

GAZİ

JOURNAL OF ENGINEERING SCIENCES

The Impact of Deep Learning and Transfer Learning Algorithms on Drone Detection Performance

Fatma Gülşah Tan^{a*}

Submitted: 15.11.2023 Revised: 04.12.2023 Accepted: 05.12.2023 doi:10.30855/gmbd.0705S01

ABSTRACT

With the rapid advancement of drone technologies, the use of drones has become of significant importance, particularly raising serious concerns in the areas of security and privacy. Deep learning and transfer learning artificial intelligence techniques hold promise for drone detection. However, to successfully apply these techniques, the need to develop new and efficient solutions for accurately detecting complex aerial conditions, variable speeds, and highly maneuverable drones is inevitable. In this study, the performance of training models using the EfficientNet model for drone detection was compared, and the challenges encountered were discussed, offering a perspective on potential future successes. According to the obtained results, when more layers are frozen in the transfer learning method, the required GPU memory for training decreases, leading to reduced GPU usage. This indicates that models trained with larger image sizes can be trained more quickly. Deep learning methods require more data and GPU resources, which extend the training time. In the conducted experiments, the best success rate achieved by a model trained with the deep learning method was 97.3%, while the model trained using the transfer learning method achieved the highest success rate of 99.7%. This demonstrates that transfer learning achieves higher accuracy with less data. However, the success rate obtained through the deep learning method is also considered quite satisfactory.

Keywords: EfficientNet, deep learning, transfer learning, object detection, drone detection

^{a*} Suleyman Demirel University
Department of Information Technology,
Isparta, Turkey
Orcid: 0000-0002-2748-0396
e mail: gulsah@sd.edu.tr

*Corresponding author:
gulsah@sd.edu.tr

Derin Öğrenme ve Öğrenme Aktarımı Algoritmalarının Drone Algılama Performansı Üzerine Etkisi

ÖZ

Drone teknolojilerinin hızla gelişmesiyle birlikte, özellikle güvenlik ve gizlilik alanlarında ciddi endişelere yol açan drone kullanımı, günümüzde büyük bir önem arz etmektedir. Derin öğrenme ve öğrenme aktarımı yapay zekâ teknikleri, drone tespiti konusunda umut vaat etmektedir. Ancak, bu tekniklerin başarıyla uygulanabilmesi için, karmaşık hava koşulları, değişken hızlar ve yüksek manevra kabiliyetine sahip dronelerin doğru şekilde saptanabilmesi için yeni ve verimli çözümler geliştirme ihtiyacı kaçınılmazdır. Bu çalışmada, drone nesnelerinin tespiti için EfficientNet modeli kullanarak eğitim modellerinin drone tespiti üzerindeki performansları ve karşılaşılan zorluklar karşılaştırılarak, gelecekteki potansiyel başarıları hakkında bir perspektif sunulmuştur. Elde edilen sonuçlara göre, öğrenme aktarımı yönteminde daha fazla katman dondurulduğunda, eğitim için gereken GPU belleği azalır ve GPU kullanımı düşer. Bu durum, daha büyük görüntü boyutlarıyla eğitilen modellerin daha hızlı eğitilebileceğini göstermiştir. Derin öğrenme yöntemi daha fazla veriye ve GPU kaynağına ihtiyaç duymaktadır, bu da eğitim süresini uzatmaktadır. Yapılan deneylerde derin öğrenme yöntemiyle eğitilen modelin en iyi başarı oranı %97.3, öğrenme aktarımı yöntemiyle eğitilen modelin en iyi başarı oranı ise %99.7 olarak belirlenmiştir. Bu, öğrenme aktarımı yönteminin az veriyle daha yüksek bir doğruluk oranı sağladığını göstermektedir. Ancak, derin öğrenme yöntemiyle elde edilen başarı oranı da oldukça tatmin edici bir sonuç olarak değerlendirilebilir.

Anahtar Kelimeler: EfficientNet, derin öğrenme, öğrenme aktarımı, nesne tespiti, drone tespiti

1. Giriş (Introduction)

Günümüzde nesne tespiti, otomasyon, güvenlik, sağlık hizmetleri ve daha birçok alan için kritik öneme sahiptir. İnsansız hava araçları ya da popüler adıyla dronelar, birçok farklı sektörde kullanılmakta ve bu alanda hızla yaygınlaşmaktadır. Tarım, lojistik, taşımacılık, haberleşme ve güvenlik gibi çeşitli alanlarda sağladığı avantajlar sayesinde drone teknolojileri, endüstrilerin verimliliğini artırmak ve yeni olanaklar yaratmak adına önemli bir role sahiptir. Ancak, dronelerin geniş kullanımı, güvenlik tehditlerinin ortaya çıkmasına da neden olmaktadır. Özellikle hassas bölgelerin korunması, gizlilik ihlallerinin önlenmesi ve hava sahasının güvenliği gibi önemli konular, drone tespiti ve izlenmesinin ne kadar kritik olduğunu vurgulamaktadır. Geleneksel yöntemlerin yetersiz kaldığı durumlarda, yapay zekâ drone tespitinde büyük bir umut ışığı olarak ortaya çıkmaktadır. Bu çalışma, derin öğrenme ve öğrenme aktarımı tabanlı eğitim modelleri ile drone tespiti konusunda yapılan çalışmaları inceleyerek, bu alanın mevcut durumunu değerlendirmeyi ve gelecekteki potansiyel başarıları öngörmeyi amaçlamaktadır. Ayrıca, drone tespitinin önemini ve bu alandaki zorlukları ele alarak, ilgili araştırmalara yeni bir perspektif kazandırmayı hedeflemektedir.

Son yıllarda, derin öğrenme ve öğrenme aktarımı yöntemleri, nesne tespiti alanında çarpıcı ilerlemelere yol açmıştır [1]. Derin öğrenme, büyük ve karmaşık veri setlerinden otomatik olarak öğrenme yeteneği olan yapay sinir ağları kullanarak karmaşık modeller oluşturma sürecidir. Bu yöntem, geniş veri setlerini kullanarak baştan başlayarak modelin eğitimini içerir. Ancak, bu yaklaşım, büyük miktarda veriye ve yüksek hesaplama kaynaklarına ihtiyaç duyar ve eğitim süreci uzun sürebilir. Öğrenme aktarımı, bir görev için öğrenilen bilgilerin, başka bir görevde kullanılmasıdır. Bu yöntem, önceden eğitilmiş bir modelin, yeni bir görev için hedefe daha hızlı ve daha etkili bir şekilde uygulanması için kullanılmasını içerir. Öğrenme aktarımı, daha az veriyle bile iyi sonuçlar elde etmeyi mümkün kılar ve eğitim süresini kısaltmaktadır.

Bu çalışmada, drone nesnelere tespiti için EfficientNet modeli kullanarak öğrenme aktarımı ve derin öğrenme yöntemlerinin deneysel olarak karşılaştırılması yapılmıştır. EfficientNet son 5 yılda nesne tespiti alanında geniş bir şekilde kullanılmıştır ve çeşitli uygulamalarda etkinliğini göstermiştir. EfficientNetV2 modellerinin, son teknoloji modellere kıyasla çok daha hızlı eğitildiği ve önemli ölçüde daha küçük oldukları gösterilmiştir, bu da onları nesne tespiti görevleri için daha verimli kılmaktadır [2]. Ayrıca, floresan mikroskopi görüntülerinden insan meme kanseri hücrelerinin otomatik sınıflandırılması için kullanılmış, bu da EfficientNet'in tıbbi görüntü analizi alanındaki potansiyelini vurgulamaktadır [3]. Ayrıca, öğrenme aktarımı yönteminde katman dondurma stratejilerinin kullanımının, veri artırma tekniğinin ve ince ayar tekniklerinin, Grafik İşlemci Ünitesi (Graphics Processing Unit, GPU) belleği kullanımı ve eğitim süresi üzerindeki etkisi incelenmiştir. EfficientNet, derin öğrenme tabanlı bir nesne algılama modelidir ve drone nesnelere tespiti için etkili bir çözüm sunmaktadır. Sonuç olarak, bu çalışma, drone nesnelere tespiti alanında derin öğrenme ve öğrenme aktarımı yöntemlerinin kullanılabilirliğini araştıran önemli bir çalışmayı temsil etmektedir. Elde edilecek sonuçların, drone nesnesinin tespiti konusunda daha etkili ve hızlı çözümler sunmak için gelecekteki çalışmalara ışık tutması amaçlanmaktadır.

2. İlgili Çalışmalar (Related Works)

Nesne tespiti, makine öğrenmesi ve görüntü işleme alanlarında yoğun bir şekilde araştırılan bir konudur. Son yıllarda, öğrenme aktarımı ve derin öğrenme yöntemlerinin kullanımı, nesne tespiti alanında büyük bir ilerleme sağlamıştır. Öğrenme aktarımı, bir görevde öğrenilen bilgilerin başka bir görevde kullanılmasını içeren bir yaklaşımdır. Derin öğrenme ise büyük ve karmaşık veri setlerinden otomatik olarak öğrenme yeteneği olan yapay sinir ağları kullanarak karmaşık modellerin oluşturulduğu bir yöntemdir. Bu çalışmalarda, farklı veri setleri, model mimarileri ve eğitim stratejileri kullanılarak drone nesnesi tespiti üzerindeki başarı oranları artırılmaya çalışılmaktadır. Bu literatür taraması, mevcut çalışmalardan elde edilen bulguların derinlemesine analizini ve öğrenme aktarımı ile derin öğrenme yöntemlerinin drone nesnesi tespiti alanında nasıl kullanılabileceği konusunda önemli bir bakış açısı sunmaktadır. Çalışmalar, nesne algılama modellerinin performansını ve genelleme yeteneğini geliştirmek için derin öğrenme ve öğrenme aktarımından yararlanmaya yönelik çeşitli teknikleri ve yaklaşımları tartışmaktadır.

Al-Emadi ve Al-Ali [4] çalışmalarında ses tabanlı drone tespiti ve tanımlamasında derin öğrenme tekniklerine odaklanmışlardır. Ses uygulamalarında derin öğrenme algoritmalarının etkinliğini vurgulayarak akustik özelliklere dayalı drone tespiti için derin öğrenmenin kullanımını önermişlerdir. Tan ve arkadaşları [5], derin öğrenme algoritmalarını nesne takip etmek için kullanarak drone takibi üzerine bir çalışma sunmuşlardır.

Lider drone ve takipçi drone olmak üzere iki drone simülasyonu gerçekleştirerek, nesne takibi ve tespiti için derin öğrenme tekniklerini kullanmışlardır. Samadzadegan ve arkadaşları [6], görünür görüntülere dayalı drone tespiti ve tanımlaması için derin evrişimli sinir ağı önermişlerdir. Bu yöntem, sadece dronelerin varlığını veya yokluğunu tespit etmekle kalmaz, aynı zamanda farklı türdeki droneleri ve kuşları birbirinden ayırt etmektedir. Derin öğrenmeyi kullanarak dronelerin tespit ve tanınmasında yüksek doğruluk elde etmişlerdir. Wang ve arkadaşları [7], derin öğrenme tabanlı tespit ve takip modüllerini entegre eden görünür ve termal drone izleme sistemi geliştirmişlerdir. Özellikle termal drone görüntüleri gibi sınırlı eğitim drone görüntüleri zorluğunu, veri artırma teknikleri geliştirerek çözmüşlerdir.

Algoritma karşılaştırması, veri kümesi analizi, ağ yapısı ve performans değerlendirmesi dahil olmak üzere nesne algılamanın farklı yönlerini keşfetmek için çok sayıda çalışma yapılmıştır. Wu ve arkadaşları [8] çalışmalarında derin öğrenme ile görsel nesne algılamadaki son gelişmelere genel bir bakış sunmuşlardır. Yaptıkları anket çalışması, dedektör mimarileri, özellik öğrenme, teklif oluşturma ve örnekleme stratejileri gibi algılama performansını etkileyen çeşitli faktörleri kapsamaktadır. Aziz ve arkadaşları [9] çalışmalarında genel nesne algılamaya odaklanmışlar ve bu alandaki son gelişmelerin kapsamlı bir incelemesini sağlamışlardır. Çalışma yaklaşık 300 yayını kapsamakta ve bölge önerisine dayalı nesne algılama yöntemlerini tartışmaktadır. Genel görüntü analizi alanında nesne algılamanın önemini ve geniş uygulama yelpazesini vurgulamışlardır. Dış hekimliği alanında, Takahashi ve arkadaşları [10] derin öğrenmeyi kullanarak dış implantlarının tanımlanmasına yönelik bir pilot çalışma gerçekleştirmişlerdir. Dış hekimliğinde nesne algılama, sınıflandırma ve tahmin görevleri için derin öğrenme yöntemlerinin kullanımının altını çizmişlerdir. Çalışma özellikle, görüntüler için derin öğrenme tabanlı nesne algılama algoritmaları kullanılarak dış hastalıklarının teşhisine odaklanmaktadır. Ayrıca, bu çalışmada derin öğrenmenin belirli alanlardaki uygulamaları da araştırılmıştır. Fu [11] nesne algılamanın geçmişini gözden geçirmiş ve son yıllarda derin öğrenme nesne algılamanın gelişimine sistematik bir giriş sağlamıştır.

Öğrenme aktarımı alanında yapılan çalışmalar incelendiğinde bu çalışmalar genel olarak önceden eğitilmiş modellerden yararlanarak ve bilgiyi bir alandan diğerine aktararak nesne algılama algoritmalarını iyileştirmeyi amaçlamaktadır. Xia ve arkadaşları [12], hava görüntülerinde nesne algılamaya odaklanmışlar ve doğal sahneler için geliştirilen nesne algılama algoritmalarının hava görüntüsü alanına transferini araştırmışlardır. ImageNet ve Bağlamdaki Microsoft Ortak Nesnelere (Microsoft Common Objects in Context, MSCOCO) gibi büyük ölçekli görüntü veri kümelerinde önceden eğitilmiş ince ayarlı ağları kullanmışlardır. Zhang ve Tao [13] nesne algılama ve semantik bölümlenme dahil olmak üzere çeşitli akış görevleri için ImageNet üzerinde önceden eğitilmiş modellerin ince ayar uygulamalarını tartışmışlardır. Ayrıca öğrenme aktarımında alan uyarlamasının önemini vurgulamışlardır. Zhao ve arkadaşları [14], denetimsiz ön eğitim kullanarak görsel nesne algılama için öğrenme aktarımında dikkate değer bir sonuç bildirmişlerdir. Çalışma sonuçlarında Momentum Kontrastı (Momentum Contrast, MoCo) yöntemi, denetimli ön eğitimden daha iyi performans elde etmiş ve etiketlerin öğrenme aktarımı için her zaman gerekli olmayabileceğini belirtmişlerdir. Shende [15], kayıp nesne tespiti için evrişimli sinir ağlarının kullanımına ilişkin bir literatür araştırması yürütmüştür. Ankette, bağlama duyarlı algılama, üretken çekişmeli ağlar, çok görevli öğrenme ve öğrenme aktarımı dahil olmak üzere farklı yaklaşımlar analiz edilmiştir. Agarwal ve arkadaşları [16], görüntü ve video işleme görevlerinin bir parçası olarak nesne algılamaya genel bir bakış sağlamıştır. Anket, çeşitli teknik yaklaşımları ve nesne algılama yöntemlerinin karşılaştırmalı analizlerini içermektedir. Athanasiadis ve arkadaşları [17], gömülü sistemler için nesne algılamada öğrenme aktarımını araştırmıştır. Yeni bir sınıf grubu için SqueezeDet sinir ağının eğitimini hızlandırmak için öğrenme aktarımı yöntemini kullanmıştır. Wang ve arkadaşları [18] Elektroensefalografi (EEG) tabanlı yorgunluk tespiti için sınıflandırma algoritmalarının gelişimini gözden geçirmişlerdir. Yorgunluk tespitinde geleneksel makine öğrenimi algoritmalarının, derin öğrenme algoritmalarının ve öğrenme aktarımı algoritmalarının kullanımını tartışmışlardır. Shen ve arkadaşları [19], Object365 üzerinde ön eğitim olarak ve öğrenilen görsel temsilleri Büyük Sözcük Örneği Segmentasyonu İçin Veri Seti (A Dataset For Large Vocabulary Instance Segmentation, LVIS) ve diğer küçük nesne algılama veri setlerinde nesne algılama için aktararak sıfır atışlı nesne algılamayı araştırmışlardır. Plata ve arkadaşları [20] manyok fitoplazma hastalığının tanınması için nesne algılamaya konvolüsyonel sinir ağlarının uygulanmasına odaklanmışlardır. Nesne algılamada daha iyi performans elde etmede özellik öğrenme ve öğrenme aktarımı ile konvolüsyonel sinir ağlarının gücünü vurgulamışlardır. Bu çalışmalar, önceden eğitilmiş modellerden yararlanma ve etki alanları arasında bilgi aktarma potansiyelini sergileyerek, öğrenme aktarımı ile nesne algılamadaki geniş uygulama yelpazesini ve ilerlemeleri toplu olarak göstermektedir.

Rahaman ve arkadaşları [21] çalışmalarında dijital göğüs röntgeni görüntülerinden Koronavirüs Hastalığı

(COVID-19) pnömonisinin otomatik olarak saptanması için sağlam bir tekniğin geliştirilmesine odaklanılmışlardır. Çalışmanın temel amacı, öğrenme aktarımı kullanırken COVID-19 pnömonisinin tespit doğruluğunu en üst düzeye çıkaran bir yöntem önermektir. Yazarlar, çeşitli genel veritabanlarını ve yakın zamanda yayınlanan makalelerden görüntüleri birleştiren bir genel veritabanı oluşturmuşlardır. Veritabanı 423 COVID-19, 1485 viral pnömoni ve 1579 normal akciğer röntgeni görüntüsünün karışımından oluşmaktadır. Önceden eğitilmiş birkaç derin konvolüsyonel sinir ağlarını eğitmek ve doğrulamak için görüntü büyütme ile birlikte öğrenme aktarımı teknikleri kullanılmıştır [22]. Bu çalışmada odaklanılan başarı oranı, göğüs röntgeni görüntülerinden COVID-19 pnömonisini tespit etme doğruluğudur. Bu çalışma ile COVID-19 tanısında yardımcı olabilecek teknolojik bir aracın geliştirilmesine katkı sağladıklarını belirtmişlerdir.

Zhu ve arkadaşları [23] çalışmalarında öğrenme aktarımı tekniklerinin Sadece Bir Kere Bak (You Only Look Once, YOLO) nesne tespiti modeline uygulanması yoluyla yoğun nesne tespiti problemlerindeki performansını artırmayı amaçlamışlardır. Çalışmalarında, farklı eğitim veri setleri kullanılarak model eğitimi gerçekleştirilmiştir. Model performansı doğruluk, hassasiyet ve F1 skoru metrikleri kullanılarak değerlendirilmiştir. YOLOv3 modelinin önceden eğitilmiş ağırlıklarının, farklı yoğunluk seviyelerindeki yollar üzerindeki nesnelere tespit etmek için eğitim verileriyle birleştirilerek kullanılabilmesi gösterilmiştir. Bu yaklaşımın, özellikle trafik yoğunluğunun yüksek olduğu yollarda ve araçların birbirine yakın seyahat ettiği yollarda nesne tespiti performansını artırdığını belirtmişlerdir. Çalışma sonuçları, YOLOv3 modeline öğrenme aktarımı uygulandığında, doğruluğun arttığını ve nesne tespiti performansının önemli ölçüde iyileştiğini göstermektedir.


Derin öğrenme ve öğrenme aktarımı, drone nesnelere tespiti alanında akademik çalışmalarda çok sınırlı bir şekilde kullanılmıştır. Yapılan literatür taramasında, bu alanda uygulama eksikliği de gözlemlenmiştir. Bu çalışmada, derin öğrenme ve öğrenme aktarımı tekniklerinin kullanılmasıyla drone nesnesi tespit performansı yapılan deneysel çalışmalarla iyileştirilmiştir. Bozkurt optimizasyon algoritması (GWO), Mirjalili ve diğerleri tarafından vahşi gri kurtların hiyerarşisi ve avlanma yönteminden esinlenilerek geliştirilmiştir [7]. Bozkurtların sürü hiyerarşisinde bireyler alfa, beta, delta ve omega rollerinden birini oynar. Alfa liderdir; grup talimatlarını takip eder. Alpha, grubun en güçlü üyesi değildir, ancak grubu yönetme açısından en iyisi olmalıdır. Beta, sürüdeki en baskın ikinci bireydir. Alfa'yı takip ederken diğerlerine hükmeder.

3. Materyal ve Yöntem (Material and Method)

Bu bölümde derin öğrenme ve öğrenme aktarımı yöntemleri hakkında bilgiler verilmiştir ve drone nesnesinin tespiti ile ilgili yapılan deneysel çalışmalar karşılaştırılmıştır.

3.1. Derin öğrenme ile drone tespiti (Drone detection with deep learning)

Derin öğrenme, yapay sinir ağlarından ilham alarak geliştirilen ve büyük veri kümelerini kullanarak karmaşık problemleri çözmek için kullanılan bir makine öğrenme yöntemidir. Derin öğrenme, katmanlı yapılardan oluşan derin sinir ağları aracılığıyla bilgisayarların öğrenme yeteneklerini simüle etmeyi amaçlar. Bir derin öğrenme ağı, genellikle sinir hücrelerinden oluşan bir yapıya sahiptir. Bu sinir hücreleri, veri girdilerini alır, bu girdileri işler ve sonuçları üretir. Derin öğrenme ağları genellikle yarı bağlantılı veya tam bağlantılı katmanlarla birbirine bağlanan düğümlerden oluşur. Bu katmanlar, verileri daha yüksek seviyeli temsillere dönüştürmek için çeşitli matematiksel işlemleri gerçekleştirir. Derin öğrenme ağları, genellikle geriye yayılım adı verilen bir eğitim süreciyle çalışır. Bu süreçte, ağına verilen örnek veriler kullanılarak, ağı optimize eden ve hataları azaltan ağırlıklar ve parametreler ayarlanır. Derin öğrenme ağları, öğrenme süreci boyunca özellik çıkarımı ve otomatik özellik seçimi yaparak veri içindeki karmaşıklıkları algılamada etkili olabilir. Şekil 1'de derin öğrenme ile drone tespit modeli oluşturulmasına ait akış gösterilmiştir.



Şekil 1. Derin öğrenme ile drone tespiti (Drone detection with deep learning)

Derin öğrenme teknikleri kullanılarak geliştirilen drone tespit modeli aşağıda belirtilen adımları içermektedir:

1. Veri setinin hazırlanması
2. Verilerin etiketlenmesi
3. Modelin eğitilmesi
4. Modelin değerlendirilmesi ve iyileştirilmesi

Drone veri seti bilgileri [24] Tablo 1’de gösterilmiştir. Veri seti %80 eğitim, %20 doğrulama verisi olarak ayrılmıştır.

Tablo 1. Drone tespiti eğitim ve test verileri sayısı (Number of training and testing data for drone detection)

Veri Türü	Eğitim Verisi	Doğrulama Verisi
Kuş	112	29
Drone	121	31
Toplam	233	60

Drone nesnesi tespiti için eğitim modelinin oluşturulması aşamasında veri seti hazırlanırken görüntülerde bulunan nesnelere etiketlemek için LabelImg kullanılmıştır. Etiketlenen veriler EfficientNet modeli ile eğitilmiştir. Deneysel çalışmalar 9 model içermektedir.


- model1: Verilerinin %5’inden 5 iterasyonlu derin öğrenme ile öğrenme
- model2: Verilerinin %50’sinden 5 iterasyonlu derin öğrenme ile öğrenme
- model3: Verilerinin %100’ünden 5 iterasyonlu derin öğrenme ile öğrenme
- model4: Verilerinin %5’inden 25 iterasyonlu derin öğrenme ile öğrenme
- model5: Verilerinin %50’sinden 25 iterasyonlu derin öğrenme ile öğrenme
- model6: Verilerinin %100’ünden 25 iterasyonlu derin öğrenme ile öğrenme
- model7: Verilerinin %5’inden 40 iterasyonlu derin öğrenme ile öğrenme
- model8: Verilerinin %50’sinden 40 iterasyonlu derin öğrenme ile öğrenme
- model9: Verilerinin %100’ünden 40 iterasyonlu derin öğrenme ile öğrenme

Tablo 2’de farklı varyasyonlara göre oluşturulan eğitim modellerinin başarı oranları gösterilmiştir. Her model için girdi boyutu 640, aynı anda işlenecek veri sayısı değeri 16 olarak alınmıştır.

Tablo 2. Derin öğrenme modellerinin başarı oranları (Success rates of deep learning models)

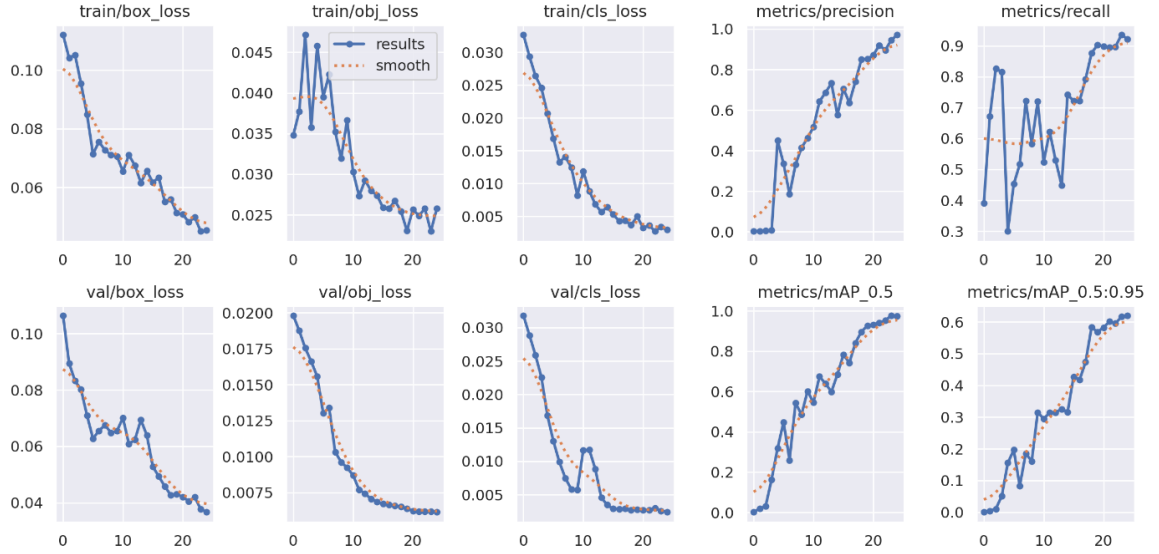
Model	Başarı Oranı	Öğrenim Zamanı (Saat)
model1	%0.59	0.003
model2	%12.3	0.008
model3	%74.8	0.013
model4	%2.5	0.008
model5	%96.4	0.023
model6	%97.3	0.045
model7	%15.3	0.013
model8	%92.2	0.035
model9	%97	0.057

Şekil 2, Şekil 3 ve Şekil 4’te alınan veri sayısına göre elde edilen en iyi başarı oranına ait kayıp performans değerleri gösterilmiştir. Şekil 2’de model7 için 40 iterasyon sonucunda drone nesnelere tespitinde alınan kayıp ve performans değerleri gösterilmiştir.



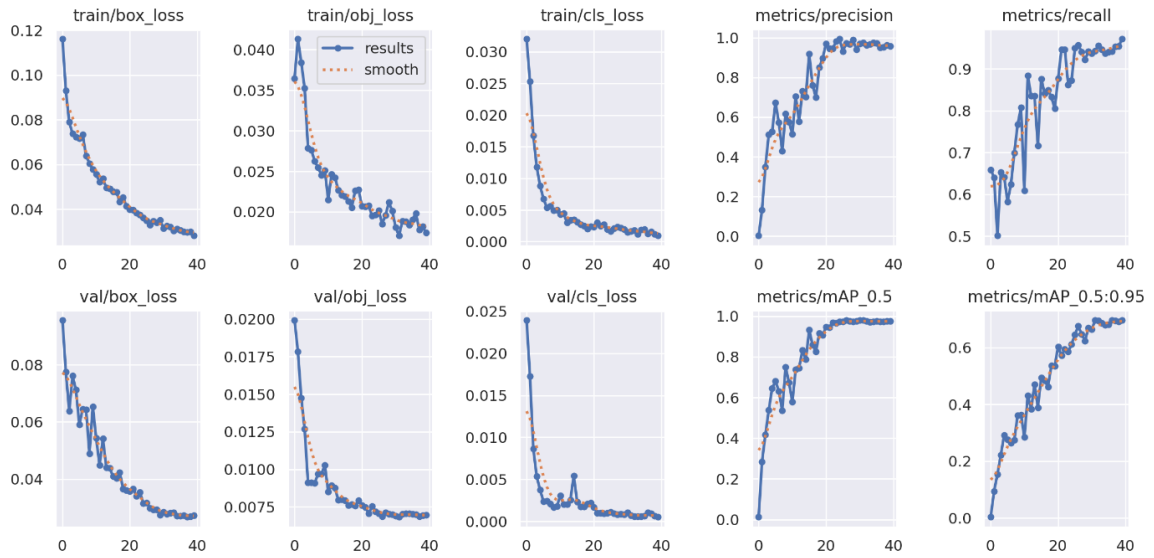
Şekil 2. model7 drone unsurları nesnesine ait kayıp ve performans ölçümleri (Loss and performance measurements for model7 drone object elements)

Şekil 3'te model5 için 25 iterasyon sonucunda drone nesnelere tespitinde alınan kayıp ve performans değerleri gösterilmiştir.



Şekil 3. model5 drone unsurları nesnesine ait kayıp ve performans ölçümleri (Loss and performance measurements for model5 drone object elements)

Şekil 4'te model6 için 25 iterasyon sonucunda drone nesnelere tespitinde alınan kayıp ve performans değerleri gösterilmiştir.



Şekil 4. model6 drone unsurları nesnesine ait kayıp ve performans ölçümleri (Loss and performance measurements for model6 drone object elements)

Şekil 4'e göre oluşturulan eğitim modeli %97.3 tahmin oranına sahiptir. Sınırlayıcı kutu, nesne kaybı ve sınıf kaybı değerleri 0, kesinlik ve geri çağırma değerleri ise 1 değerine yaklaşmaktadır. Eğitim modellerinde aşırı öğrenme olmaması için hiper parametreler deneme-yanılma yoluyla belirlenmiştir. Modellerin tahmin oranları hesaplanırken kullanılan matematiksel formüller formül 1,2,3,4 ve 5'te gösterilmiştir.

$$Kesinlik = \frac{Doğru Pozitif}{(Doğru Pozitif + Yanlış Pozitif)} \quad (1)$$

$$Geri Çağırma = \frac{Doğru Pozitif}{(Doğru Pozitif + Yanlış Negatif)} \quad (2)$$

$$F1 = 2 * \frac{Kesinlik * Geri Çağırma}{(Kesinlik + Geri Çağırma)} \quad (3)$$

$$Ortalama Hassasiyet (AP) = \sum_{k=0}^{k=n-1} [Geri Çağırma(k) - Geri Çağırma(k+1)] * Kesinlik(k) \quad (4)$$

$$Ortalama Hassasiyet Ortalaması (mAP) = \frac{1}{n} \sum_{k=1}^{k=n} AP_k \quad (5)$$

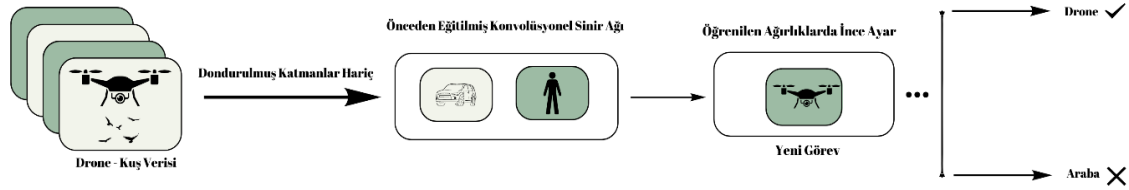
Belirtilen formüllerde kesinlik, modelin pozitif olarak tahmin ettiği örneklerin gerçekten ne kadar doğru olduğunu gösterir. Geri çağırma, gerçek pozitif örneklerin kaçınının model tarafından doğru bir şekilde tespit edildiğini gösterir. F1 skoru, kesinlik ve geri çağırma arasında bir denge kurar. Ortalama hassasiyet, nesne tespiti modellerinin doğruluğunu ölçen bir metriktir ve genellikle sınıf bazında değerlendirilir. Ortalama hassasiyet ortalaması, birden fazla sınıfa sahip bir nesne tespit problemi için kullanılan bir metriktir. Bu, her sınıfın ortalama hassasiyet ortalaması alınarak elde edilir. Şekil 5'te en iyi tahmin oranını alan modelin tespit ettiği nesnelere ait görüntüler verilmiştir.



Şekil 5. Derin öğrenme modeli ile tespit edilen drone görüntüleri (Drone images detected with the deep learning model)

3.2. Öğrenme aktarımı ile drone tespiti (Drone detection with learning transfer)

Öğrenme aktarımı, bir görevde öğrenilen bilgilerin, farklı ancak ilgili bir görevde kullanılmasını sağlayan bir makine öğrenme yöntemidir. Öğrenme aktarımı, kaynak görevden hedef göreve bilgi ve beceri aktarımını içerir ve genellikle sınırlı veri veya karmaşık modellerle karşılaşıldığında faydalıdır. Öğrenme aktarımı, genellikle derin öğrenme ağları ile birlikte kullanılır. Derin öğrenme ağları, birçok katmandan oluşan karmaşık bir yapıya sahiptir ve genellikle büyük veri kümeleri üzerinde eğitilir. Öğrenme aktarımı, bu derin öğrenme ağlarının öğrendiği temsilleri ve özellikleri başka bir göreve uyarlamayı amaçlar. Bir öğrenme aktarımı senaryosunda, önceden eğitilmiş bir derin öğrenme ağı genellikle bir önceden eğitilmiş model olarak adlandırılır. Önceden eğitilmiş model, yeni bir görev için kullanılmak üzere özellik çıkarımı ile hedef göreve özgü temsilleri oluşturmak üzere değiştirilir. Önceden eğitilmiş bir modelin temsilleri, hedef görevde daha iyi bir başlangıç noktası sağlayarak, daha hızlı ve daha etkili bir öğrenme süreci sağlayabilir. Şekil 6'da öğrenme aktarımı ile drone tespit modeli oluşturulmasına ait akış gösterilmiştir.



Şekil 6. Öğrenme aktarımı ile drone nesne tespiti (Drone object detection using transfer learning)

Öğrenme aktarımı teknikleri kullanılarak geliştirilen drone tespit modeli aşağıda belirtilen süreçleri içermektedir:

1. Veri setinin hazırlanması
2. Deney parametrelerinin belirlenmesi
3. Modelin eğitilmesi
4. Modelin değerlendirilmesi ve iyileştirilmesi

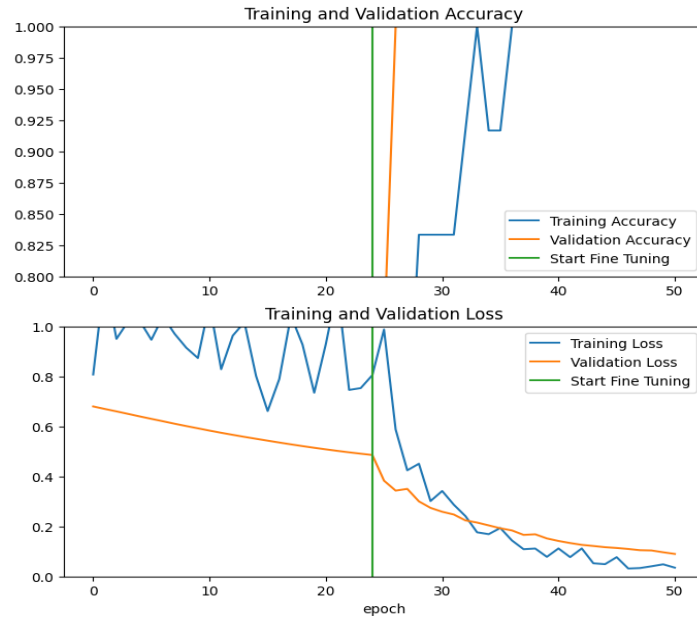
Öğrenme aktarımı deneyleri aynı eğitim verileri kullanılarak 3 farklı şekilde gerçekleştirilmiştir. Tablo 3'te öğrenme aktarımı ile elde edilen modellerin başarı oranları gösterilmiştir.

- model1: Eğitim verilerinin %5'inden 5 iterasyonlu öğrenme aktarımı ile öğrenme
- model2: Eğitim verilerinin %50'sinden 5 iterasyonlu öğrenme aktarımı ile öğrenme
- model3: Eğitim verilerinin %100'ünden 5 iterasyonlu öğrenme aktarımı ile öğrenme
- model4: Eğitim verilerinin %5'inden 25 iterasyonlu öğrenme aktarımı ile öğrenme
- model5: Eğitim verilerinin %50'sinden 25 iterasyonlu öğrenme aktarımı ile öğrenme
- model6: Eğitim verilerinin %100'ünden 25 iterasyonlu öğrenme aktarımı ile öğrenme
- model7: Eğitim verilerinin %5'inden 40 iterasyonlu öğrenme aktarımı ile öğrenme
- model8: Eğitim verilerinin %50'sinden 40 iterasyonlu öğrenme aktarımı ile öğrenme
- model9: Eğitim verilerinin %100'ünden 40 iterasyonlu öğrenme aktarımı ile öğrenme

Tablo 3. Öğrenme aktarımı modellerinin başarı oranları (Success rates of transfer learning models)

Model	Başarı Oranı	Öğrenim Zamanı (Saat)
model1	%83.3	0.000004
model2	%92	0.0001
model3	%97	0.0003
model4	%100	0.0001
model5	%99.1	0.00036
model6	% 99.5	0.00072
model7	%100	0.0003
model8	%98.7	0.0010
model9	%99.7	0.0016

Tablo 3'te verilen deney sonuçlarında model4 ve model7'de aşırı öğrenme olduğu için başarı grafiklerinde gösterilmemiştir. Şekil 7, Şekil 8 ve Şekil 9'da alınan veri sayısına göre elde edilen en iyi başarı oranına ait kayıp performans değerleri gösterilmiştir.



Şekil 7. model1 öğrenme aktarımı ile en iyi alınan sonuç (Best results obtained with transfer learning using model1)



Şekil 8. model5 öğrenme aktarımı ile en iyi alınan sonuç (Best results obtained with transfer learning using model5)



Şekil 9. model9 öğrenme aktarımı ile en iyi alınan sonuç (Best results obtained with transfer learning using model9)

Şekil 9'a göre model9 doğrulama veri kümesinde %99.7'lik bir doğruluk oranı elde etmiştir. Eğitim ve doğrulama kayıp grafikleri göz önüne alındığında, modelin hızla öğrenmeye başladığı ve zamanla kayıpların düştüğü görülmektedir. Ayrıca, doğruluk değerinin 1'e yaklaştığı gözlemlenmiştir. Bu sonuçlar, modelin aşırı öğrenmeden kaçındığını ve yeni veri kümesinde de başarılı olduğunu göstermektedir. Bu çalışma, öğrenme aktarımı yaklaşımının karmaşık görevleri çözmek için güçlü bir yöntem olduğunu ve drone tespiti problemlerinde yüksek doğruluk elde etmenin mümkün olduğunu vurgulamaktadır.

4. Sonuçlar ve Tartışma (Results and Discussion)

Bu çalışmada, drone nesnelere tespiti için öğrenme aktarımı ve derin öğrenme yöntemlerinin etkinliği değerlendirilmiştir. Nesne tespiti alanında birçok farklı model bulunmaktadır ve kullanılacak en iyi model, belirli bir uygulama bağlamında performans, hız ve ölçeklenebilirlik gibi faktörlere bağlıdır. Hangi modelin

kullanılacağı, belirli bir görevin gereksinimlerine ve sınırlamalarına bağlıdır. Örneğin, büyük bir veri seti varsa ve yüksek doğruluk gerekiyorsa, EfficientNet gibi derin modeller tercih edilebilir. Ancak, gerçek zamanlı uygulamalarda hız ön planda ise, YOLO gibi hızlı modeller tercih edilebilir. EfficientNet, küçük boyutlu ve yüksek performanslı olmasıyla bilinen bir modeldir. Bu çalışmada EfficientNet modeli kullanılarak elde edilen sonuçlar, her iki yöntemin de başarılı sonuçlar sunduğunu göstermektedir. Derin öğrenme yöntemiyle eğitilen model %97.3, öğrenme aktarımı yöntemiyle eğitilen model %99.7 tahmin oranı sunmaktadır.

Derin öğrenme yöntemi, büyük veri setlerine ve yüksek hesaplama kaynaklarına ihtiyaç duyduğundan daha uzun bir eğitim süresi gerektirir. Ancak, yüksek doğruluk oranlarına ulaşmak için etkili bir yöntemdir. Derin öğrenme yöntemi, genellikle büyük veri setleriyle eğitildiğinde en iyi performansı gösterir. Ancak, veri seti yeterince büyük değilse veya veri setindeki sınıflar arasında dengesizlik varsa, genelleme yeteneği zayıflayabilir. Ayrıca, derin öğrenme yönteminin eğitim süreci, daha fazla hesaplama kaynağı gerektirdiği için daha uzun sürebilir. Öte yandan, öğrenme aktarımı yöntemi daha hızlı eğitim süresi ve daha az veriyle bile tatmin edici sonuçlar elde etme avantajına sahiptir. Bu yöntemde, önceden eğitilmiş bir model, hedef görev için daha hızlı bir şekilde uyarlanabilir. Veri seti yetersiz olsa bile, önceden eğitilmiş modelin genel bilgisi, yeni görevde iyi bir performans sağlayabilir. Öğrenme aktarımı yöntemi, özellikle veri seti sınırlı olduğunda veya önceden eğitilmiş modelin kullanıldığı alanlarda başarıyla uygulanmaktadır. Nesne tespitinde veri setine drone nesnesine ek olarak kuş nesnelere de dâhil edilmiştir. Daha fazla sınıf eklemenin avantajları, modelin çeşitli nesnelere daha iyi ayırt etme yeteneğini artırabilir. Bu, özellikle benzer görünümlü nesnelere tespiti konusunda modelin güçlü ve hassas olmasını sağlayabilir. Örneğin, kuşları dronelerden ayırt etmek, bu stratejinin etkisini gösteren önemli bir örnek olabilir. Ancak, yeni sınıflar eklerken dikkate alınması gereken bazı faktörler de vardır. Öncelikle, veri setinizin yeterli ve çeşitli olması önemlidir, çünkü her sınıfın temsil edildiği yeterli örnekler, modelin doğru öğrenmesini sağlar. Ayrıca, modelin daha fazla sınıfı öğrenmesi daha karmaşık hale getirebilir ve eğitim sürecini uzatabilir. Bu bağlamda, yeni sınıflar eklerken dengeli bir yaklaşım benimsemek, özellikle nesnelere arasındaki benzerlikleri ve farklılıkları göz önünde bulundurmak önemlidir. Ayrıca, performansın sürekli olarak izlenmesi ve modelin genelleme yeteneğinin korunması için düzenli değerlendirmeler yapılması da önemlidir. Sonuç olarak, sınıf sayısını artırarak başarıyı artırma stratejisi, iyi bir veri seti ve dengeli bir yaklaşım ile birleştirildiğinde etkili olabilir. Ancak, eklenen her sınıfın getirdiği zorlukları ve potansiyel karmaşıklığı anlamak önemlidir. Bu, daha fazla sınıf eklenip eklenmemesi kararını daha bilinçli bir şekilde yönetmenize yardımcı olacaktır.

Bu çalışmada, öğrenme aktarımı yönteminde katman dondurma stratejilerinin de etkisi incelenmiştir. Katman dondurma, GPU belleği kullanımını azaltmak ve eğitim süresini hızlandırmak için etkili bir yöntemdir. Modelde daha fazla katmanın dondurulması, GPU belleği ihtiyacını azaltır ve eğitim süresini kısaltır. Bu, daha büyük modellerin veya daha yüksek çözünürlüklü görüntülerin kullanıldığı durumlarda avantaj sağlar. Ancak, daha fazla katmanın dondurulması, modelin genel performansı üzerinde de etkili olabilir. Bazı durumlarda, daha fazla katmanın dondurulması, doğruluk oranını azaltabilir veya modelin daha yavaş bir şekilde öğrenmesine neden olabilir. Bu nedenle, öğrenme aktarımı yönteminde katman dondurma stratejilerinin dikkatli bir şekilde seçilmesi ve modelin hedef görevde iyi bir performans sergilemesi için deneme yanılma sürecini gerektirebilir. Her iki yöntemde drone nesnelere tespiti konusunda başarılı sonuçlar sağlamaktadır. Hangi yöntemin tercih edileceği, kullanılabilir veri miktarı, hesaplama kaynakları ve hedeflenen doğruluk oranı gibi faktörlere bağlı olacaktır. Elde edilen sonuçlar, önceki benzer çalışmaların sonuçları ile karşılaştırıldığında önemli bir ilerleme sağladığını göstermektedir. Öğrenme aktarımının, özellikle sınırlı veri durumlarında, modelin başarı oranını önemli ölçüde artırdığı ve nesne algılama alanında geniş bir uygulama potansiyeli olduğu vurgulanmaktadır. Bu çalışma, drone tespiti konusunda derinlemesine bir anlayış sağlamak ve gelecekteki benzer çalışmalara temel oluşturmak amacıyla gerçekleştirilmiştir. Gelecekteki çalışmalarda, daha büyük veri setleri ve farklı model mimarileri kullanarak daha kapsamlı araştırmalar yapılabilir. Ayrıca, farklı katman dondurma stratejilerinin etkileri daha ayrıntılı bir şekilde incelenebilir.

Çıkar Çatışması Beyanı (Conflict of Interest Statement)

Yazarlar tarafından herhangi bir çıkar çatışması bildirilmemiştir.

Kaynaklar (References)

[1] G. Marques, D. Agarwal, and I. de la Torre Díez, "Automated medical diagnosis of COVID-19 through EfficientNet convolutional neural network," *Appl Soft Comput*, vol. 96, p. 106691, Nov. 2020, doi: 10.1016/j.asoc.2020.106691.

- [2] M. Tan and Q. V. Le, "EfficientNetV2: Smaller Models and Faster Training," *ArXiv*, Apr. 2021. [Online]. Available: <https://arxiv.org/abs/2104.00298>. [Accessed: Sep. 25, 2023].
- [3] A. K. Kakumani, "Deep Learning Architecture For Classification Of Breast Cancer Cells in Fluorescence Microscopy Images," *International Journal of Advanced Research in Computer Science*, vol. 13, no. 06, pp. 44–44, Dec. 2022, doi: 10.26483/ijarcs.v13i6.6921.
- [4] S. Al-Emadi, A. Al-Ali, and A. Al-Ali, "Audio-Based Drone Detection and Identification Using Deep Learning Techniques with Dataset Enhancement through Generative Adversarial Networks," *Sensors*, vol. 21, no. 15, p. 4953, Jul. 2021, doi: 10.3390/s21154953.
- [5] Z. TAN, M. KARAKÖSE, and E. ÖZET, "Drone Tracking with Drone using Deep Learning," *International Journal of Computer and Information Technology(2279-0764)*, vol. 11, no. 3, Aug. 2022, doi: 10.24203/ijcit.v11i3.238.
- [6] F. Samadzadegan, F. Dadrass Javan, F. Ashtari Mahini, and M. Gholamshahi, "Detection and Recognition of Drones Based on a Deep Convolutional Neural Network Using Visible Imagery," *Aerospace*, vol. 9, no. 1, p. 31, Jan. 2022, doi: 10.3390/aerospace9010031.
- [7] Y. Wang, Y. Chen, J. Choi, and C.-C. J. Kuo, "Towards Visible and Thermal Drone Monitoring with Convolutional Neural Networks," *APSIPA Trans Signal Inf Process*, vol. 8, no. 1, 2019, doi: 10.1017/ATSIP.2018.30.
- [8] Z. Wu, S. Pan, F. Chen, G. Long, C. Zhang, and P. S. Yu, "A Comprehensive Survey on Graph Neural Networks," *IEEE Trans Neural Netw Learn Syst*, vol. 32, no. 1, pp. 4–24, Jan. 2021, doi: 10.1109/TNNLS.2020.2978386.
- [9] L. Aziz, Md. S. Bin Haji Salam, U. U. Sheikh, and S. Ayub, "Exploring Deep Learning-Based Architecture, Strategies, Applications and Current Trends in Generic Object Detection: A Comprehensive Review," *IEEE Access*, vol. 8, pp. 170461–170495, 2020, doi: 10.1109/ACCESS.2020.3021508.
- [10] T. Takahashi, K. Nozaki, T. Gonda, T. Mameno, M. Wada, and K. Ikebe, "Identification of dental implants using deep learning—pilot study," *Int J Implant Dent*, vol. 6, no. 1, p. 53, Dec. 2020, doi: 10.1186/s40729-020-00250-6.
- [11] Y. Fu, "Recent Deep Learning Approaches for Object Detection," *Highlights in Science, Engineering and Technology*, vol. 31, pp. 64–70, Feb. 2023, doi: 10.54097/hset.v31i.4814.
- [12] G.-S. Xia *et al.*, "DOTA: A Large-Scale Dataset for Object Detection in Aerial Images," in *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition*, IEEE, Jun. 2018, pp. 3974–3983. doi: 10.1109/CVPR.2018.00418.
- [13] J. Zhang and D. Tao, "Empowering Things With Intelligence: A Survey of the Progress, Challenges, and Opportunities in Artificial Intelligence of Things," *IEEE Internet Things J*, vol. 8, no. 10, pp. 7789–7817, May 2021, doi: 10.1109/JIOT.2020.3039359.
- [14] N. Zhao, Z. Wu, R. W. H. Lau, and S. Lin, "What makes instance discrimination good for transfer learning?," Jun. 2020. [Online]. Available: <https://arxiv.org/abs/2006.06606>. [Accessed: Dec. 12, 2023].
- [15] S. Shende, "CNN Based Missing Object Detection," *Int J Res Appl Sci Eng Technol*, vol. 11, no. 4, pp. 956–959, Apr. 2023, doi: 10.22214/ijraset.2023.50138.
- [16] S. Agarwal *et al.*, "Unleashing the power of disruptive and emerging technologies amid COVID-19: A detailed review," May 2020. [Online]. Available: <https://arxiv.org/abs/2005.11507>. [Accessed: Sep. 25, 2023].
- [17] I. Athanasiadis, P. Mousoulotiis, and L. Petrou, "A Framework of Transfer Learning in Object Detection for Embedded Systems," Nov. 2018. [Online]. Available: <https://arxiv.org/abs/1811.04863>. [Accessed: Sep. 13, 2023].
- [18] F. Wang *et al.*, "Recent Advances in Fatigue Detection Algorithm Based on EEG," *Intelligent Automation & Soft Computing*, vol. 35, no. 3, pp. 3573–3586, 2023, doi: 10.32604/iasc.2023.029698.
- [19] S. Shen *et al.*, "K-LITE: Learning Transferable Visual Models with External Knowledge," Apr. 2022. [Online]. Available: <https://arxiv.org/abs/2204.09222>. [Accessed: Sep. 13, 2023].
- [20] I. T. Plata, E. B. Panganiban, D. B. Alado, A. C. Taracatac, B. B. Bartolome, and F. R. E. Labuanan, "A Recognition Method for Cassava Phytoplasma Disease (CPD) Real-Time Detection based on Transfer Learning Neural Networks," *International Journal of Advanced Computer Science and Applications*, vol. 12, no. 12, 2021, doi: 10.14569/IJACSA.2021.0121234.
- [21] M. M. Rahaman *et al.*, "Identification of COVID-19 samples from chest X-Ray images using deep learning: A comparison of transfer learning approaches," *J Xray Sci Technol*, vol. 28, no. 5, pp. 821–839, Sep. 2020, doi: 10.3233/XST-200715.
- [22] M. E. H. Chowdhury *et al.*, "Can AI Help in Screening Viral and COVID-19 Pneumonia?," *IEEE Access*, vol. 8, pp. 132665–132676, 2020, doi: 10.1109/ACCESS.2020.3010287.
- [23] C. Zhu, J. Liang, and F. Zhou, "(Retracted) Transfer learning-based YOLOv3 model for road dense object detection," *J Electron Imaging*, vol. 32, no. 06, Jan. 2023, doi: 10.1117/1.JEI.32.6.062505.
- [24] Saha, I., "drone-bird classification," [Online]. Available: <https://www.kaggle.com/datasets/imbikramsaha/drone-bird-classification> [Accessed: Dec. 25, 2023].

* This paper was presented at the 5th International Conference on Artificial Intelligence and Applied Mathematics in Engineering (ICAIAEME 2023) and the

abstract was published as an e-book.

This is an open access article under the CC-BY license

