntemleriyle karşılaştırılmıştır. Gerçekleştirilen deneysel çalışmalardan elde edilen sonuçlarda, önerilen yöntem en iyi doğruluk ölçütü sonucunu %98.89'lik değer ile sağlarken en kötü sonucu %93.33 ile ShuffleNet göstermiştir. Diğer performans değerlendirme ölçütlerinde ise yine önerilen yöntem en iyi sonuçlara sahiptir. Ayrıca, önerilen yöntem ile en iyi ikinci performansa sahip olan GoogLeNet'in Doğruluk, Kesinlik, Özgüllük ve F1-skor ölçütleri sırasıyla %1.14, %2.18, %2.32 ve %1.10 olarak iyileştirilmiştir. Önerilen yöntem AlexNet'in geliştirilmiş yapısı olduğu için buradaki iyileştirme yüzdeleri ise Doğruluk için %3.48, Kesinlik için %6.52, Özgüllük için %7.32 ve F1-skor için %3.29 olarak elde edilmiştir. Deneysel çalışmalardan elde edilen tüm sonuçlar değerlendirildiğinde önerilen yöntem ile dronların daha etkin bir şekilde sınıflandırıldığı görülmektedir.

Gelecek çalışmalarda, uzak görüntülerden drone türlerinin tespit edilmesi ve sınıflandırılması ayrıca farklı optimizasyon yöntemleri ile ESA modelinin iyileştirilmesi düşünülebilir. Öte yandan, önerilen yöntem mimarisi farklı silahlı ve farklı amaçlar için kullanılan drone görüntüleriyle oluşturulan veri setlerinde kullanılmak üzere geliştirilebilir.

KAYNAKLAR

- Anwar, M.Z., Kaleem, Z., & Jamalipour, A. (2019). Machine Learning Inspired Sound-Based Amateur Drone Detection for Public Safety Applications. *IEEE Transactions on Vehicular Technology*, 68(3), 2526–2534. <https://doi.org/10.1109/TVT.2019.2893615>
- Basak, S., Rajendran, S., Pollin, S., & Scheers, B. (2022). Combined RF-Based Drone Detection and Classification. *IEEE Transactions on Cognitive Communications and Networking*, 8(1), 111–120. <https://doi.org/10.1109/TCCN.2021.3099114>
- Basbug, A.M., & Sert, M. (2019-January). Acoustic Scene Classification Using Spatial Pyramid Pooling with Convolutional Neural Networks. *IEEE 13th International Conference on Semantic Computing*, (pp. 128–131). <https://doi.org/10.1109/ICSC.2019.00029>
- Coluccia, A., Fascista, A., Schumann, A., Sommer, L., Dimou, A., Zarpalas, D., Méndez, M., de la Iglesia, D., González, I., Mercier, J.-P., Gagné, G., Mitra, A., & Rajashekar, S. (2021). Drone vs. Bird Detection: Deep Learning Algorithms and Results from a Grand Challenge. *Sensors*, 21, 2824. <https://doi.org/10.3390/s21082824>
- Coluccia, A., Parisi, G., & Fascista, A. (2020). Detection and Classification of Multirotor Drones in Radar Sensor Networks: A Review. *Sensors*, 20, 4172. <https://doi.org/10.3390/s20154172>
- Dale, H., Baker, C., Antoniou, M., Jahangir, M., Atkinson, G., & Harman, S. (2022). SNR-dependent drone classification using convolutional neural networks. *IET Radar, Sonar & Navigation*, 16, 22–33. <https://doi.org/10.1049/rsn2.12161>
- Grác, Š., Beňo, P., Duchoň, F., Dekan, M., & Tölgyessy, M. (2020). Automated detection of multi-rotor UAVs using a machine-learning approach. *Applied System Innovation*, 3(3), 1–23. <https://doi.org/10.3390/asi3030029>
- Han, X., Zhong, Y., Cao, L., & Zhang, L. (2017). Pre-trained alexnet architecture with pyramid pooling and supervision for high spatial resolution remote sensing image scene classification. *Remote Sensing*, 9(8), 1–22. <https://doi.org/10.3390/rs9080848>
- Hassanalain, M., & Abdelkefi, A. (2017). Classifications, applications, and design challenges of drones: A review. *Progress in Aerospace Sciences*, 91, 99–131. <https://doi.org/10.1016/j.paerosci.2017.04.003>
- Huang, Z., Wang, J., Fu, X., Yu, T., Guo, Y., & Wang, R. (2020). DC-SPP-YOLO: Dense connection and spatial pyramid pooling based YOLO for object detection. *Information Sciences*, 522, 241–258. <https://doi.org/10.1016/j.ins.2020.02.067>
- Jamil, S. Malicious Drones Dataset (2022). <https://www.kaggle.com/datasets/sonainjamil/malicious-drones/> Erişim Tarihi 07.03.2022.
- Kim, B.K., Kang, H.S., Lee, S., & Park, S.O. (2021). Improved Drone Classification Using Polarimetric Merged-Doppler Images. *IEEE Geoscience and Remote Sensing Letters*, 18(11), 1946–1950. <https://doi.org/10.1109/LGRS.2020.3011114>
- Kılıç, R., Kumbasar, N., Oral, E.A., & Ozbek, I.Y. (2022). Drone classification using RF signal based spectral features. *Engineering Science and Technology, an International Journal*, 28, 101028. <https://doi.org/10.1016/j.jestch.2021.06.008>
- Lashgari, E., Liang, D., & Maoz, U. 2020. Data augmentation for deep-learning-based electroencephalography. *Journal of Neuroscience Methods*, 346, 108885. <https://doi.org/10.1016/j.jneumeth.2020.108885>
- Li, Z., Liu, F., Yang, W., Peng, S., & Zhou, J. (2021). A Survey of Convolutional Neural Networks: Analysis, Applications, and Prospects. *IEEE Transactions on Neural Networks and Learning Systems*, 1–21. <https://doi.org/10.1109/tnnls.2021.3084827>
- 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. <https://doi.org/10.1109/ACCESS.2021.3130231>
- Lykou, G., Moustakas, D., & Gritzalis, D. (2020). Defending Airports from UAS: A Survey on Cyber-Attacks and Counter-Drone Sensing Technologies. *Sensors*, 20, 3537. <https://doi.org/10.3390/s20123537>

- Oh, H.M., Lee, H., & Kim, M.Y. (2019-October). Comparing Convolutional Neural Network(CNN) models for machine learning-based drone and bird classification of anti-drone system. *International Conference on Control, Automation and Systems*, (pp. 87–90). <https://doi.org/10.23919/ICCAS47443.2019.8971699>
- Ouyang, X., Gu, K., & Zhou, P. (2018). Spatial Pyramid Pooling Mechanism in 3D Convolutional Network for Sentence-Level Classification. *IEEE/ACM Transactions on Audio, Speech, and Language Processing*, 26(11), 2167–2179. <https://doi.org/10.1109/TASLP.2018.2852502>
- Seidaliyeva, U., Akhmetov, D., Ilipbayeva, L., & Matson, E.T. (2020). Real-Time and Accurate Drone Detection in a Video with a Static Background. *Sensors*, 20, 3856. <https://doi.org/10.3390/s20143856>
- Singha, S., & Aydin, B. (2021). Automated drone detection using YOLOv4. *Drones*, 5(3). <https://doi.org/10.3390/drones5030095>
- Sivil Havacılık Genel Müdürlüğü (2022). <https://iha.shgm.gov.tr/public/haberler?ID=2677244/> Erişim Tarihi 15.07.2022.
- Taha, B., & Shoufan, A. (2019). Machine Learning-Based Drone Detection and Classification: State-of-the-Art in Research. *IEEE Access*, 7, 138669–138682. <https://doi.org/10.1109/ACCESS.2019.2942944>
- Takahashi, R., Matsubara, T., & Uehara, K. (2020). Data Augmentation Using Random Image Cropping and Patching for Deep CNNs. *IEEE Transactions on Circuits and Systems for Video Technology*, 30(9), 2917–2931. <https://doi.org/10.1109/TCSVT.2019.2935128>
- Tan, Y.S., Lim, K.M., Tee, C., Lee, C.P., & Low, C.Y. (2021). Convolutional neural network with spatial pyramid pooling for hand gesture recognition. *Neural Computing and Applications*, 33, 5339–5351. <https://doi.org/10.1007/s00521-020-05337-0>
- Uddin, Z., Altaf, M., Bilal, M., Nkenyereye, L., & Bashir, A.K. (2020). Amateur Drones Detection: A machine learning approach utilizing the acoustic signals in the presence of strong interference. *Computer Communications*, 154, 236–245. <https://doi.org/10.1016/j.comcom.2020.02.065>
- Walia, H. Bird vs Drone New Dataset (2022). <https://www.kaggle.com/datasets/harshwalia/bird-vs-drone-new/> Erişim Tarihi 07.03.2022.
- Wojtanowski, J., Zygmunt, M., Drozd, T., Jakubaszek, M., Życzkowski, M., & Muzal, M. (2021). Distinguishing Drones from Birds in a UAV Searching Laser Scanner Based on Echo Depolarization Measurement. *Sensors*, 21, 5597. <https://doi.org/10.3390/s21165597>
- Yee, P.S., Lim, K.M., & Lee, C.P. (2022). DeepScene: Scene classification via convolutional neural network with spatial pyramid pooling. *Expert Systems with Applications*, 193, 116382. <https://doi.org/10.1016/j.eswa.2021.116382>
- Yue, J., Mao, S., & Li, M. (2016). A deep learning framework for hyperspectral image classification using spatial pyramid pooling. *Remote Sensing Letters*, 7, 875–884. <https://doi.org/10.1080/2150704X.2016.1193793>
- Zhang, X., Mehta, V., Bolic, M., & Mantegh, I. (2020-October). Hybrid AI-enabled Method for UAS and Bird Detection and Classification. *IEEE International Conference on Systems, Man and Cybernetics*, (pp. 2803–2807). <https://doi.org/10.1109/SMC42975.2020.9282965>