

**T.C.
İSTANBUL GEDİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**



**EVRİŞİMSEL SİNİR AĞI KULLANILARAK İNSANSIZ HAVA
ARACI TESPİT UYGULAMASI**

YÜKSEK LİSANS TEZİ

Ahmed Fouad Kadhim KOYSHA

Elektrik ve Elektronik Mühendisliği Anabilim Dalı

Elektrik ve Elektronik Mühendisliği Tezli Yüksek Lisans Programı

**ARALIK 2023
İSTANBUL**

**T.C.
İSTANBUL GEDİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**



**EVİRİŞİMSEL SİNİR AĞI KULLANILARAK İNSANSIZ HAVA
ARACI TESPİT UYGULAMASI**

YÜKSEK LİSANS TEZİ

**Ahmed Fouad Kadhim KOYSHA
(211280001)
0009-0004-2967-724X**

Elektrik ve Elektronik Mühendisliği Anabilim Dalı

Elektrik ve Elektronik Mühendisliği Tezli Yüksek Lisans Programı

Tez Danışmanı: Dr. Öğr. Üyesi Aytaç Uğur YERDEN

İstanbul 2023



T.C.
İSTANBUL GEDİK ÜNİVERSİTESİ
Lisansüstü Eğitim Enstitüsü Müdürlüğü

Jüri Tez Onay Formu

11.12.2023

LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ MÜDÜRLÜĞÜ

Bu çalışma 11.12. 2023 tarihinde aşağıdaki jüri tarafından Elektrik ve Elektronik Mühendisliği Anabilim Dalı, Elektrik ve Elektronik Mühendisliği (Tezli Yüksek Lisans) Programı Yüksek Lisans Tezi olarak kabul edilmiştir.

TEZ JÜRİSİ

Dr. Öğr. Üyesi Aytaç Uğur YERDEN

Danışman

İstanbul Gedik Üniversitesi

Prof. Dr. Feriha ERFAN KUYUMCU

Üye (İmza)

İstanbul Gedik Üniversitesi

Dr. Öğr. Üyesi Onur AKAR

Üye (İmza)

Marmara Üniversitesi

YEMİN METNİ

Yüksek Lisans tezi olarak sunduğum “Evrişimsel Sinir Ağı Kullanılarak İnsansız Hava Aracı Tespit Uygulaması” adlı çalışmanın, bilimsel ahlak ve geleneklere uygun şekilde tarafımdan yazıldığını, bu tezdeki bütün bilgileri akademik ve etik kurallar içinde elde ettiğimi, yararlandığım eserlerin tamamının kaynaklarda gösterildiğini ve çalışmamın içinde kullanıldıkları her yerde bunlara atıf yapıldığını, patent ve telif haklarını ihlal edici bir davranışımın olmadığını belirtir ve bunu onurumla doğrularım (11/12/2023).

Ahmed Fouad Kadhim KOYSHA

ÖNSÖZ

Bu yüksek lisans tezi, "Evrişimsel Sinir Ağı (ESA) Kullanılarak İnsansız Hava Aracı Tespit Uygulaması" başlığı altında gerçekleştirilen bir araştırmanın sonucunu sunmaktadır. Bu çalışma, insansız hava araçlarının tespiti konusundaki önemli bir sorunu ele almaktadır ve bu alandaki yenilikçi bir yaklaşımı tanıtmaktadır. İnsansız hava araçları (İHA'lar), sivil ve askeri uygulamalarda giderek artan bir şekilde kullanılmaktadır. Ancak, bu artan kullanım, gizlilik ihlali, güvenlik tehditleri ve kamusal güvenlik kaygılarına yol açmaktadır. Bu nedenle, İHA'ların tespit edilmesi ve izlenmesi büyük bir önem taşımaktadır. Bu tez, Evrişimsel Sinir Ağı (ESA) temelli bir tespit sistemi geliştirme amacını taşımaktadır. ESA'lar, görüntü işleme ve nesne tanıma alanında büyük bir başarı elde etmiş derin öğrenme yöntemleridir. Bu tez, ESA kullanarak İHA'ların otomatik tespiti için bir çözüm sunmaktadır. Prof. Dr. Feriha ERFAN KUYUMCU'ya ve tez danışmanım Dr. Öğr. Üyesi Aytaç Uğur YERDEN, bu çalışmanın başarılı bir şekilde tamamlanmasında ve değerli önerileriyle yol gösterdikleri için teşekkür ediyorum. Ayrıca, bu çalışmanın laboratuvar çalışmalarında, veri toplamada ve analizlerde yardımcı olan herkese teşekkür ederim. Bu tez, insansız hava araçlarının tespiti konusunda yeni bir yaklaşım sunma çabasıdır. Umarım, bu çalışma bu alandaki bilimsel ve teknolojik gelişmelere katkıda bulunur. Son olarak, bu tezin tamamlanmasında desteklerini esirgemeyen aileme ve arkadaşlarıma teşekkür ederim.

Aralık 2023

Ahmed Fouad Kadhim KOYSHA

İÇİNDEKİLER

	<u>Sayfa</u>
ÖNSÖZ.....	iv
İÇİNDEKİLER	v
KISALTMALAR	vii
ÇİZELGE LİSTESİ.....	viii
ŞEKİL LİSTESİ.....	ix
ÖZET.....	x
ABSTRACT	xi
1. GİRİŞ	1
1.1 İnsansız Hava Araçları	2
1.2 Çalışmanın Önemi.....	3
1.3 Yapay Zeka, Makine Öğrenmesi ve İHA'lar Arasındaki İlişkiler	4
1.4. Araştırmanın Sınırlılıkları	7
1.5. Tezin Yapısı	8
2. ARKAPLAN VE LİTERATÜR TARAMASI.....	10
2.1 Yapay Sinir Ağları Tarihiçesi	10
2.2 Makine Öğrenme.....	11
2.2.1 Makine öğrenme tipleri	12
2.2.2 Makine öğrenme özellikleri	12
2.2.3 Makine öğrenme genelleme	12
2.3 Sinir Ağları.....	13
2.3.1 Kökenler (hücreler) (neuron)	13
2.3.2 Çok katmanlı ağlar	14
2.3.3 Geri -yayılım	15
2.3.4 Aktivasyon fonksiyonu tipleri.....	16
2.3.5 Derin öğrenme.....	17
2.4. Bilgisayar Görüşü.....	18
2.5. Evrişimli Sinir Ağları ve Derin Öğrenme	19
2.5.1. Evrişim katmanı	20
2.5.2. Havuzlama ve adımlama	22
2.5.3. Ek katmanlar	23
2.5.4. İyileştirme ve veri artırma.....	24
2.6. Nesne Algılama Teknolojileri	24
2.6.1. Optik olmayan yaklaşımlar	25
2.6.1.1. Akustik tespit	25
2.6.1.2. Radar tespit.....	25
2.6.1.3. Radyo frekansı tespiti.....	25
2.6.2 Optik yaklaşımlar	25
2.6.2.1. El ile oluşturulan özellik çıkarımı kullanan yaklaşımlar	26
2.6.2.2. Derin öğrenmeyi kullanan yaklaşımlar	26
2.6.2.2.1 İki aşamalı nesne tespiti	26
2.6.2.2.2 Tek aşamalı nesne tespiti	27

2.7. Literatür Taraması	30
3. MATERYAL VE YÖNTEM	46
3.1. Veri Seti Hazırlama Araçları	46
3.1.1 Açık kaynak kullanılabilen veri kümesi	46
3.1.2 Gerçek dünya veri kümesi	47
3.1.3 Fotorealistik görüntülerle sentetik veri kümesi oluşturma	47
3.1.4 Roboflow çerçevesi	49
3.1.5 Veri kümesi ön işleme	50
3.1.6 Modellerin eğitilmesi ve test edilmesi	51
3.2 İnsansız Hava Aracı Tespit Sistemi Tasarımı ve Uygulaması	53
4. BULGULAR VE TARTIŞMA	56
5. SONUÇ	63
KAYNAKLAR	65
ÖZGEÇMİŞ	72

KISALTMALAR

Artıklı Blok	: ResNet Yapısına Sahip Tekrarlanan Konvolüsyonel Katmanlar
batch size	: Bloğun Çıkış Boyutu (Output Size)
CNN	: Evrişimli Sinir Ağı (Convolutional Neural Network)
DD (HSV)	: Ton-Doyma-Değer(Hue-Saturation-Value)
ESA	: Evrişimsel Sinir Ağı
Evrişimsel	: Konvolüsyonel Katman (lar)
FCN (TEA)	: Fully Convolutional Network (Tamamen Evrişimli Ağ)
İHA	: İnsansız Hava Aracı
KCF	: Kernelized Correlation Filter
ReLU	: Rektifiye Lineer Aktivasyon Fonksiyon
RoI	: İlgi Bölgeleri (Regions of Interest)
RPN	: Bölge Öneri Ağı (Region Proposal Network)
s2	: Adımı 2 Olan (Stride of 2) Konvolüsyonel Katman
TAÇKD (SSD)	: Tek Atışlı Çok Kutulu Dedektör (Single Shot MultiBox Detector)
YGH (HOG)	: Yönlendirilmiş Gradyanların Histogramı (Histogram of Oriented Gradients)
YOLO	: You Only Look Once
YSA	: Yapay Sinir Ağı

ÇİZELGE LİSTESİ

	<u>Sayfa</u>
Çizelge 2.1: Araştırma Sonuçları Tablosu.....	33
Çizelge 2.2: Sonuçlar Tablosu.....	35
Çizelge 2.3: Makalenin Ana Sonuçlarını ve Önemli Metrikleri.....	36
Çizelge 2.4: İHA Tespiti İçin ESA Mimarileri ve Bulguları.....	43

ŞEKİL LİSTESİ

	<u>Sayfa</u>
Şekil 1.1: Çeşitli Alanlarda Kullanılan İHA'lar	2
Şekil 1.2: Pratikte Görme Kavramı	5
Şekil 2.1: Yapay Sinir Hücre	13
Şekil 2.2: Tam Bağlantılı Çok Katmanlı Yapay Sinir Ağı	15
Şekil 2.3: Bir Görüntüden Evrişim Filtrelemesi Kullanarak Yatay Kenarları Tespit Etme	21
Şekil 2.4: Bir Evrişimli Sinir Ağı Örneği	22
Şekil 2.5: İki Aşamalı Nesne Tespit Yapısının Bir Örneği	27
Şekil 2.6: Tek Aşamalı Nesne Algılama Yapısının Bir Örneği	28
Şekil 2.7: YOLOv3 Yapı	29
Şekil 3.1: Roboflow Etiketlemek Sonuç	49
Şekil 3.2: İHA Etiketlemek İçin Roboflow Çerçevesini Kullanma	50
Şekil 3.3: RoboFlow Veri Artırma Kullanımı	51
Şekil 3.4: Veri Kümesini Ayırmak İçin RoboFlow Kullanımı	52
Şekil 3.5: YOLOV5 Modelini Google VM'ye Klonlama	52
Şekil 3.6: Sistem Akışı	53
Şekil 3.7: YMAL Dosya Ayarları	55
Şekil 3.8: Artırılmış Veri Kümesi	55
Şekil 4.1: Önerilen Fine-Tuned Modelin Eğitim Sürecindeki Performanstaki İlerleme	56
Şekil 4.2: Önerilen Fine-Tuned Model Kullanılarak Eğitim Setinde Drone Nesnelerinin Algılanması İçin Hassasiyet-Hatırlama Eğrisi	57
Şekil 4.3: Önerilen Modelin, Test Veri Kümesindeki Görüntülerle Drone Algılama İşlemi	58
Şekil 4.4: Diğer Yaklaşımlarla Karşılaştırma	58
Şekil 4.5: Behera ve Bazil Tarafından Önerilen Yaklaşımın Eğitilirken Kayıp Değerinin İlerleyişi	59
Şekil 4.6: Tan ve Diğerleri Tarafından Önerilen Yöntemin Eğitilirken Kayıp Değerinin İlerleyişi	60
Şekil 4.7: Eğitilmiş Modeller Tarafından Eğitim Veri Kümesi İçin Elde Edilen Hassasiyet (Precision), Geri Çağırma (Recall) ve mAP Sonuçları	61
Şekil 4.8: (Behera ve Bazil (2020) ve (Tan ve diğ., 2021) Tarafından Elde Edilen Test Veri Kümesine Dayalı Tespit Doğruluğu ile Önerilen Modelin Karşılaştırılması	61

EVRIŞİMSEL SİNİR AĞI KULLANILARAK İNSANSIZ HAVA ARACI TESPİT UYGULAMASI

ÖZET

Bu tez, evrişimsel sinir ağı (ESA) kullanarak insansız hava aracı (İHA) tespiti ve sınıflandırması için yeni bir yaklaşım sunar. Bu çalışmanın amacı, İHA'ların tespitinde ve sınıflandırılmasında doğruluk ve etkinliği artırmak, böylece savunma ve güvenlik alanlarındaki uygulamalar için güvenilir bir araç oluşturmaktır. Son yıllarda hızla gelişen bir teknoloji olmasına karşın, tespiti ve tanımlanması konusunda hala ciddi sorunlar ve meydan okumalar bulunmaktadır. Modern bir nesne algılama modeli olan YOLOv5'i kullanarak yeni bir yaklaşım sunmaktadır. Temel amaç, İHA'ların doğruluğunu ve etkinliğini artırarak savunma ve güvenlik alanlarında güvenilir bir araç geliştirmektir. İHA'ların tespiti ve sınıflandırılması, güvenlik, savunma, hava sahası yönetimi ve endüstriyel uygulamalar gibi birçok alanda büyük öneme sahiptir ve teknolojik gelişmeler, daha güvenli ve verimli bir geleceğe katkı sağlayabilir. Bu nedenle, modern nesne algılama teknikleri, özellikle YOLOv5'in kullanılması hem akademik hem de endüstriyel düzeyde büyük bir katkı sağlamaktadır. Çalışma sürecinde, gerçek hayatta çekilmiş İHA görüntüleri ile sentetik verilerden oluşan bir veri seti oluşturulmuştur. Bu veri seti, özelleştirilmiş bir ESA modelini eğitmek için kullanılmıştır. Eğitim sürecinde, çeşitli hiper parametreler ve faktörler dikkate alınmış ve katmanların dondurulması ve sentetik Gauss gürültüsünün eklenmesi gibi tekniklerin performans üzerindeki etkisi incelenmiştir. Bu metodoloji, İHA tespitinde ve sınıflandırmasında ESA'nin yüksek doğruluk oranlarına ulaştığını göstermiştir. Model, farklı İHA tiplerini doğru bir şekilde tespit edip sınıflandırabilmiştir, bu da gerçek zamanlı tespit ve İHA tabanlı tehditlere karşı savunma sistemlerinin geliştirilmesinde değerli bir araç olduğunu kanıtlamıştır. Sonuç olarak, evrişimsel sinir ağları ve İHA tespiti ve sınıflandırmasındaki zorlukları aşmada etkili bir yol sunan YOLO algoritması, bu tezle öne çıkmaktadır. Bu, İHA'ların güvenlik, savunma ve benzeri alanlarda daha etkin bir şekilde kullanılmasını destekleyecek önemli bilgiler sunmaktadır.

Anahtar Kelimeler: *Evrişimsel Sinir Ağı, Faster RCNN, İnsansız Hava Aracı, Tespit Uygulaması, 3D Modelleme*

UNMANNED AERIAL VEHICLE DETECTION APPLICATION USING CONVOLUTIONAL NEURAL NETWORK

ABSTRACT

This thesis presents a new approach to unmanned aerial vehicle (UAV) detection and classification using Convolutional Neural Networks (CNNs). The primary aim of this study is to enhance the accuracy and effectiveness of UAV detection and classification, thereby creating a reliable tool for applications in defense and security fields. It introduces a novel approach by utilizing YOLOv5, a modern object detection model. The fundamental objective is to improve the accuracy and effectiveness of UAV detection, thereby creating a reliable tool for defense and security applications. UAV detection and classification hold significant importance in various domains such as security, defense, airspace management, and industrial applications, and technological advancements in this area can contribute to a safer and more efficient future. Therefore, the utilization of modern object detection techniques, particularly YOLOv5, holds great promise in both academic and industrial contexts. During the research process, a comprehensive dataset was compiled, consisting of real-world UAV images and synthetic data. This dataset was used to train a customized YOLOv5 model. Throughout the training process, various hyperparameters and factors were meticulously considered, and techniques like layer freezing and the addition of synthetic Gaussian noise were examined for their impact on performance. This methodology demonstrated that YOLOv5 achieved high accuracy rates in UAV detection. The model accurately detected and classified different UAV types, showcasing its value as a tool for real-time detection and defense against UAV-based threats. In conclusion, the YOLO algorithm offers an effective approach to overcome challenges in CNN-based UAV detection and classification, making it a standout feature of this thesis. It provides valuable insights that support the more efficient utilization of UAVs in security, defense, and related fields.

Keywords: *Convolutional Neural Networks, Faster RCNN, Unmanned Aerial Vehicle, Detection Application, 3D Modelling, Drone Model Classification*

1. GİRİŞ

İnsansız Hava Araçları (İHA), hem askeri hem de sivil uygulamalar açısından hızla gelişen ve yaygınlaşan bir teknoloji olmuştur. İHA'ların etkin kullanımı, bir dizi görevi yerine getirme yeteneği ile kanıtlanmıştır. Ancak, karmaşık hava sahalarında İHA'ların güvenlik ve uyumluluk açısından doğru bir şekilde tespit edilmesi kritik bir öneme sahiptir (Göktürk Çetinkaya ve Koç, 2023). Bu çalışma, İHA tespiti ve sınıflandırması konusunda ilerlemeyi amaçlamakta ve bu amaçla Evrişimsel Sinir Ağı (ESA) tekniklerini kullanmaktadır. ESA, görüntü işleme ve nesne tespiti alanlarında son yıllarda önemli başarılar elde etmiş bir derin öğrenme yöntemidir (LeCun vd., 2015). İHA'ların farklı boyutlar, açılar ve arka plan koşulları altında bulunan görüntülerini işleyebilme yeteneği, bu teknolojinin seçilmesinde kritik bir faktördür. Güvenlik, savunma ve benzeri alanlarda kullanılan İHA sistemlerinin performansını artırmak için İHA tespiti ve sınıflandırılması konusunda daha gelişmiş ve etkili bir yöntem sunma ihtiyacı, bu çalışmanın diğer bir amacını oluşturmaktadır. İHA'ların doğru tespiti ve sınıflandırılması, optimize edilmiş bir algoritmanın geliştirilmesini gerektiren zorlu bir görevdir (Krizhevsky vd., 2012). Bu nedenle, çalışmanın hedefi İHA tespiti konusunda ileri düzeyde araştırmalar yapmak ve ESA kullanarak daha güvenilir ve doğru sonuçlar elde etmektir. Bu süreçte YOLO mimarisini kullanmaktadır. YOLO v5 nesne tespiti için popüler bir derin öğrenme çerçevesidir ve sınıflandırma ve tespit işlemlerini bir arada sunmasıyla bilinir (Girshick, 2015). İHA'ların karmaşık görüntülerini işleyebilme ve doğru şekilde sınıflandırabilme yeteneği, bu çerçevenin bu çalışma için ideal bir seçenek olmasını sağlar.

Bu çalışmanın sonuçları, hem akademik araştırmaları ilerletme potansiyeline sahip olabilir hem de endüstriyel uygulamalara yönelik kullanışlı bilgiler sunarak İHA teknolojisinin gelişimine katkı sağlayabilir.

1.1 İnsansız Hava Araçları

İnsansız hava araçları, günümüzde hem askeri hem de sivil alanlarda çeşitli görevlerde kullanılmaktadır. İstihbarat toplama, keşif görevleri, güvenlik operasyonları, doğal afetlerin izlenmesi ve tarımsal uygulamalar gibi geniş bir uygulama yelpazesine sahip olan İHA'lar, erişim zorluğu veya riskli durumlar gibi durumlarda önemli bir araçtır (Göktürk Çetinkaya ve Koç, 2023). Farklı sektörlerde geniş bir yelpazede kullanılan çeşitli İHA tipleri Şekil 1.1'de gösterilmektedir. Bu kapsamda a) Tarım alanında kullanılan İHA'lar, b) Milli savunma amaçları için geliştirilen ANKA-S gibi askeri İHA'lar ve c) Görüntü yakalama ve fotoğrafçılık alanlarında sıkça kullanılan İHA'lar gibi örnekler verilebilir.



Şekil 1.1: Çeşitli Alanlarda Kullanılan İHA'lar

Kaynak: (Ergunsah ve Kosunalp, 2022)

Gelişen teknoloji ile birlikte, İHA'ların kullanımı ve işlevselliği sürekli olarak artmakta, yeni kullanım alanları keşfedilmekte ve geliştirilmektedir. Ancak, bu hızlı gelişme beraberinde bazı zorlukları da getirir. Özellikle güvenlik açıklıkları, hava trafik yönetimi, yüksek maliyetler ve enerji verimliliği konularında çözüm bulunması gereken önemli sorunlar bulunmaktadır. Bilgi güvenliği, İHA'ların birçok uygulamasında kritik bir öneme sahip olan bir alan olup, İHA'ların hassas verileri taşıdığı veya hassas bölgelerde kullanıldığı durumlarda bilgisayar korsanlarına karşı savunmasız kalabilmektedir. Bunun yanı sıra, İHA'ların sayısındaki artış, hava trafik yönetimini karmaşık hale getirerek İHA'ların ve diğer hava araçlarının güvenli bir şekilde uçuş yapabilmesi için etkin bir hava trafik yönetimi sistemine ihtiyaç duyulmasını gündeme getirmiştir. Buna ek olarak, İHA'ların üretimi, bakımı ve

iřletilmesi genellikle yksek maliyetli olup, bu durum İHA'ların daha yaygın ve erişilebilir hale gelmesini zorlařtırmaktadır. Enerji verimlilięi konusunda ise, İHA'ların uçuř sreleri ve grev yetenekleri, kullanılan bataryaların mr ve enerji verimlilięi ile doęrudan ilişkilidir.

Trkiye'nin İHA teknolojisi alanındaki geliřimi, bu alanda dikkat çekici ve nemli bir katkı saęlamıřtır. Modern sanayi devriminin getirdięi olanaklar ve teknolojik geliřmeler sayesinde, Trkiye, insansız hava araları teknolojisinin hızlı bir řekilde geliřimine katkıda bulunmuřtur (Gktrk etinkaya ve Ko, 2023). Bu, hem Trkiye'nin bu alanda ilerleme kaydetmesinin hem de İHA teknolojisinin daha geniř bir kullanım alanı bulmasının nn amıřtır. İHA teknolojisi hızla geliřen bir alan olup, bu alanda Trkiye'nin gsterdięi geliřme ve katkılar da dikkat çekicidir. Bununla birlikte, İHA teknolojisinin daha da geliřtirilmesi ve kullanımının yaygınlařtırılması iin zm bekleyen bazı nemli sorunlar bulunmaktadır. İHA teknolojisinin gelecekteki geliřimi, bu sorunların nasıl ele alındıęı ve zldęne baęlı olacaktır.

1.2 alıřmanın nemi

İnsansız hava araları, son yıllarda hızla geliřen bir teknoloji olmasına karřın, tespiti ve tanımlanması konusunda hala ciddi sorunlar ve meydan okumalar bulunmaktadır. Bu baęlamda, İHA'ların tespitine ynelik akademik arařtırmalar, bu alandaki sorunları zmede hayati bir role sahiptir. İHA tespiti, birok farklı sektrdeki kritik iřlevlere hizmet etmektedir. Bu alanlar arasında askeri gvenlik, sivil hava sahası ynetimi, kamu gvenlięi ve kiřisel gizlilik bulunmaktadır. İHA'ların etkili ve doęru bir řekilde tespit edilmesi, potansiyel tehditlerin erken tanımlanmasını, gizlilik ihlallerinin nlenmesini ve hava trafięinin gvenli bir řekilde ynetilmesini mmkn kılar. zellikle havaalanları, askeri sler, halka aık etkinlikler ve kritik altyapı tesisleri gibi hassas alanlarda İHA tespiti, gvenlięin ve dzenin korunmasında hayati neme sahiptir (Smith vd., 2022).

Akademik erevede, İHA tespiti konusundaki arařtırmalar, bu alanda inovasyon ve geliřme iin nemli bir potansiyele sahiptir. Yeni sensr teknolojileri, veri analitik teknikleri ve tespit yntemlerinin keřfi ve geliřtirilmesi, gvenlik hizmetleri, hava trafik ynetim kuruluřları ve dięer ilgili kuruluřlara etkin ve gvenli operasyonlar gerekleřtirme konusunda yardımcı olabilir (Johnson vd., 2023).

Endüstriyel ve ticari açıdan bakıldığında, İHA tespiti üzerine yapılan çalışmalar da büyük bir öneme sahiptir. İHA'ların ticari ve sivil kullanımının hızla arttığı bir dönemde, güvenilir ve etkili tespit sistemlerinin geliştirilmesi ve uygulanması, bu endüstrinin sürdürülebilir ve kontrollü büyümesine katkıda bulunabilir (Lee vd., 2021).

1.3 Yapay Zeka, Makine Öğrenmesi ve İHA'lar Arasındaki İlişkiler

Yapay zekanın keşfi ve insan zihninin makineyle simülasyonu üzerinden yarım asırdan fazla bir zaman geçmiştir (Goodfellow vd., 2016). Yapay zeka, insan zekasını taklit etmek veya simüle etmek için bilgisayar sistemlerinin kullanılması anlamına gelir. Makine öğrenmesi ise yapay zekanın bir alt dalı olup, bir bilgisayarın belirli bir görevi gerçekleştirmek için verilerden öğrenme yoluyla bilgi kazanmasını sağlayan algoritmaları içerir (Mitchell, 1997). Makine öğrenmesi, insan beyninin kullanılması gereken ve zekaya ihtiyaç duyan alanlarda bir makinenin karar vermesini sağlayabilir. Özellikle büyük veri setleri veya karmaşık problemlerle ilgili kararlar almak için makine öğrenmesi teknikleri kullanılır (Bishop, 2006).

Son yıllarda internet teknolojisinin hızlı gelişimi, beşinci nesil internetin yaygınlaşması ve akıllı telefonların kullanımı, makine öğrenmesi için algoritmaların ve komutların yalnızca insansız hava araçları gibi belirli alanlarla sınırlı olmadığını göstermiştir. Bu algoritmalar ve komutlar, farklı mühendislik ve bilgi alanlarında da yaygın olarak kullanılmaktadır (LeCun vd., 2015).

İHA'lar, yapay zeka, makine öğrenimi ve algoritmalara dayalı çalışmalar sayesinde hızlı bir şekilde gelişmiştir. İHA'lar sadece askeri alanda veya silahlı kuvvetlerde değil, günlük yaşamın temel ihtiyaçlarını karşılamak veya ticari pazarda kullanılmak üzere ticari olarak da geliştirilmektedir (Fossen, 2020). Ticari şirketler, ölçeklenebilir Python veya diğer programlama dillerini kullanarak makine öğrenmesi ve derin öğrenme için özel algoritmalar geliştirmek ve İHA'lar üretmek için birbirleriyle rekabet etmektedirler. Bu şirketler, İHA'lar için geliştirilen algoritmaların ve uygulamaların ilerlemesine öncülük etmişlerdir (Russell ve Norvig, 2016). İHA tespiti alanında yapılan araştırmalar, evrişimli sinir ağlarının etkinliği ve performansı üzerinde odaklanmaktadır. Evrişimli sinir ağları, derin öğrenme yöntemleri arasında sıkça kullanılan bir yapay sinir ağı türüdür. Özellikle İHA tespiti için evrişimli sinir ağları kullanılarak İHA görüntülerinin analizi yapılmaktadır

(Krizhevsky vd., 2012). Evriřimli sinir aęları, grntleri kk paralara bler ve her bir parayı ayrı ayrı analiz ederek İHA'ları tanımak iin gerekli zellikleri ğrenir. Bu yntem, İHA tespiti iin daha kesin ve doęru sonular elde edilmesini saęlar (Szegedy vd., 2015). řekil 1.2’de sarı bir taksi ve yol kenarına park etmiř bir kamyon grlmektedir.



řekil 1.2: Pratikte Grme Kavramı

Kaynak: (Amini, 2022)

Grntdeki detaylar ve grme kavramıyla ilgili ayrıntıları daha da geniřletebiliriz. rneęin, sarı taksi ve beyaz kamyonun yanı sıra dięer araların ve yayaların hareketi, trafik akıřı ve gvenlięi aısından nemlidir. İnsanlar, trafikteki nesnelerin konumunu, hızını ve ynelimini algılayarak gvenli bir řekilde hareket edebilirler. Benzer řekilde, İHA'lar da bu tr bilgileri algılayarak otonom uuř yapabilir veya trafik denetimi ve gvenlięi iin kullanılabilir.

Grme algoritmaları ve İHA'lar arasındaki baęlantılar da nemlidir. İHA'lar, grnt iřleme ve nesne algılama tekniklerini kullanarak evrelerini analiz edebilir ve kararlar alabilirler. rneęin, bir İHA, bir kaza durumunda hızlı bir řekilde olay yerine ulařabilir, hasar tespiti yapabilir veya kurtarma operasyonlarına yardımcı olabilir. Grme algoritmaları aynı zamanda İHA'ların engelleri algılamasını, gvenli bir řekilde manevra yapmasını ve navigasyonunun iyileřtirilmesini saęlayabilir. İHA'larla birlikte kullanılan grme teknolojileri, farklı sektrlerde birok fayda saęlar. rneęin, tarım sektrnde İHA'lar, bitki hastalıklarını tespit etmek, tarım alanlarını haritalamak ve tarım verimlilięini artırmak iin grnt analizi yapabilirler. İnřaat sektrnde İHA'lar, yapı denetimi, inřaat ilerlemesi izleme ve gvenlik gzetimi gibi alanlarda kullanılabilir.

Bilgisayarla görme veya computer vision, bilgisayar sistemlerine görsel verileri anlamaları ve yorumlamaları için yetenek kazandıran bir alan olarak tanımlanabilir. Görüntü işleme, desen tanıma, nesne algılama, nesne takibi ve görüntü sınıflandırma gibi teknikleri içerir. Gelişmiş algoritmalar ve derin öğrenme yöntemleri kullanarak, bilgisayarlar görüntülerden anlam çıkarabilir, nesneleri tanıyabilir, hareketi algılayabilir ve karmaşık görevleri gerçekleştirebilir hale gelir. İnsansız hava araçları ve bilgisayarla görme arasında güçlü bir bağlantı vardır. İHA'lar, görüntü işleme ve nesne algılama tekniklerini kullanarak çevrelerini algılayabilir ve görsel verileri analiz edebilirler. Bu sayede İHA'lar, otonom uçuş, nesne takibi, engelleri algılama, haritalama, hedef tespiti gibi görevleri gerçekleştirebilirler. Bilgisayarla görme, İHA'ların birçok alanda fayda sağlamasını sağlar. Örneğin, güvenlik ve savunma alanında İHA'lar, görüntü işleme ve nesne algılama algoritmalarını kullanarak tehlikeli bölgeleri izleyebilir, sınırları koruyabilir ve hedefleri tespit edebilir. Tarım sektöründe ise İHA'lar, bitki sağlığını izlemek, tarım alanlarını haritalamak ve verimliliği artırmak için görüntü işleme tekniklerini kullanabilir.

İHA'ların bilgisayarla görme teknolojileriyle entegre olması, daha akıllı ve özerk İHA sistemlerinin geliştirilmesine olanak sağlar. Örneğin, İHA'lar, çevrelerini algılayarak engelleri otomatik olarak tespit edebilir ve çarpışmalardan kaçınabilir. Aynı zamanda, nesne takibi algoritmalarıyla hareketli hedefleri izleyebilir ve görevleri gerçekleştirebilir. Bu da İHA'ların verimliliğini ve etkinliğini artırır. Bilgisayarla görme aynı zamanda İHA'lar için bir veri toplama ve analiz aracı olarak da kullanılabilir. İHA'lar, yüksek çözünürlüklü kameralar aracılığıyla görsel verileri toplayabilir ve bu verileri analiz ederek çeşitli uygulamalarda kullanılabilir. Örneğin, çevresel değişiklikleri izlemek, çevresel hasarları tespit etmek veya haritalama yapmak için görüntü verilerini kullanabilir. İHA'ların bilgisayarla görme teknolojisiyle birleşmesi, birçok sektörde çeşitli uygulamaları beraberinde getirir. Örneğin, tarım sektöründe İHA'lar, tarım alanlarını izleyerek bitki hastalıklarını tespit edebilir ve tarım verimliliğini artırmak için gerekli önlemleri alabilir. İnşaat sektöründe İHA'lar, inşaat ilerlemesini izleyerek süreçleri optimize edebilir ve güvenlik gözetimi yapabilir. Arama kurtarma operasyonlarında İHA'lar, görüntü analizi ve nesne algılama yetenekleri sayesinde kayıp veya tehlikede olan kişilerin tespitinde yardımcı olabilir.

Ayrıca, güvenlik ve savunma alanında İHA'lar ve bilgisayarla görme teknolojisi birlikte kullanılarak sınırları izleme, tehlikeli bölgeleri tarayarak riskleri belirleme ve hızlı müdahale yapma gibi görevler gerçekleştirilebilir. Yangın söndürme operasyonlarında İHA'lar, görüntü analiziyle yangının yayılmasını izleyebilir ve yangına müdahale stratejilerine destek olabilir. Ayrıca, trafik denetimi ve kentsel planlama gibi alanlarda da İHA'lar ve bilgisayarla görme teknolojisi kullanılarak trafik akışı ve güvenliği iyileştirilebilir.

Bu tezde, derin öğrenme ve evrişimli sinir ağı kullanarak programlanmış bir görme duyusu ve otomatik analize dayalı bir savunma sistemi geliştirilmesi hedeflenmektedir. Bu sistem, İHA'ların çevrelerini algılamalarını, nesneleri tanımlarını ve olayları analiz etmelerini sağlayacak. Elde edilen sonuçlar, İHA teknolojilerinin güvenlik ve savunma alanlarında daha etkili bir şekilde kullanılmasını sağlayacaktır.

1.4. Araştırmanın Sınırlılıkları

Araştırmalar her zaman belirli sınırlamalarla karşılaşabilir ve bu sınırlamaların bilincinde olmak, yapılan çalışmanın güvenilirliği ve geçerliliği açısından önemlidir. İnsansız hava araçları tespiti alanında yapılan araştırmalar da belirli sınırlamalara tabidir. Bu bölümde, bu tür araştırmaların potansiyel sınırlamaları aşağıda ele alınmıştır:

Birinci olarak, İHA tespiti için evrişimli sinir ağı (ESA) kullanımıyla ilgili bazı sınırlamalar mevcuttur. ESA'ler, görüntü tanıma ve sınıflandırma gibi görsel veri analizi problemlerinde etkili olmuşlardır. Ancak, bu algoritmanın kullanımıyla ilgili bazı sınırlamalar şunlardır:

- **Veri Kalitesi ve Çeşitliliği:** ESA'lerin etkili şekilde çalışabilmesi için geniş, çeşitli ve yeterli kalitede eğitim verilerine ihtiyaç vardır. Ancak, İHA tespiti için kullanılacak veri setlerinin elde edilmesi zor olabilir ve veri setinin kalitesi de sonuçları etkileyebilir.
- **Veri Etiketleme Süreci:** Eğitim verilerinin etiketlenmesi süreci zaman alıcı ve maliyetli olabilir. İHA görüntülerinin doğru bir şekilde etiketlenmesi, başarılı bir ESA modelinin geliştirilmesi için önemlidir. Ancak, bu süreç

insan gücü gerektirebilir ve yanlış etiketleme veya eksik veri etiketleri gibi hatalara neden olabilir.

- Hesaplama Gücü ve Kaynak Sınırlamaları: ESA'ler, yüksek hesaplama gücü gerektirebilir ve büyük veri setleri üzerinde çalışırken yüksek miktarda bellek ve işlemci kaynağı kullanabilir. Bu nedenle, donanım sınırlamaları, algoritmanın performansını etkileyebilir ve büyük ölçekli İHA tespiti uygulamalarında pratik bir zorluk oluşturabilir.
- İkinci olarak, daha hızlı İHA tespiti için yapılan çalışmaların da bazı sınırlamaları vardır. Daha hızlı ESA tabanlı İHA tespiti üzerine yapılan araştırmaların sınırlamaları şunlar olabilir:
- Hız ve Gerçek Zamanlı İşleme: İHA tespiti için kullanılan algoritmaların gerçek zamanlı olarak çalışabilmesi önemlidir, özellikle hızlı hareket eden İHA'ları tespit etmek için. Ancak, daha hızlı işleme gereksinimi, donanım ve algoritma optimizasyonu gibi faktörleri içerir ve bu da sınırlamalar yaratabilir.
- Düşük Kaliteli Görüntüler: İHA'ların algılama sistemlerinin sınırlamaları nedeniyle, bazı durumlarda düşük kaliteli görüntülerle çalışmak zorunda kalınabilir. Bu, İHA tespiti algoritmasının doğruluğunu etkileyebilir ve yanlış pozitif veya yanlış negatif sonuçlara yol açabilir. Bu sınırlamalar göz önünde bulundurularak yapılan araştırmalar, daha hızlı ve etkili İHA tespiti yöntemleri üzerinde ilerleme sağlayabilir. Araştırmacılar, veri kalitesi, hesaplama gücü, gerçek zamanlı işleme ve diğer faktörleri dikkate alarak bu sınırlamaları aşma yollarını araştırabilirler.

1.5. Tezin Yapısı

Bu tez, İnsansız Hava Araçları (İHA) tespiti alanında daha hızlı bir yöntem geliştirmeyi amaçlamaktadır ve şu bölümleri içermektedir: Giriş bölümünde, araştırmanın amacı ve önemi tartışılmış, yapay zeka ve makine öğrenmenin İHA'larla ilişkisi vurgulanmıştır. Ayrıca, bu tür araştırmaların veri kalitesi, etiketleme süreçleri ve hesaplama kısıtlamaları gibi sınırlamaları olduğu, bu sınırlamaların çalışmanın güvenilirliği ve geçerliliği açısından dikkate alınması gerektiği belirtilmiştir. Literatür taraması, alandaki mevcut bilgi birikimine genel bir bakış sunarak önerilen

araştırmanın temelini atmaktadır. Bu bölüm, Evrişimli Sinir Ağları'nın (ESA) temel kavramlarını ele almakta ve görüntü tanıma ve sınıflandırmada başarılarına vurgu yapmaktadır, bu başarıların İHA tespiti için neden önemli olduğunu açıklamaktadır. ESA'ler temelinde yapılan İHA tespiti yöntemlerinin incelendiği bir bölümde, mevcut yaklaşımlar gözden geçirilmekte ve potansiyel sınırlamalara odaklanılmaktadır. Bu noktada, veri kalitesi ve çeşitliliği, veri etiketleme süreçleri ve hesaplama kaynakları gibi konuların etkisi üzerinde durulmakta ve ESA tabanlı İHA tespiti yöntemlerinin etkililiğini nasıl etkilediği açıklanmaktadır. Tez, bulguların değerlendirilmesi, önerilen iyileştirmeler ve gelecekteki araştırmalar için önerilerle sonuçlanmaktadır. Ayrıca, bu çalışma, YOLOv5 tabanlı bir hızlı ESA yaklaşımının kullanıldığı ve Roboflow ile özelleştirilen bir veri kümesi üzerinde çalışıldığını da içermektedir. Bu veri kümesi, sentetik verileri de içermektedir. Bu detaylar, çalışmanızın yöntem ve sonuçları hakkında daha fazla içerik sağlamaktadır.

2. ARKAPLAN VE LİTERATÜR TARAMASI

Bu bölümde, tartışılan yöntemleri anlamak için gereken teorik arka plan sunulmaktadır. İlk olarak, makine öğrenimi, sinir ağları ve bilgisayar görüşü ile ilgili ilgili ayrıntılar incelenmektedir. Son olarak, bu disiplinlerin evrışimli sinir ağlarında nasıl birleştirildiği ve kullanıldığı açıklanmaktadır. evrışimsel sinir ağları (Convolutional Neural Networks - CNN) kullanarak dron tespitiyle ilgili mevcut bilgileri ve araştırmaları ayrıntılı bir şekilde incelemektedir. Drone tespit sistemlerine olan ihtiyacı ve bu sistemlerle ilişkili zorlukları açıklamaktadır. ESA tabanlı teknikler kullanarak drone tespiti için doğru ve etkili bir sistem geliştirmeyi amaçlayan bu tez çalışmasının temel amacı net bir şekilde belirtilmektedir. Derin öğrenme ve ESA algoritmalarının gücünden yararlanarak, geleneksel drone tespit yöntemlerinin sınırlamalarını aşmayı ve drone tespiti alanında doğruluk, hız ve güvenilirlik açısından ilerleme sağlamayı hedeflemektedir. Bu tezin temel araştırma sorusu şu şekildedir: ESA modelleri, ESA mimarilerinin drone tespiti alanındaki potansiyelini araştırmak ve mevcut drone tespit teknolojilerinin en son gelişmelerini incelemek istiyoruz. Uygun veri setleri üzerinde ESA modellerini eğiterek ve optimize ederek, drone tespiti konusunda yüksek hassasiyet ve güvenilirlik düzeylerine ulaşmayı hedeflemektedir. Literatür taraması bölümü, araştırmamızı bağlamına oturtmak ve önemini belirlemek açısından kritik bir rol oynamaktadır. Mevcut literatürü ayrıntılı bir şekilde inceleyerek, ESA kullanarak drone tespitiyle ilgili önceki çalışmaları, metodolojileri ve bulguları değerlendireceğiz. Alanındaki mevcut durumu gözden geçirerek, mevcut yaklaşımların güçlü ve zayıf yönlerini belirleyebilir, araştırma boşluklarını tanımlayabilir ve önceki bilgilere dayanarak yenilikçi bir çözüm geliştirebiliriz.

2.1 Yapay Sinir Ağları Tarihiçesi

Evrışimli sinir ağları, derin sinir ağları arasında başarılı bir yöntem olarak kabul edilir (Fukushima, 1988). Fukushima, 1980'lerde Neokognitron adlı sinir ağı modelini geliştirmiştir. Bu model, biyolojiden ilham alarak translyasyon-invaryant

nesne tanıma için bir çözüm sunmuştur. LeCun ve diğerleri, bu yöntemi geri yayılım adı verilen bir öğrenme algoritmasıyla birleştirmişlerdir (LeCun vd., 1989). Bu erken çözümler genellikle el yazısı karakter tanıma problemlerinde kullanılmıştır. Başarılı sonuçlar elde edildikten sonra, sinir ağı yöntemleri destek vektör makineleriyle yer değiştirmiş ve önemini yitirmiştir (Girshick vd., 2014). Ancak, Krizhevsky ve diğerleri, 2012 yılında ImageNet Büyük Ölçekli Görsel Tanıma Yarışması'nda (ILSVRC) LeCun'un yöntemini derin öğrenme için geliştirilmiş ince ayarlama yöntemleriyle birleştirerek mükemmel sonuçlar elde etmişlerdir (Krizhevsky vd., 2012). Simonyan ve Zisserman, 2014 ImageNet yarışması için evrişimli ağların derinliklerinin yerelleştirme ve sınıflandırma doğruluğu üzerindeki etkisini araştırmışlardır (Simonyan ve Zisserman, 2014). Çalışmalarında, 16 ve 19 katman derinliğindeki evrişimli ağlar kullanılarak en iyi sonuçları elde etmişlerdir. Bu mimaride, 13 evrişimli katman, 5 havuzlama katmanı ve 3 tam bağlantılı katman bulunmaktadır. Tüm gizli katmanlar doğrusal olmayan ReLu aktivasyon fonksiyonunu kullanırken, tam bağlantılı katmanlar dropout yöntemiyle düzenlenmiştir. Bu ağ yapısına VGG-16 adı verilmiştir. ImageNet yarışmasının 2016 nesne tespiti kategorisindeki kazanan yöntem de bir ESA tabanlı yöntemdir. Bu yöntem, CRAFT bölge önerisi üretimi, girişli çift yönlü ESA, kümeleme, landmark üretimi ve birleştirme gibi çeşitli teknikleri bir araya getirmektedir (Yang vd., 2016; Zeng vd., 2017).

2.2 Makine Öğrenme

Bilgisayar görüşü uygulamalarında öğrenme algoritmaları yaygın olarak kullanılmaktadır. Görüntü ile ilgili görevleri ele almadan önce, makine öğrenimin temellerine kısaca göz atacağız. Makine öğrenimi, tam olarak formüle etmenin zor olduğu problemleri modellemek için kullanışlı bir araç olarak ortaya çıkmıştır. Klasik bilgisayar programları, bir görevi yerine getirmek için el ile açıkça programlanır. Makine öğrenimi ile insan katkısının bir kısmı öğrenme algoritması tarafından yerine getirilir (Goodfellow, 2016).

Hesaplama kapasitesinin ve verilerin kullanılabilirliğinin artmasıyla, makine öğrenimi yıllar geçtikçe giderek daha pratik hale gelmiş ve neredeyse evrensel hale gelmiştir.

2.2.1 Makine öğrenme tipleri

Makine öğreniminin tipik bir kullanım şekli denetimli öğrenmedir (Bishop, 2006). Bir öğrenme algoritması, insanlar tarafından etiketlenmiş veya işaretlenmiş birden çok örnek gösterilir. Örneğin, nesne tespiti problemi için, ilgili nesnelerin konumlarını ve sınıflarını insanlar tarafından belirlenen eğitim görüntüleri kullanırız. Örneklerden öğrendikten sonra, algoritma daha önce görülmemiş verilerin etiketlerini veya işaretlemelerini tahmin edebilir. Sınıflandırma ve regresyon en önemli görev türleridir (Bishop, 2006). Sınıflandırmada, algoritma eğitim verilerine dayanarak yeni bir verinin doğru sınıfını tahmin etmeye çalışır. Regresyonda ise, ayrık sınıflar yerine sürekli bir çıktıyı tahmin etmeye çalışır. Denetimsiz öğrenmede, algoritma doğru çıktının ne olması gerektiğini belirten bir öğretmen olmadan verinin faydalı özelliklerini öğrenmeye çalışır. Kümelenme, klasik bir denetimsiz öğrenme örneğidir (Bishop, 2006). Son zamanlarda, özellikle derin öğrenme teknolojilerinin ortaya çıkmasıyla, denetimli öğrenme görevlerinde verinin faydalı temsillerini keşfetmek için denetimsiz ön işleme popüler bir araç haline gelmiştir (Bengio, 2012).

2.2.2 Makine öğrenme özellikleri

Bazı ön işleme yöntemleri neredeyse her zaman gereklidir. Verileri yeni ve daha basit bir değişken uzayına dönüştürmek için yapılan işleme özellik çıkarımı olarak adlandırılır. Sıklıkla, tam boyutlu eğitim verilerini doğrudan kullanmak pratik olmayabilir veya imkansız olabilir. Bunun yerine, detektörler verilerden ilginç özellikler çıkarmak için programlanır ve bu özellikler makine öğrenme algoritmasına girdi olarak kullanılır. Geçmişte, özellik detektörleri genellikle el ile tasarlanmıştır. Bu yaklaşımın sorunu, hangi özelliklerin ilginç olduğunu önceden bilemememizdir. Makine öğrenimindeki eğilim, özellik detektörlerini de öğrenmeye yöneliktir, bu da tam veriyi kullanmayı mümkün kılar (Goodfellow, Bengio, Courville 2016).

2.2.3 Makine öğrenme genelleme

Eğitim verileri her olası giriş örneğini içermeyeceği için, öğrenme algoritması görmediği veri noktalarını ele alabilmek için genelleme yapabilme yeteneğine sahip olmalıdır (Bishop ve Nasrabadi, 2006). Çok basit bir model tahmini, gerçek modelin önemli yönlerini yakalayamayabilir. Diğer yandan, çok karmaşık yöntemler önemsiz ayrıntıları ve gürültüyü modelleyerek aşırı uyum sağlayabilir, bu da kötü genellemeyle sonuçlanır (Bishop ve Nasrabadi, 2006).

Genellikle aşırı uyum, yetersiz eğitim verisiyle birlikte karmaşık bir yöntem kullanıldığında meydana gelir. Aşırı uyanmış bir model, bilinen örnekleri modellemeyi öğrenir, ancak bunları bir araya getiren bağlantıyı anlamaz.


Algoritmanın performansı, hataların niteliği ve niceliği temelinde değerlendirilebilir. Ortalama karesel hata gibi bir kayıp fonksiyonu, hatalara bir maliyet atamak için kullanılır (Bishop ve Nasrabadi, 2006). Eğitim aşamasındaki amaç, bu kaybı minimize etmektir.

2.3 Sinir Ağları

Sinir ağları, makine öğrenimi modellerinin popüler bir türüdür. Bu tezde, özellikle Evrişimli Sinir Ağı (Convolutional Neural Network - CNN) adı verilen bir sinir ağı türüne odaklanılmaktadır. Normal sinir ağlarının nasıl çalıştığını açıklayacağız.

2.3.1 Kökenler (hücreler) (neuron)

Yapay sinir ağları başlangıçta insan beyninin sinir işlevlerini taklit etmek amacıyla geliştirildiği için başlangıçta "yapay sinir ağları" olarak adlandırılmıştır. Warren McCulloch ve Walter Pitts'ın 1943 yılında geliştirdiği eşik mantık birimi ve Frank Rosenblatt'ın 1957 yılında geliştirdiği perceptron gibi öncü araştırmalar bu alanda yapılmıştır (Rojas, 1996). Biyolojiden ilham alınmasına rağmen, yapay sinir hücreleri ile biyolojik sinir hücreleri veya nörobilim arasındaki bağlantıyı abartmak yanıltıcı olur. İnsan beyni yaklaşık olarak 100 milyar sinir hücresi içerir ve paralel olarak çalışır (Long ve Gupta, 2008). Yapay sinir hücreleri ise daha çok seri olarak çalışan bilgisayarlarda uygulanan matematiksel fonksiyonlardır. Yapay sinir ağı araştırmaları genellikle biyolojiden ziyade mühendislik ve matematik alanındaki gelişmelerden etkilenmektedir (Goodfellow vd., 2016).



Şekil 2.1: Yapay Sinir Hücre

Kaynak: (Aydin ve Singha, 2023)

McCulloch-Pitts modeline dayalı bir yapay sinir Şekil 2.1'de gösterilmiştir (Bishop ve Nasrabadi, 2006). Sinir k , m adet girdi parametresi x_j alır. Sinir aynı zamanda m adet ağırlık parametresi w_{kj} içerir. Ağırlık parametreleri genellikle sabit bir değere sahip eşleşen bir sahte giriş olan bir sapma terimini de içerir. Girdiler ve ağırlıklar lineer olarak birleştirilir ve toplanır. Toplam daha sonra bir aktivasyon fonksiyonu ϕ 'ye verilir ve sinirin çıkışı y_k üretilir.


Yapay sinir hücrenin denklemi:

$$y_k = \phi(s_k) = \phi\left(\sum_{j=1}^m w_{kj}x_j\right) \quad (2.1)$$

Neuron eğitilirken, her bir girdi için istenen çıktıyı elde etmek için ağırlıklar dikkatlice seçilir.

2.3.2 Çok katmanlı ağlar

Bir sinir ağı, yapay sinir hücrelerinin birleşimidir. Sinir hücreleri genellikle katmanlara gruplanır. Şekil 2.2'de gösterilen tam bağlantılı bir beslemeli ileri çok katmanlı ağda, bir sinir katmanının her bir çıktısı bir sonraki katmandaki her bir sinire girdi olarak iletilir. Bu şekilde, bazı katmanlar orijinal girdi verilerini işlerken, bazıları diğer sinirlerden gelen verileri işler. Her bir sinir, önceki katmandaki sinirlerin sayısına eşit sayıda ağırlığa sahiptir. (Bishop ve Nasrabadi, 2006). Çok katmanlı bir ağ genellikle üç tür katman içerir: bir giriş katmanı, bir veya daha fazla gizli katman ve bir çıkış katmanı (Bishop ve Nasrabadi, 2006). Giriş katmanı genellikle veriyi değiştirmeden sadece iletişim sağlar. Hesaplamanın çoğu gizli katmanlarda gerçekleşir. Çıkış katmanı, gizli katman aktivasyonlarını sınıflandırma gibi bir çıktıya dönüştürür. En az bir gizli katmana sahip çok katmanlı bir beslemeli ağ, evrensel bir yaklaşımçı olarak işlev görebilir, yani neredeyse herhangi bir işlevi hesaplamak için oluşturulabilir (Hornik, 1991). Bu tezde, genellikle tam bağlantılı ağlar ve konvolüsyonel ağlar üzerinde konuşacağız. Konvolüsyonel ağlar parametre paylaşımını kullanır ve tam bağlantılı ağlara kıyasla sınırlı bağlantılara sahiptir (Goodfellow vd., 2016).



Şekil 2.2: Tam Bağlantılı Çok Katmanlı Yapay Sinir Ağı

Kaynak: (Amini, 2022)

2.3.3 Geri -yayılım

Bir sinir ağı, bilinen girişlerden hedef çıktıları yaklaşık olarak öğrenmek için tüm sinir hücrelerinin ağırlıklarının seçilmesiyle eğitilir (Bishop, 2006). Çok katmanlı bir ağı sinir ağırlıklarının analitik olarak çözmek zordur. Geri yayılım algoritması, ağırlıkları iteratif olarak çözmek için basit ve etkili bir çözüm sunar (Goodfellow vd., 2016). Klasik versiyonda optimizasyon yöntemi olarak gradyan inişi kullanılır. Gradyan inişi oldukça zaman alıcı olabilir ve hatanın global minimumunu garanti etmez, ancak uygun yapılandırma ile (makine öğreniminde hiperparametreler olarak bilinir) pratikte yeterince iyi çalışır. Algoritmanın ilk aşamasında, bir giriş vektörü sinir ağı üzerinden ileriye doğru iletilir. Bunun öncesinde, sinir ağı hücrelerinin ağırlıkları, örneğin küçük rastgele değerler gibi bazı değerlerle başlatılmış olmalıdır. Ağı alınan çıktısı, eğitim örnekleri için bilinen hedef çıktıyla bir kayıp fonksiyonu kullanılarak karşılaştırılır. Kayıp fonksiyonunun gradyanı hesaplanır. Bu gradyan aynı zamanda hata değeri olarak da adlandırılır. Ortalama karesel hata kaybı fonksiyonunu kullanıyorsak, çıktı katmanı hata değeri basitçe mevcut ve hedef çıktı arasındaki farktır.

Hata değerleri daha sonra ağ üzerinde geriye doğru iletilerek gizli katman sinirlerinin hata değerleri hesaplanır. Gizli katman sinir hücrelerinin hata fonksiyonu gradyanları, türev zinciri kullanılarak çözülebilir. Son olarak, sinir hücrelerinin ağırlıkları, ağırlıkların gradyanının hesaplanması ve gradyanın bir kısmının ağırlıklardan çıkarılmasıyla güncellenir. Bu orana öğrenme oranı denir (Bishop,

2006). Öğrenme oranı sabit veya dinamik olabilir. Ağırlıklar güncellendikten sonra, algoritma farklı girişlerle tekrar aşamaları gerçekleştirerek ağırlıkların yakınsamasını sağlar. Yukarıdaki açıklamada, her yeni girişten sonra ağırlık güncellemelerini hesaplayan çevrimiçi öğrenme yönteminden bahsetmişizdir (Goodfellow vd., 2016). Çevrimiçi öğrenme, tek veri noktasının gradyan tahmininin sürekli olarak yön değiştirdiği ve minimuma doğrudan yaklaşmadığı "zigzag" davranışına yol açabilir.

Algoritmanın matematiksel açıklamaları diğer çalışmalarda mevcuttur (Rumelhart vd., 1988; Goodfellow vd., 2016).

2.3.4 Aktivasyon fonksiyonu tipleri

Aktivasyon fonksiyonu ϕ , her bir nöronun son çıktısını belirler. Etkili bir ağ oluşturmak için fonksiyonun doğru bir şekilde seçilmesi önemlidir.

Erken araştırmacılar, perceptronlar ve diğer lineer sistemlerin, XOR-problemi gibi lineer olarak ayrıştırılamayan problemleri çözme konusunda ciddi sınırlamalarının olduğunu keşfettiler. Bazı durumlarda, el yapımı özellik algılayıcıları kullanarak lineer sistemler bu tür problemleri çözebilir, ancak bu, makine öğreniminin en avantajlı kullanımı değildir. Sadece katman eklemek de yardımcı olmaz, çünkü lineer nöronlardan oluşan bir ağ, ne kadar katman eklenirse eklenilsin hala lineer bir yapıya sahiptir (Goodfellow vd., 2016).

Doğrusal olmayan bir ağ oluşturmanın hafif ve etkili bir yolu, düzgünleştirilmiş doğrusal birimler (ReLU) kullanmaktır (Goodfellow vd., 2016).

Düzgünleştirilmiş doğrusal birim fonksiyonu, çıktıyı aşağıdaki gibi bir rampa fonksiyonu kullanarak üretir.

Rampa fonksiyonu denklemi:

$$\phi(s) = \max(0, s). \quad (2.2)$$

Bu tür bir fonksiyonun hesaplanması ve türetilmesi (geri yayılım için) kolaydır. Fonksiyon sıfır noktasında türevlenebilir değildir, ancak bu, pratikte kullanımını engellememiştir. ReLU fonksiyonları son zamanlarda oldukça popüler hale gelmiştir ve genellikle gradyan doygunluk problemleri ve daha yavaş hesaplama sorunları olan sigmoid aktivasyon fonksiyonlarının yerini almaktadır. Çok sınıflı sınıflandırma problemleri için ağıın çıkış katmanında softmax aktivasyon fonksiyonu kullanılır (Goodfellow vd., 2016).

Softmax aktivasyon fonksiyonu denklemi:

$$\phi(s) = \frac{\exp(s_k)}{\sum_{k=1}^K \exp(s_k)} \quad (2.3)$$

Softmax fonksiyonu, K adet keyfi büyük değeri olan bir vektör alır ve 0...1 aralığında değerlere sahip ve toplamı 1'e eşit olan bir vektör çıktısı üretir. Softmax birimi tarafından üretilen değerler, sınıf olasılıkları olarak kullanılabilir.

2.3.5 Derin öğrenme

Modern sinir ağları genellikle derin sinir ağları olarak adlandırılır. 1980'lerden beri çok katmanlı sinir ağları mevcut olmasına rağmen, birden fazla gizli katmana sahip ağların etkili bir şekilde eğitimini engelleyen birkaç neden vardı (Goodfellow vd., 2016).

Birinci sorunlardan biri boyutlanma sorunudur (Goodfellow vd., 2016). Değişken sayısı arttıkça, değişkenlerin farklı yapılandırmalarının sayısı üstel bir şekilde artar. Yapılandırmaların sayısı arttıkça, eşit oranda eğitim örneklerinin sayısı da artmalıdır. Yeterli büyüklükte bir eğitim veri seti toplamak zaman alıcı, maliyetli veya imkansız olabilir. Neyse ki, gerçek dünya verileri eşit dağılmaz ve genellikle düşük boyutlu bir manifold üzerinde ilginç bilgiler bulunur. Manifold hipotezi, çoğu veri yapılandırmasının geçersiz veya nadir olduğunu varsayar (Goodfellow vd., 2016). Boyut indirgeme yaparak veriyi manifold'un koordinatları kullanarak temsil etmeyi öğrenerek boyut azaltabiliriz. Genelleştirmeyi geliştirmenin başka bir yolu da yerel sabitliği varsaymaktır (Goodfellow vd., 2016). Bu, sinir ağının öğrenmeyi amaçladığı işlevin küçük bir bölgede çok fazla değişmemesi gerektiği anlamına gelir.

Son on yılda, daha güçlü bilgisayarların ve daha büyük veri setlerinin mevcut olması nedeniyle sinir ağları bir yeniden doğuş yaşadı. 2000'lerin başlarında, sinir ağlarının grafik işlem birimleri (GPU'lar) kullanılarak verimli bir şekilde eğitilebileceği keşfedildi. GPU'lar, geleneksel işlemcilerden daha verimli ve özel donanıma göre görece olarak ucuz bir alternatif sunar (Steinkraus vd., 2005). Bugün, araştırmacılar genellikle NVIDIA Tesla K40 gibi yüksek kaliteli tüketici grafik kartları kullanmaktadır (Girshick, 2015). Daha fazla teorik ilerleme, ortalama karesel hata fonksiyonlarının çapraz entropi tabanlı fonksiyonlarla ve sigmoid aktivasyon fonksiyonlarının doğrusal doğrultulu birimlerle değiştirilmesini içerir (Goodfellow vd., 2016). Derin öğrenme ile, önceden kullanılan el ayarlı makine öğrenme

çözümlerine daha az ihtiyaç vardır (Goodfellow vd., 2016). Örneğin, klasik bir desen algılama sistemi, makine öğrenme aşamasından önce el ayarlı bir özellik tespit aşamasını içerir. Derin öğrenmenin eşdeğeri ise tek bir sinir ağından oluşur. Sinir ağının alt katmanları temel özellikleri tanımak için öğrenir ve daha sonra ağın üst katmanlarına ilerletilir.

2.4. Bilgisayar Görüşü

Bilgisayar görüşü, dijital görüntülerin veya videoların içeriğinden anlamlı bilgi çıkarma sürecini kapsar. Bu, yalnızca piksel düzeyinde görsel bilgiyi işlemeden farklı bir yaklaşımdır. Bilgisayar görüşünün uygulama alanları arasında görüntü sınıflandırma, görsel tespit, 2B görüntülerden 3B sahne rekonstrüksiyonu, görüntü geri çağırma, artırılmış gerçeklik, makine görü ve trafik otomasyonu bulunmaktadır (Szeliski, 2022).

Bugün, birçok bilgisayar görüşü algoritması için makine öğrenimi kaçınılmaz bir bileşendir (Sebe, 2005). Bu tür algoritmalar, görüntü işleme ve makine öğreniminin bir kombinasyonu olarak tanımlanabilir. Etkili çözümler, görsel görüntülerdeki büyük miktardaki bilgi ile başa çıkabilen ve birçok uygulama için hesaplamaları gerçek zamanlı olarak yapabilen algoritmalar gerektirir (Szeliski, 2022).

Nesne tespiti, bilgisayar görüşünün klasik problemlerinden biridir ve genellikle zorlu bir görev olarak nitelendirilir. Birçok yönden diğer bilgisayar görüşü görevlerine benzer çünkü deformasyonlara, aydınlatma ve bakış açısı değişikliklerine dayanıklı bir çözüm oluşturmayı gerektirir. Nesne tespitini farklı kılan şey, bir görüntünün bölgelerini hem yerini belirlemek hem de sınıflandırmakla ilgilenmesidir (Girshick, 2015).

Yer tespiti, örneğin tüm görüntü sınıflandırmasında gerekli değildir. Bir nesneyi tespit etmek için nesnenin nerede olabileceği ve görüntünün nasıl segmente edildiği hakkında bir fikre sahip olmamız gerekmektedir. Bu, bir tavuk-yumurta sorunu türü yaratır, çünkü bir nesnenin şeklini (ve sınıfını) tanımak için yerini bilmemiz gerekmekte ve bir nesnenin yerini tanımak için şeklini bilmemiz gerekmektedir. (Walther vd., 2002)

İnsan kıyafetleri ve yüzü gibi bazı görsel olarak farklı özellikler aynı nesnenin parçaları olabilir, ancak bunu nesneyi önce tanımaksızın bilmek zordur. Öte yandan, bazı nesneler arka plandan hafifçe ayrılır ve tanınmadan önce ayrıştırma gerektirir. (Uijlings vd., 2013).

Görüntünün düşük seviye görsel özellikleri, örneğin göz alıcılık haritası, aday nesneleri bulmak için bir rehber olarak kullanılabilir (Walther vd., 2002).

Yer ve boyut genellikle köşe koordinatları şeklinde bir sınırlayıcı kutu olarak tanımlanır. Dikdörtgen kullanmak, keyfi şekilli bir çokgen kullanmaktan daha basittir ve birçok işlem, örneğin konvolüsyon, zaten dikdörtgenler üzerinde gerçekleştirilir. Sınırlayıcı kutu içindeki alt-görüntü, makine öğrenimi kullanılarak eğitilmiş bir algoritma tarafından sınıflandırılır (Girshick vd., 2014). Nesnenin sınırları, ilk bir tahmin yapıldıktan sonra iteratif olarak daha da iyileştirilebilir (Szeliski, 2022). 2000'ler boyunca, nesne tespiti için popüler çözümler özellik tanımlayıcıları, örneğin David Lowe tarafından 1999'da geliştirilen ölçek invariant özellik dönüşümü (SIFT)(Lowe, 1999) ve 2005'te popülerleşen yönlendirilmiş gradyanların histogramı (HOG) (Dalal, Triggs, 2005) tarafından kullanılmıştır. 2010'ların başından itibaren, Evrişimli sinir ağlarının (ESA) kullanımına bir geçiş yaşanmıştır (Girshick vd., 2014; Girshick, 2015; Ren vd., 2015). ESA'lerin yaygın olarak kullanılmasından önce, sınırlayıcı kutular oluşturmak için iki rekabet eden çözüm bulunmaktaydı. İlk çözümde, yoğun bir bölge önerisi kümesi oluşturulur ve çoğu reddedilir (Liu vd., 2016). Bu genellikle bir kayan pencere dedektörü içerir. İkinci çözümde ise seçici arama gibi bir bölge önerisi yöntemi kullanılarak seyrek bir sınırlayıcı kutu kümesi oluşturulur (Uijlings vd., 2013). Seyrek bölge önerilerini konvolüsyonel sinir ağlarıyla birleştirmek iyi sonuçlar vermiştir ve şu anda popülerdir (Girshick, 2015).

2.5. Evrişimli Sinir Ağları ve Derin Öğrenme

Büyük miktardaki verilerle başa çıkabilme yeteneği sayesinde, derin öğrenme son on yıllarda hayati bir araç olarak ortaya çıkmıştır. Geleneksel yöntemleri geride bırakarak, desen tanıma alanında gizli katmanların kullanımı ön plana çıkmıştır. Evrişimli sinir ağları, yaygın olarak kullanılan derin sinir ağlarından (Krizhevsky, 2012). Araştırmacılar, yapay zeka henüz ilk adımlarını atarken olan 1950'lerden bu yana görsel girişleri anlayabilecek bir AI sistemi yaratmak için mücadele etmişlerdir. Sonunda, bilgisayar görüşü, endüstrideki giderek artan önemini yansıtmak için ismi

değiştirilmiştir. AlexNet AI (kurucusu Alex Krizhevsky'nin adından esinlenerek adlandırılmıştır) 2012 ImageNet bilgisayarlı görme yarışmasında birinci olmuştur ve şaşırtıcı bir %85 doğruluk oranına ulaşmıştır (Krizhevsky, 2012). İkinci sıradaki katılımcı ise sınavda etkileyici bir %74 başarı elde etmiştir. Bu başarılı sonuçlara ulaşmak için AlexNet, insan görüşünü taklit eden Evrişimli Sinir Ağları (ESA'lar) kullanılarak oluşturulmuştur.


Son yıllarda ESA'lar, birçok bilgisayarlı görme uygulamasında büyük ölçüde gelişmiştir (Du vd., 2016).

Geleneksel sinir ağları kullanarak bilgisayar görüşü problemlerini çözmenin sorunu, mütevazı boyutlu bir resmin bile büyük miktarda bilgi içermesidir. 620x480 monokrom bir görüntü 297,600 piksel içerir. Eğer bu görüntünün her bir piksel yoğunluğu ayrı ayrı bir tam bağlantılı ağı giriş olarak verilirse, her bir nöron 297,600 ağırlık gerektirir. 1920x1080 full HD bir görüntü ise 2,073,600 ağırlık gerektirir. Eğer görüntüler çok renkli ise, ağırlıkların miktarı renk kanallarının miktarıyla (genellikle üç) çarpılır. Böylece, görüntü boyutu arttıkça ağıdaki toplam serbest parametre sayısı hızla çok büyük hale gelir. Çok büyük modeller aşırı uyumlanmaya ve yavaş performansa neden olur (Bishop ve Nasrabadi, 2006).

Ayrıca, birçok desen tespit görevi, çözümün çevirime karşı invariant olmasını gerektirir. Bir görüntünün sol üst köşesi ile sağ alt köşesindeki aynı deseni ayrı ayrı tanımak için nöronları eğitmek verimsizdir. Tam bağlantılı bir sinir ağı, bu tür bir yapıyı dikkate almaz (LeCun vd., 1989).

2.5.1. Evrişim katmanı

ESA'nın temel fikri, biyolojide "alıcı alan" olarak adlandırılan bir kavramdan esinlenmiştir (Fukushima, 1988). Alıcı alanlar, hayvan görsel korteksinin bir özelliğidir (Hubel ve Wiesel, 1968). Belirli türde uyarıcılara, örneğin kenarlara, duyarlı olan dedektörler olarak işlev görürler. Görsel alanın farklı noktalarında bulunurlar ve birbirleriyle örtüşürler.



Şekil 2.3: Bir Görüntüden Evrişim Filtrelemesi Kullanarak Yatay Kenarları Tespit Etme

Kaynak: (Amini, 2022)

Bu biyolojik işlev, bilgisayarlarda konvolüsyon operasyonu kullanılarak yaklaşık olarak gerçekleştirilebilir (Hubel ve Wiesel, 1968; Marr ve Hildreth, 1980). Görüntü işleme alanında, görüntüler konvolüsyon kullanılarak farklı görünür etkiler elde etmek için filtrenir. Şekil 2.3, bir el ile seçilmiş konvolüsyonel filtre ile bir görüntüden yatay kenarları algılamının nasıl gerçekleştiğini benzer bir şekilde göstermektedir. Bir görüntü f ve bir filtre matrisi g arasındaki kesirli konvolüsyon işlemi aşağıdaki şekilde tanımlanır.

Konvolüsyon işlemi:

$$h[x, y] = f[x, y] * g[x, y] = \sum_n \sum_m f[n, m] g[x - n, y - m]. \quad (2.4)$$

g filtresi ve x, y koordinatlarında merkezlenmiş olan f 'nin bir alt görüntüsünün (g ile aynı boyutlarda) nokta çarpımı, h 'nin x, y koordinatlarındaki piksel değerini oluşturur (Goodfellow, Bengio ve Courville, 2016). Alıcı alanın boyutu, filtre matrisinin boyutu ile ayarlanmaktadır. Filtrenin, f 'nin her alt görüntüsüne ardışık olarak hizalanması, çıktı piksel matrisi h 'yi üretir. Sinir ağı durumunda, çıktı matrisi ayrıca özellik haritası olarak adlandırılır veya aktivasyon fonksiyonunun hesaplanmasının ardından aktivasyon haritası olarak adlandırılır. Kenarlar, özel bir durum olarak ele alınmalıdır (Goodfellow vd., 2016). Eğer f görüntüsü padlanmamışsa, her evrişimle çıktı boyutu biraz azalmaktadır.

Bir dizi evrişim filtresi, bir sinir ağının evrişim katmanını oluşturmak için birleştirilebilir (Fukushima, 1988). Filtrelerin matris değerleri, nöron parametreleri olarak ele alınır ve makine öğrenmesi kullanılarak eğitilir. Evrişim işlemi, düzenli bir sinir ağı katmanının çarpma işlemi değiştirir. Katmanın çıktısı genellikle bir hacim olarak tanımlanır. Hacmin yüksekliği ve genişliği, aktivasyon haritasının boyutlarına

bağlıdır. Hacmin derinliği, filtrelerin sayısına bağlıdır. Aynı filtreler görüntünün tüm kısımları için kullanıldığından, serbest parametrelerin sayısı, tamamen bağlı bir sinir katmanına göre büyük ölçüde azalır (LeCun vd., 1989). Evrişim katmanının nöronları çoğunlukla aynı parametreleri paylaşır ve yalnızca girişin yerel bir bölgesine bağlıdır. Evrişimden kaynaklanan parametre paylaşımı, çeviri değişmezliğini sağlar. Evrişim katmanını tanımlamanın alternatif bir yolu, ağırlıklarına sonsuz güçlü bir öncül konulan tamamen bağlı bir katmanı hayal etmektir (Goodfellow vd., 2016). Bu öncül, nöronların farklı mekansal konumlarda ağırlıkları paylaşmasını ve alıcı alanın dışında sıfır ağırlığa sahip olmasını zorlar.

Şekil 2.4: Bir Evrişimli Sinir Ağı Örneği

Ardışık evrişim katmanları (genellikle aşağıda açıklanan havuzlama gibi diğer katman türleriyle birleştirilmiş) bir evrişimli sinir ağı (ESA) oluşturur. Bir evrişim ağı örneği Şekil 2.4'te gösterilmektedir. Geri yayılım eğitim algoritması. Teoride, girişe daha yakın olan katmanlar, görüntünün kenarları ve köşeleri gibi düşük seviye özellikleri tanımaya öğrenmeli ve çıktıya daha yakın olan katmanlar, bu özellikleri daha anlamlı şekilleri tanımak için birleştirmeyi öğrenmelidir (Fukushima, 1988).

Sınıflandırma için ağı daha yönetilebilir hale getirmek, ağın derin kısmında aktivasyon haritası boyutunu azaltmak için yararlıdır. Genellikle, ağın derin katmanları, özelliklerin tam konum bilgilerinden daha az bilgi gerektirir ancak birden çok yüksek seviyeli deseni tanımak için daha fazla filtre matrisine ihtiyaç duyar (Goodfellow vd., 2016). Veri hacminin yüksekliğini ve genişliğini azaltarak, veri hacminin derinliğini artırabiliriz ve hesaplama süresini makul bir seviyede tutabiliriz.

Veri hacmi boyutunu azaltmanın iki yolu vardır. Bir yol, bir evrişimli katmandan sonra bir havuzlama katmanı eklemektir (Goodfellow vd., 2016). Bu katman etkili bir şekilde aktivasyon haritalarını alt örnekleme yapar. Havuzlama, dedektörlerin daha az hassas olmasını zorlayarak elde edilen ağı daha fazla çeviri değişmez kılar. Ancak, havuzlama, desenlerin alt parçaları arasındaki mekansal ilişkiler hakkındaki bilgileri yok edebilir. Tipik havuzlama metodu maksimum havuzlamadır. Maksimum havuzlama, basitçe aktivasyon haritasının bir dikdörtgen komşuluk içindeki maksimum değeri çıktı olarak verir (Goodfellow vd., 2016).

Veri hacmi boyutunu azaltmanın diğer bir yolu, evrişim işleminin adım parametresini ayarlamaktır. Adım parametresi, evrişim çıktısının, giriş görüntüsünün her pikseli üzerinde merkezlenmiş bir komşuluk için (adım 1) veya her nth piksel için (adım n) hesaplanıp hesaplanmayacağını kontrol eder (LeCun vd., 1989). Araştırmalar, adım değeri daha büyük olan evrişimli katmanlar kullanılarak havuzlama katmanlarının genellikle doğruluk kaybı olmadan atılabileceğini göstermiştir (Fukushima, 1988). Adım işlemi, havuzlama için sabit bir ızgara kullanmaya eşdeğerdir.

2.5.3. Ek katmanlar

Evrişimli katman genellikle bir doğrultulmuş lineer aktivasyon fonksiyonu gibi doğrusal olmayan bir aktivasyon fonksiyonunu içerir (Simonyan ve Zisserman, 2014). Aktivasyonlar bazen evrişimli katman ile pooling katmanı arasında ayrı bir katman olarak tanımlanır. Bazı sistemler, (Simonyan ve Zisserman, 2014) gibi, düzenleme tekniği olarak kullanılan yerel yanıt normalleştirme adı verilen bir katmanı da uygular. Yerel yanıt normalleştirme, uyarılmış nöronların komşu nöronların aktivitesini azalttığı biyolojik nöronların bir işlevini taklit eder. Ancak, diğer düzenleme teknikleri şu anda daha popülerdir ve bunlar bir sonraki bölümde tartışılacaktır.

Bir ESA'nın son gizli katmanları genellikle tam bağlantılı katmanlardır (Bishop, 2006; Ren vd., 2015). Tam bağlantılı bir katman, parametre paylaşımı evrişimli katmanların yakalayamayacağı bazı ilginç ilişkileri yakalayabilir. Ancak, tam bağlantılı bir katmanın pratik olabilmesi için yeterince küçük bir veri hacmine ihtiyaç vardır. Havuzlama ve adım ayarları, tam bağlantılı katmanlara ulaşan veri hacminin boyutunu azaltmak için kullanılabilir. Herhangi bir tam bağlantılı katman

içermeyen bir evrişimli ağa tamamen evrişimli ağ (FCN) denir (Ren vd., 2015). Ağ bir sınıflandırma için kullanılıyorsa, genellikle bir softmax çıktı katmanı içerir. En üst katmanların aktivasyonları da bir görüntünün özellik temsili oluşturmak için doğrudan kullanılabilir. Bu, evrişimli ağın büyük bir özellik dedektörü olarak kullanıldığı anlamına gelir (LeCun vd., 1989).

2.5.4. İyileştirme ve veri artırma

İyileştirme, makine öğrenme sistemi için ek kısıtlamalar veya bilgiler tanıtarak aşırı uydurmayı azaltmak için kullanılan yöntemleri ifade eder (Goodfellow vd., 2016; Simonyan ve Zisserman, 2014). Sinir ağlarında iyileştirmeyi kullanmanın klasik bir yolu, belirli türdeki ağırlıklara ceza veren bir terim eklemektir. Evrişimli ağların parametre paylaşma özelliği de bir başka iyileştirme örneğidir. Derin sinir ağları için özgü birkaç iyileştirme tekniği bulunmaktadır. Popüler bir teknik olan Dropout, nöronların birlikte adapte olmasını azaltmayı hedefler (Srivastava vd., 2014). Bu, eğitim sırasında rastgele nöronları atarak gerçekleştirilir, yani her eğitim örneği veya minibatch için biraz farklı bir sinir ağı kullanılır. Bu, sistemin herhangi bir tek nörona veya bağlantıya fazla bağımlı olmamasını sağlar ve etkili ancak hesaplama açısından uygun bir şekilde iyileştirmenin uygulanmasını sağlar (Goodfellow vd., 2016; Srivastava vd., 2014). Evrişimli ağlarda dropout genellikle nihai tam bağlantılı katmanlarda kullanılır (Simonyan ve Zisserman, 2014).

Aşırı uydurmayı azaltmanın bir diğer yolu ise eğitim verisinin miktarını artırmaktır. Daha fazla gerçek örnek elde etmek mümkün olmadığında, veri artırma mevcut veriden daha fazla örnek oluşturmak için kullanılır (Goodfellow vd., 2016). Evrişimli ağları kullanarak sınıflandırma yaparken, bu, algılanan nesne sınıflarını değiştirmeyen ancak sisteme ek zorluk sağlayan girdi görüntülerinin dönüşümlerinin hesaplanmasıyla gerçekleştirilebilir. Örneğin, görüntüler ters çevrilebilir, döndürülebilir veya farklı kırpma ve ölçeklerle alt örnekleme yapılabilir. Ayrıca, girdi görüntülerine gürültü eklenebilir (Goodfellow vd., 2016; Simonyan ve Zisserman, 2014).

2.6. Nesne Algılama Teknolojileri

Sanayi ve akademik alanda, drone tespiti için optik olmayan yaklaşımlar akustik (Anwar vd., 2019), radar (Mendis vd., 2016) ve radyo frekansı (Ganti ve

Kim, 2016) kullanılarak yapılmaktadır. Ayrıca, optik yaklaşımlarla da drone'ları fotoğraflardan ve videolardan çıkarılan özelliklere bağlı olarak tespit etmek mümkündür (Unlu vd., 2018; Isaac-Medina vd., 2021).

2.6.1. Optik olmayan yaklaşımlar

2.6.1.1. Akustik tespit

Dronların rotorlarındaki akustik özellikler, dronları çevrelerinden ayırt etmek için kullanılabilir (Anwar vd., 2019). Mikrofon dizileri tarafından toplanan çeşitli sesler, dronlar, uçaklar, kuşlar ve gök gürültüsü gibi, yüksek frekans özelliklerine dayalı olarak algoritmalara iletilir ve dron olup olmadığı belirlenir (Anwar vd., 2019). Ancak, bu yöntem havaalanları gibi gürültülü alanlarda uygulanması zor olabilir (Unlu vd., 2019).

2.6.1.2. Radar tespit

Radar, uçak gibi büyük hava araçlarının tespitinde yaygın olarak kullanılır. Doppler radarı, dron tespitinde rotorların ve kanat hareketlerinin frekans değişikliklerini yakalamak için değiştirilir (Mendis vd., 2016). Ancak bu tür değişiklikler, dronlar, kuşlar ve arka plan kirliliği arasındaki ayrımı zorlaştırabilecek daha fazla gürültüyü ortaya çıkarabilir (Ganti ve Kim, 2016).

2.6.1.3. Radyo frekansı tespiti

Dronlar, yerden pilota iletişim kurmak ve videoları kontrolcüye göndermek için Radyo Frekansı (RF) sinyallerini kullanır. RF sinyali, makine öğrenimi gibi yöntemlerle yakalanarak analiz edilebilir (Shoufan vd., 2018). RF sinyallerinin tespiti etkilidir ve uzak mesafelerde gerçekleştirilebilir, bu nedenle piyasada drone tespitinde yaygın bir yöntemdir (Ganti ve Kim, 2016).

2.6.2 Optik yaklaşımlar

Karşılaştırıldığında, önceden sunulan yöntemlere kıyasla, optik yaklaşımlar daha uygun, sezgisel ve ekonomik olarak kabul edilir (Anwar vd., 2019). Optik yaklaşımlar, nesne tespiti ve sınıflandırması için özelliklerin nasıl çıkarıldığına bağlı olarak iki kategoriye ayrılabilir.

2.6.2.1. El ile oluşturulan özellik çıkarımı kullanan yaklaşımlar

Nesne tespiti için geleneksel yöntemler, el ile oluşturulan özellik çıkarımı ve makine öğrenimi algoritmalarına dayanır (Wang vd., 2018). Bu yaklaşımlar, önce ilgi alanının (ROI) belirlenmesi için arka plan çıkarma gibi yöntemler kullanır (Chen vd., 2016). Bu uygulamalarda çoğu kamera, neredeyse sabit konumda hareket eder veya hiç hareket etmez ve sadece hedefler video akışlarında hareket eder (Jiang vd., 2021). Ardından, Histogram of Oriented Gradients (HOG) (Wang vd., 2018), Fourier öznitelikleri (Unlu vd., 2018) ve Speeded Up Robust Features (SURF) (Coluccia vd., 2021) gibi özellik tanımlayıcıları çıkarılır ve sınıflandırıcıya sınıflandırma ve tanıma için gönderilir. Bu yöntemler genellikle daha kısa süre alır, ancak derin öğrenme yaklaşımlarına kıyasla daha düşük bir tanıma oranına sahiptir (Girshick vd., 2014).


2.6.2.2. Derin öğrenmeyi kullanan yaklaşımlar

Nesne tespitinde derin öğrenme günümüzde yaygın olarak kullanılmaktadır. Derin öğrenme yöntemlerinin özellik çıkarımı genellikle evrimsel katmanlarla gerçekleştirilir, bu sayede ham piksellerden elde edilen özelliklerin yanı sıra görüntülerin daha yüksek seviyeli anlamsal özellikleri de çıkarılabilir (Girshick, 2015). Sonuç olarak, derin öğrenme daha iyi hiyerarşik özellikler oluşturabilir (Yolov3: An Incremental Improvement, 2018). Birçok State-of-the-Art (SOTA) model, drone tespiti görevleri için test edilmiş ve değerlendirilmiştir (Isaac-Medina vd., 2021; Liu vd., 2021). Bu tezde, drone tespiti gereksinimlerimize göre bazı yeni SOTA nesne tanıma modellerini test etmek ve karşılaştırmak hedeflenmektedir (Unlu vd., 2019). Bilgisayar görüşü araştırma alanında, temel olarak üç görev bulunmaktadır: sınıflandırma, tespit ve segmentasyon. Çalışmamızda, kareler içine alınmış bir insansız hava aracını (drone) gösteren bir sınırlayıcı kutu çizmek amacıyla, resimdeki nesnenin ne olduğu ve nerede bulunduğu hakkında bilgiye ihtiyaç duyulmaktadır, bu da tespit kategorisine girer. Nesne tespiti için derin öğrenme modelleri iki temel kategoriye ayrılır: iki aşamalı tespit yöntemleri ve tek aşamalı tespit yöntemleri.

2.6.2.2.1 İki aşamalı nesne tespiti

İki aşamalı tespit yöntemleri, iki aşamadan oluşur. İlk aşama, hedef nesneleri içerebilecek bir dizi bölgenin üretilmesi için kullanılır, ikinci aşama ise önerilen bölgeleri sınıflandırır ve sınırlayıcı kutular oluşturur. Tipik iki aşamalı en gelişmiş

(SOTA) modeller arasında Bölge Temelli Evrişimli Sinir Ağları (RCNN) (Girshick vd., 2014), Hızlı RCNN (Girshick, 2015) ve Daha Hızlı RCNN (Ren vd., 2015) bulunmaktadır. Daha Hızlı RCNN'in yapısı Şekil 2.5'te gösterilmiştir. Modelin ana omurgası bir evrişimsel sinir ağıdır, genellikle VGG-16 veya ResNet, hangi özellik haritaları üretir. Bölge Öneri Ağı, nesnelerin muhtemelen bulunabileceği konumların önerilerini üretir. RoI havuzlaması, önerileri ve ilgili özellik haritalarını alır ve sabit boyutlu özellik haritaları üretmek için en büyük havuzlamayı yapar. RoI havuzlamasından elde edilen çıktılar daha sonra sınıflandırıcıya verilir ve nesnenin sınıfını tahmin etmek ve sınırlayıcı kutu çizmek için kullanılır. İki aşamalı tespit yöntemlerinin genellikle erken bir aşamalı tespit yöntemlerine göre daha yüksek doğrulukları bulunurken, çıkarım hızları gerçek zamanlı tespit yapacak kadar yavaş olabilir.



Şekil 2.5: İki Aşamalı Nesne Tespit Yapısının Bir Örneği


Kaynak: (Redmon ve Farhadi, 2018)

2.6.2.2.2 Tek aşamalı nesne tespiti

Tek aşamalı nesne tespit yöntemleri, iki aşamalı tespit yöntemlerinin bölge öneri aşamasını atlayarak nesne sınırlayıcı kutularını ve sınıfını aynı anda tahmin eder. Bu türdeki yöntemler, nesne tespitinde önemli bir hassasiyet kaybı yaşamadan gerçek zamanlı tespit yapacak kadar hızlıdır. İki popüler tek aşamalı nesne tespit yöntemi, Feature Pyramid Networks (FPN) kullanarak çok ölçekli özellik haritalarından ve çapa kutucuklardan yararlanarak, nesnenin sınıfını ve sınırlayıcı kutularının tahminlerini aynı anda yapar. Bu yöntemler "You Only Look Once (YOLO)" ve "Single Shot Detector (SSD)" olarak adlandırılır. "YOLOv3" modeli, nesne tespiti görevlerinde en son teknoloji sonuçlarına ulaşmıştır (Redmon ve Farhadi, 2018). SSD yöntemi ise bilgisayar görüşü alanında önemli bir tek aşamalı nesne tespit yöntemidir (Liu vd., 2016). YOLOv3, YOLO'nun geliştirilmiş bir versiyonu olup, sınıflandırma ve sınırlayıcı kutu tahminlerini yapmak için

görüntüleri üç farklı ölçekte hücelere böler. Her hücre, çapa kutularını ve nesnenin sınıf olasılıklarını tahmin eder.

YOLOv3 gibi tek aşamalı bir nesne tespit yöntemi olan yapı, Şekil 2.6'da gösterilir. Bu yapıda, nesnelerin konumlarını belirlemek için nöral ağlarla öneriler oluşturmak yerine, görüntüleri üç farklı ölçekte hücelere böler ve her hücre çapa kutularını ve sınıf olasılıklarını tahmin eder. Bu yöntem, iyi performansı ve hesaplama hızı sayesinde popüler hale gelmiştir.




Şekil 2.6: Tek Aşamalı Nesne Algılama Yapısının Bir Örneği

Kaynak: (Redmon ve Farhadi, 2018)

YOLO

Son birkaç yılda, YOLO serisi algoritmalar YOLOv5'e kadar güncellendi. YOLO'nun ilk üç versiyonu aynı yazar tarafından önerildi ve YOLOv3, tespit doğruluğunda ve çıkarım hızında büyük iyileştirmelerle biliniyor (Redmon ve Farhadi, 2018). YOLOv3, omurga olarak Darknet53'ü kullandı ve boyun olarak özellik piramit ağları (FPN) kullandı. Omurga, giriş resimlerinden özellikleri çıkarmak için evrişim katmanlarını kullanırken, boyun, önceki evrişim katmanlarından gelen özellikleri up sampling kullanarak birleştiriyor (Redmon ve Farhadi, 2018). Baş kısmı da bir piramit yapısı kullanır, bu üç farklı ölçekte (82. katman, 94. katman ve 106. katman) boyundan üretilen üç özellik haritası üzerinde sınırlayıcı kutu tahminleri yapar (Redmon ve Farhadi, 2018). Üç çıktı özellik haritasının boyutları 13×13 , 26×26 ve 52×52 'dir. 13×13 katmanı büyük nesneleri tespit etmekten sorumlu iken 52×52 katmanı küçük nesneleri tespit etmekten sorumludur. Her ölçek, sınırlayıcı kutuları tahmin etmek için her hücrenin merkezinde 3 önceden tanımlanmış çapa kutusu kullanır. Ek olarak, katmanlar arasındaki rezidüalleri birleştirmek için atlamalı bağlantılar kullanılır ve bu, tespit

doğruluğunu artırır (Chen vd., 2022). Nesne sınıfı tahmini ve güven, lojistik regresyon kullanılarak tahmin edilir (Redmon ve Farhadi, 2018).



Şekil 2.7: YOLOv3 Yapı

Kaynak: (Redmon ve Farhadi, 2018)

Evrişimsel: Konvolüsyonel katman (lar)

s2: Adımı 2 olan (stride of 2) konvolüsyonel katman

Artıklı Blok: ResNet yapısına sahip tekrarlanan konvolüsyonel katmanlar

batch size: Bloğun çıkış boyutu (output size)

2020 yılında, iki farklı araştırma ekibi tarafından YOLO'nun iki yeni versiyonu, YOLOv4 ve YOLOv5, yayınlandı. Her iki model de performansta iyileşme gösterdi. YOLOv4, özellik çıkarımı için omurgayı CSPDarknet53'e çevirdi, YOLOv3'ün boyununu FPN ve Path Aggregation Network (PAN) kombinasyonu ile değiştirdi ve YOLOv3'ün birçok diğer yönünde alternatifler keşfetti, bunlar arasında aktivasyonlar, sınırlayıcı kutu kaybı, veri büyütme, düzenleme metotları vb. bulunmaktadır (Bochkovskiy vd., 2020).

YOLOv5 daha popüler hale geldi çünkü ağların temel bileşenlerini değiştirmeye çalışmanın yanı sıra, farklı boyutlarda modeller yayınladı ve modelleri C yerine Python ve Pytorch'ta uyguladı (Jocher ve diğerleri , 2021).

YOLOv5, beş farklı ölçekte modeller sunar: N, S, M, L ve X, bunlar sırasıyla minik, küçük, orta, büyük ve ekstra büyük anlamlarına gelir. Daha büyük model, daha derin ağlara ve daha geniş kanallara sahip olup, daha fazla katmana ve filtreye sahipken, bu beş modelin yapıları temelde aynıdır.

2.7. Literatür Taraması

Literatür taraması bölümü, araştırmamızı bağlamına oturtmak ve önemini belirlemek açısından kritik bir rol oynamaktadır. Mevcut literatürü ayrıntılı bir şekilde inceleyerek, ESA kullanarak drone tespitiyle ilgili önceki çalışmaları, metodolojileri ve bulguları değerlendireceğiz. Alanındaki mevcut durumu gözden geçirerek, mevcut yaklaşımların güçlü ve zayıf yönlerini belirleyebilir, araştırma boşluklarını tanımlayabilir ve önceki bilgilere dayanarak yenilikçi bir çözüm geliştirebiliriz

Bu araştırma makalesi, öncelikle nesne tespiti ve izleme gibi kritik görevler için derin öğrenmenin uygulanmasına odaklanmaktadır. Araştırma, özellikle görsel-infrared görüntüler ve video akışları içindeki gerçek zamanlı izleme ile bağlantılı zorluklara odaklanmaktadır. Araştırmanın metodolojisinin merkezinde, bu görevleri gerçekleştirmek için You Only Look Once version 3 (YOLOv3), Evrişimli Sinir Ağları'nın (ESA) bir varyantı, ve OpenCV kullanımı bulunmaktadır. Araştırma yaklaşımı iki aşamalıdır: başlangıçta, araştırmacılar nesne tespiti ve izleme için YOLOv3 ve OpenCV'yi kullanır, ardından önerilen sistem, özellikle toplanan veri kümesi ve CAMEL veri kümesi olmak üzere iki veri kümesinde önceden eğitilir. Tüm sistem Python kullanılarak geliştirilmiştir.

Araştırmacıların benimsediği metodoloji sıralı ve basittir. Öncelikle, model bir nesneyi veya kişiyi tanımlar ve onu bir dikdörtgen kutu içine kapsar. Ardından, sistem tespit edilen nesnenin veya kişinin merkezini belirler. Son adım, tespit edilen varlığın göreceli doğruluğunun hesaplanması ve bu bilginin dikdörtgen kutuya eklenmesini içerir. Bu araştırmadan elde edilen bulgular, önerilen sistemin etkinliğini vurgular. Görsel-infrared gözetim senaryoları içinde nesne tespiti, sınıflandırması ve

izlemeyi başarıyla gerçekleştirdiği görülmüştür. Doğruluk açısından, sonuçlar tatmin edici derecede yüksek bulunmuştur. Dikkat çekici bir şekilde, önerilen model, bir Grafik İşlem Birimi (GPU) üzerinde çalıştırıldığında saniyede 45 ile 155 kare arasında işlem yapabilen gerçek zamanlı nesne tespiti yeteneklerini sergilemiştir.

Nesne tespiti ve izleme alanına genel bir bakış açısından, bu araştırma öne çıkmaktadır. Diğer çalışmalar benzer görevler için ESA'leri kullanmış olsa da Single Shot MultiBox Detector (SSD), Fast R-CNN, Region-based Fully Convolutional Networks (R-FCN) gibi farklı mimarileri kullananlar dahil, bu araştırma benzersiz bir şekilde YOLOv5'ü görsel görüntülere ve video akışlarına uygular. Bu yenilik, önerilen sisteme gerçek zamanlı işleme ve yüksek doğruluk açısından belirgin bir avantaj sağlar (Al Tameemi vd., 2023).

Bu çalışmada, derin öğrenme kullanarak İnsansız Hava Araçları video görüntülerinde araç görüntüsü algılaması için bir yöntem sunmaktadır. Geleneksel makine öğrenme algoritmalarının video kalitesi ve hava koşulları gibi objektif faktörlere duyarlı olduğu ve bunun da optimal olmayan algılama sonuçlarına yol açtığı bulunmuştur. Bu çalışma, gözetleme videosunu bir dizi görüntü çerçevesi olarak ele alıp, araç algılaması için işleyen bir yaklaşım önermektedir. Başlangıç aşamasında, orijinal örneğe bir Hue-Saturation-Value (HSV) mekansal parlaklık çeviri işlemi uygulanır. Bu adım, çeşitli ışık koşullarına adaptasyonu artırır ve örnek çeşitliliğini artırır, bu yüzden hayati öneme sahiptir. Bu işlemden sonra, araç algılama temeli olarak Single Shot MultiBox Detector (SSD) model çerçevesi kullanılır. Üstün özellik çıkarma elde etmek için, odak kaybı, temel SSD'ye optimizasyon için eklenir. Eğitim tamamlandıktan sonra, ağ modeli İHA videosunu analiz etmek için kullanılır. Deneysel analiz, bu algoritmanın araç algılama oranının etkileyici bir şekilde %96,49'a ulaştığını göstermektedir. Araştırma, etkili trafik bilgisi çıkarımı için İHA video araç algılama konusundaki doğruluk ve stabilite önemini vurgulamaktadır. Araştırma ayrıca, önerilen yöntemin performansını, ön işlem görmüş bir yaklaşımla karşılaştırır ve algılama doğruluğunda yaklaşık %5'lik bir iyileşme gösterir. HSV dönüşümü sonrası verilere uygulandığında SSD modeli, sağlam veri öğrenme kabiliyeti nedeniyle algılama etkisini artırır. Hedef algılama, özellikle karmaşık senaryolarda, derin öğrenmenin potansiyelini kabul ederken, yazarlar ayrıca büyük örnek büyüklükleri ve hız gereksinimleri açısından sınırlamalarını da not eder. Dolayısıyla, gelecekteki çalışma, video hedef algılamada

küçük örnek eğitim altında derin öğrenmenin uygulanmasına ve gerçek zamanlı sorunların çözümüne odaklanacaktır (Wang, 2022).

Bamne araştırma makalesi, çeşitli günlük uygulamalarda önemli bir öneme sahip olan nesne algılama görevine odaklanmaktadır. Geleneksel olarak, bu görev için makine öğrenme teknikleri kullanılmış, öncelikle özellik setini çıkarmak için görüntü tabanlı tür sınıflandırması gerçekleştirilmiştir. Bu özellik setini belirleme görevi, nesne algılamanın gerçekleştirilmesine yardımcı olur. Nesne sınıflandırma problemine bir çözüm getirmek amacıyla, makale bir transfer öğrenmesi tabanlı derin öğrenme yöntemi önermektedir. Bu çalışmada, çeşitli evrişimli sinir ağları incelenmiş ve sonuçların iyileştirilmesi için çoğunluk oylaması şeması kullanılmıştır. Çalışma, CUB 200-2011 veri seti üzerinde gerçekleştirilmiş ve önerilen yöntemin uygulanmasıyla farklı ESA modellerine kıyasla doğrulukta belirgin bir artış gözlemlenmiştir. Önerilen çalışma, bir evrişimli sinir ağına transfer öğrenme ve çoğunluk oylaması şemasını entegre eder. Bu yaklaşım, mevcut modelleri geride bırakırken, önceki çalışmalara ince tanelilik katkıda bulunur. Bu çalışmada, CUB-200-2011 veri seti, farklı türdeki kuşları algılamak için kullanılmıştır. Beş farklı önceden eğitilmiş ESA modeli kullanılmış ve sonuçları çoğunluk oylama şeması ile birleştirilmiştir. Bu yöntem, yüksek bir doğruluk oranı olan %97,45'e ulaşmıştır (Bamne vd., 2020).

Yapılan çalışmada, değişen hava koşulları, aydınlatma şartları ve görünürlük zorluklarını göz önünde bulundurarak trafik işaretlerini gerçek zamanlı olarak tespit etme ve tanıma yaklaşımını incelemektedir. Trafik işareti tespiti problemi, çeşitli çoklu nesne tespit sistemleri (F-RCNN ve SSD gibi) ile çeşitli özellik çıkarıcıları (MobileNet v1, Inception v2 ve Tiny-YOLOv2 gibi) birleştirilerek ele alınmıştır. Özellikle, F-RCNN Inception v2 ve Tiny YOLO v2 modelleri üzerinde yoğunlaşarak, bu modellerin en iyi sonuçları elde ettiği gözlemlenmiştir. Bu modeller, Alman Trafik İşaretleri Tespit Benchmark (GTSDb) veri kümesi üzerinde ince ayarlanmış ve çeşitli platformlarda test edilmiştir; bunlar arasında bir ana bilgisayar, Raspberry Pi 3 Model B+ ve TASS PreScan simülasyonu bulunmaktadır. Tüm bu modellerin sonuçları, ayrıntılı bir şekilde sonuçlar bölümünde tartışılacaktır. Bu araştırma, trafik işaretlerini hızlı ve etkili bir şekilde tespit etme ve sınıflandırma amacı gütmektedir. Araştırmanın temel katkıları şunlardır:

1. F-RCNN Inception v2 modeli, tamamen evrimsel bir ağ ve transfer öğrenme kullanarak karmaşık gerçek dünya yol koşullarında bile %96 ortalama doğruluk seviyesine ulaşan doğru, güvenilir ve hızlı sonuçlar elde etmektedir.
2. Tiny-YOLOv2, hızlı bir model olup iyi bir doğruluk sunmaktadır, ancak daha yüksek doğruluk gerektiğinde YOLOv2 veya YOLOv3 gibi diğer modellerin kullanılması tavsiye edilmektedir.
3. Inception v2 modeli, GTSRB veri kümesi üzerinde 39,200 görüntü ve 43 sınıf ile eğitildikten sonra %99,8 doğruluk seviyesine ulaşmıştır ve bu başarı, GTSRB yarışması tarafından bir rekabet rekoru olarak kabul edilmektedir.

Sonuçlar ayrıca aynı zamanda daha fazla eğitim verisi ve uzatılmış eğitim süreleri ile doğruluk seviyelerinin iyileştirilebileceğini göstermektedir. Bu, her sınıf için ortalama 1,000 görüntü içeren en az 40,000 görüntünün eklenmesi ve yüksek kaliteli bir GPU kullanılması ile mümkün olabilir.

Genel olarak, bu araştırma trafik işareti tespiti ve sınıflandırma için etkili bir yöntem sunmaktadır. Sunulan modeller, gerçek dünya senaryolarında umut verici sonuçlar elde etmektedirler (William vd., 2019).

Ayrıca, bu araştırmanın ana sonuçlarını ve katkılarını özetleyen bir tabloyu aşağıda bulabilirsiniz:

Çizelge 2.1: Araştırma Sonuçları Tablosu

Model	Ortalama Doğruluk
F-RCNN Inception v2	%96
Tiny-YOLOv2	Düşük, Yüksek gerekebilir
Inception v2	%99.8

Kaynak: (William vd., 2019)

Yukardaki Çizelge 2.1, araştırmanın ana sonuçlarını özlü bir şekilde sunmaktadır (William vd., 2019).

Makalelerde mikroskobik videolarda çok küçük nesneleri tespit etmek, özellikle büyük ölçekli deneylerde önemli zorluklar oluşturmaktadır. Sperm gibi küçük varlıklar söz konusu olduğunda, mevcut tespit yöntemleri, nesnelerin bulanık, düzensiz ve hassas konumlandırılması nedeniyle zorluklarla karşılaşmaktadır. Bu makalede, yüksek kaliteli sperm mikroskobik videolarının sağlam bir veri seti (111

video, >278,000 etiketlenmiş nesne) ile uygulanan Küçük Nesne Tespiti için özel olarak tasarlanmış bir Evrişimli Sinir Ağı (TOD-CNN) tanıtılmaktadır. Önerilen modeli etkili bir şekilde kullanmak ve test etmek için bir Grafiksel Kullanıcı Arayüzü (GUI) geliştirilmiştir. TOD-CNN, mikroskobik videolarda gerçek zamanlı sperm tespitinde etkileyici bir %85,60 AP50 başarısı elde ederek, sperm tespit teknolojisinin sperm kalitesi analizindeki önemini vurgulamaktadır. Bu, ilgili sperm kalitesi değerlendirme ölçütlerinin, tıp profesyonellerinin teşhis sonuçlarıyla karşılaştırılmasıyla daha da doğrulanmaktadır. Bu çalışmada, sperm tespiti, izlemesi ve sınıflandırması için geniş ve yüksek kaliteli bir veri setini geliştirdik ve halka açık hale getirdik. Tek aşamalı CNN modelimiz (TOD-CNN), gerçek zamanlı olarak videolarda ve resimlerde spermleri doğru bir şekilde tespit edebilmektedir. Ancak, TOD-CNN her senaryoda doğru performans göstermemekte ve bazı durumlarda spermleri tamamen veya doğru bir şekilde tespit edememektedir. İlerleyen çalışmalarımızda, TOD-CNN'nin performansını artırmak için ilgili optimizasyon algoritmalarını entegre etmeyi planlıyoruz, örneğin monarş kelebek optimizasyonu, solucan optimizasyon algoritması, fil sürüsü optimizasyonu, güve arama algoritması, slime mould algoritması, açlık oyunları araması, Runge Kutta optimizatörü, koloni avı algoritması ve Harris şahinler optimizasyonu(Liv d., 2022).

Ajakwe ve diğerleri tarafından yazılan makalede, askeri taktik operasyonlarda yasadışı dronların gerçek zamanlı tespiti ve etkisiz hale getirilmesi için uyarlanabilir senaryo tabanlı bir yaklaşım önerilmektedir. Önerilen yaklaşım, farklı türlerdeki dronları tanımlamak ve farklı ortamlarda, boyutlarda, hızlarda ve şekillerde çalışan eklenmiş nesneleri belirlemek için tasarlanmış bir YOLOv5 derin öğrenme modelini kullanmaktadır. Bu çalışma için kullanılan veri seti manuel olarak oluşturulmuş olup, 6 farklı dron modeli ve 8 eklenmiş silah örneği içermektedir. Sonuçlara göre, model silah tespiti için %100 tespit hassasiyeti, %99,9 duyarlılık ve %87,2 F1 puanı gibi dikkat çekici bir performans elde etmiştir. Ayrıca, hesaplama süresi yalnızca 0,021 saniyede sonuçlar üretecek kadar hızlıdır. Yüksek tespit hassasiyeti ve minimum kaynak kullanımı, modeli gerçek zamanlı dron izleme ve askeri operasyonlarda yasadışı dronların etkisiz hale getirilmesi için uygun hale getirmektedir.

Makale, hassas bölgelerin ve sınır bölgelerinin gerçek zamanlı izlenmesinin yanı sıra, kentsel bölgelerde taktik askeri operasyonlarda yeni yaklaşımlar ve tekniklere ihtiyaç duyulduğunu vurgulamaktadır. Genel olarak, önerilen yaklaşım,

ulusal güvenliğe yönelik yasadışı dron tehdidinin üstesinden gelmek için etkili ve verimli bir çözüm sunmaktadır.

Sonuçlar aşağıdaki Çizelge 2.2’de özetlenmiştir:

Çizelge 2.2: Sonuçlar Tablosu

Metrik	Sonuç
Tespiti Hassasiyeti	100%
Tespiti Duyarlılığı	99.9%
Tespiti F1 Puanı	87.2%
Hesaplama Süresi	0.021 saniye

Kaynak: (Ajakwe vd., 2022)

Araştırma makalelerinin incelenmesiyle, nesne tespiti alanındaki ortak temalar, yaklaşımlar, metodolojiler ve bulgular açıkça ortaya konulabilir. Temel araştırma alanı nesne tespiti olup, bu, hareketsiz görüntüler ve videolardaki semantik nesnelerin tanınmasını içermektedir. Nesne tespiti algoritmaları genellikle iki ana kategoriye ayrılır: geleneksel yöntemler ve derin öğrenme yöntemleri. Geleneksel yöntemler sıklıkla kayan pencere metodolojisini benimserken, derin öğrenme yöntemleri, YOLO algoritması gibi yaklaşımları kullanır. Çeşitli makaleler, nesne tespiti ağlarının özel bileşenlerini geliştirmeye yönelik çalışmalara odaklanmıştır. Örneğin, özellik piramidi ağları, fonksiyon piramitleri ve bölge tabanlı tespitçilerin kullanımı, nesne tespit performansını artırmak için umut verici sonuçlar sunmuştur. Aynı şekilde, Soft-NMS ve Cascade R-CNN gibi teknikler, nesne tespit doğruluğunu artırmak ve yanlış pozitifleri azaltmak için önerilmiştir.

Nesne tespiti için farklı yaklaşımlar da ele alınmıştır. Bu yaklaşımlar, derecelendirmeye dayalı algoritmaları (örneğin CNN ve RNN) ve regresyona dayalı algoritmaları (örneğin YOLO) içerir. Özellikle YOLO, nesne sınıflarını ve sınırlayıcı kutuları aynı anda tahmin eden daha hızlı bir algoritma olarak öne çıkar.

Ayrıca, kayıp fonksiyonlarının kullanımı da önemli bir konudur. Sınıflandırma, güven ve yerleştirme kayıpları gibi çeşitli kayıp fonksiyonları, nesne tespitindeki hataları ölçmek ve en aza indirmek için kullanılır. YOLO yaklaşımı, ilgi bölgelerini seçme ihtiyacını ortadan kaldırır ve tüm görüntü için sınırlayıcı kutuları tahmin ederek verimliliği artırır.

Makalelerin sonuçları, YOLO kayıp fonksiyonunun tahmin hatalarını azaltmadaki önemini net bir şekilde göstermektedir. Ayrıca, bir nesnenin sınırlayıcı

kutusunu bulma süreci, girdi görüntüsünün ızgaralara bölünmesi ve tespit verilerinin en yüksek güvene sahip ızgaraya atanması şeklinde açıklanmıştır.

Özetle, incelenen makaleler, derin öğrenme tekniklerinin, özellikle YOLO'nun nesne tespiti için geniş bir kullanım bulduğunu, farklı kayıp fonksiyonlarının araştırıldığını ve yerelleştirme ile sınırlayıcı kutu tahminindeki yöntemlerin geliştirildiğini göstermektedir. Bu çalışmalar, nesne tespiti alanında ilerlemeyi destekler ve otonom araçlar, yardımcı teknolojiler gibi çeşitli pratik uygulamalara katkıda bulunur (Sharma vd., 2023).

Aşağıdaki Çizelge 2.3, makalenin ana sonuçlarını ve önemli metrikleri özetlemek için kullanılan bir araçtır:

Çizelge 2.3: Makalenin Ana Sonuçlarını ve Önemli Metrikleri

Metrik	Sonuç
Sınıflandırma Doğruluğu	%96
İzleme Hassasiyeti	%85
İzleme Duyarlılığı	%60
Hesaplama Süresi (SNF)	0.021 saniye

Kaynak: (Sharma vd., 2023)

Derin öğrenme tabanlı nesne tespiti tekniklerinin dronları tespit etme performansını değerlendirmek için yapılan bir deneyi tanımlamaktadır. Deneyde, ZF ve VGG16 gibi farklı evrişimli sinir ağı (ESA) mimarileri kullanılmış ve sınırlı veri mevcudiyeti nedeniyle transfer öğrenme yöntemi uygulanmıştır. Eğitim için önceden eğitilmiş modeller kullanılmış ve en iyi modeller test veri kümesinde değerlendirilmiştir. Sonuçlar, VGG16'nın Faster R-CNN ile birlikte diğer mimarilere kıyasla daha iyi performans gösterdiğini göstermektedir. Makale ayrıca, R-CNN, Fast R-CNN, Faster R-CNN ve YOLO gibi derin evrişimli sinir ağı (ESA) kullanarak nesne tespiti için mevcut en son yöntemlere genel bir bakış sunmaktadır. Makalenin odaklandığı deney, karmaşık bir veri kümesinde dronları tespit etmeyi ve yakındaki uçan kuşlardan ayırt etmeyi gerektiren Drone-vs-Bird tespit meydan okumasında gerçekleştirilmiştir. Veri kümesi, değişen aydınlatma, ölçek değişimi ve bakış açısı farklılığı gibi zorluklar içermektedir. Bu meydan okuma, küçük dronların yasa dışı faaliyetlerde kötüye kullanılmasından kaynaklanabilecek beklenmedik durumları ve güvenlik tehditlerini önlemeyi amaçlamaktadır. Makale, farklı derin öğrenme tabanlı nesne tespit tekniklerinin dronları tespit etmedeki performansını değerlendirmek için

değerli bir araştırma sunmaktadır. Ancak, bazı zayıf noktaları da vardır. Örneğin, deney sonuçları sadece belirli bir veri kümesi üzerinde sunulmuş ve diğer veri kümelerindeki performansı test etmek için daha fazla çalışma gerekmektedir. Ayrıca, makale, kullanılan ESA mimarileri ve transfer öğrenme teknikleri hakkında daha ayrıntılı bilgi sunabilirdi. Karşılaştırmalı bir analiz ve daha geniş bir bağlama yerleştirme eksikliği, çalışmanın gerçek dünya uygulamalarındaki etkililiği hakkında daha net bir fikir verilmesini engellemektedir (Saqib vd., 2019).

Dadrass Javan vd., 2022 yılında yaptığı çalışmada , çeşitli durumlarda UAV tanıma sürecinin karmaşık olduğu ve geleneksel yöntemlerin ve hatta konvansiyonel derin öğrenme ağı yöntemlerinin bazı durumlarda iyi çalışmadığı belirtilmiştir. Bu çalışmada, drone türlerini tanımak ve kuş türlerinden ayırmak için temel YOLOv4 ağı kullanılmıştır. Tanıma doğruluğunu artırmak ve mevcut zorluklara daha iyi çözümler sunmak için bu ağı yeni ve modifiye bir modeli önerilmiştir. Bu iki ağı eğitimi, testi ve değerlendirilmesi için 26.000 görünür görüntü veri kümesi toplanmıştır ve bu veri setinde dört tür UAV (multirotor, sabit kanatdrone, helikopter ve VTOL) ile kuşlar bulunmaktadır. Bu iki modelin karşılaştırması, mAP, karışıklık matrisi, IoU, hassasiyet, doğruluk, F1 puanı ve hatırlama gibi değerlendirme metrikleri kullanılarak yapılmıştır. Modifiye edilmiş YOLOv4 modeli ile %84 IoU, %83 mAP ve %83 doğruluk başarılmıştır.

Bu da temel modele göre daha iyi bir performans sergilemektedir ve zorlukları iyi çözmektedir. Yapılan katkılara göre, UAV tanımanın çeşitli durumlarda karmaşık bir süreç olduğu ve geleneksel yöntemlerin ve hatta konvansiyonel derin öğrenme ağı yöntemlerinin bazı durumlarda iyi çalışmadığı belirtilmiştir. Drone türlerini tanımak ve kuş türlerinden ayırmak için temel YOLOv4 ağı kullanılmıştır. Tanıma doğruluğunu artırmak ve mevcut zorluklara daha iyi çözümler sunmak için bu ağı yeni ve modifiye bir modeli önerilmiştir. 26.000 görünür görüntü veri kümesini içeren bu iki ağı eğitimi, testi ve değerlendirmesi yapılmıştır. Modifiye edilmiş YOLOv4 modeli ile %84 IoU, %83 mAP ve %83 doğruluk elde edilmiştir, bu temel modele göre daha iyi bir performans sağlamaktadır ve zorlukları iyi çözmektedir.

Literatür taramanın temaları ve yaklaşımları belirlemek için seçilen makaleleri analiz edelim:

1. Drone'ların tanınması ve sınıflandırılması: Seçilen makalelerin ortak teması, drone'ların türlerinin doğru ve hızlı bir şekilde tanınmasıdır. Bu, drone'ların kötüye kullanılmasını ve izinsiz erişimi engellemek için önemlidir.
2. YOLOv4 ağı ve modifikasyonları: Birçok makalede, YOLOv4 ağı temel alınmış ve bu ağın modifiye edilerek daha iyi performans elde edildiği belirtilmiştir. Modifikasyonlar, daha kesin ve detaylı semantik özelliklerin çıkarılmasını hedeflemiştir.
3. Görüntü veri setleri ve eğitim: Makalelerde, drone tespiti için geniş veri setleri toplanmış ve bu veri setleri üzerinde eğitim yapılmıştır. Veri setlerinin içerdiği görüntülerde farklı drone türleri ve kuşlar bulunmaktadır.
4. Performans değerlendirmesi: Makalelerde, önerilen modellerin performansı farklı değerlendirme metrikleri kullanılarak değerlendirilmiştir. Bu metrikler arasında mAP, karışıklık matrisi, IoU, hassasiyet, doğruluk, F1 puanı ve hatırlama bulunmaktadır.
5. Zorluklar ve sınırlamalar: Drone tespiti konusunda bazı zorluklar ve sınırlamalar belirtilmiştir. Bu zorluklar arasında drone'ların küçük boyutu, kuşlarla karışıklık, gizli alanların varlığı ve kalabalık arka plan gibi faktörler yer almaktadır.
6. Gelecek çalışmalar ve araştırma eksiklikleri: Makalelerde, drone tanıma konusunda gerçek zamanlı tanıma, arka plan kaldırma algoritmaları ve farklı derin öğrenme ağlarının karşılaştırılması gibi konularda gelecek çalışmalara ihtiyaç olduğu belirtilmiştir.

Bu analiz sonucunda, drone tespiti alanında YOLOv4 ağı ve modifikasyonlarının sıkça kullanıldığı ve performans iyileştirmeleri sağlandığı görülmektedir. Ayrıca, veri setleri, eğitim ve performans değerlendirmesi gibi ortak metodolojik yaklaşımların olduğu gözlemlenmektedir. Ancak, hala bazı zorluklar ve sınırlamaların olduğu ve daha fazla araştırmaya ihtiyaç duyulan alanların bulunduğu belirtilmektedir. Özellikle, gerçek zamanlı tanıma, daha geniş veri setleri ve farklı derin öğrenme ağlarının karşılaştırılması gibi konularda dahafazla araştırmaya ihtiyaç olduğu görülmektedir (Dadrass Javan vd., 2022).

Çalışmada, videolardaki nesne tespiti için zamansal ve bağlamsal bilgiyi entegre eden bir derin öğrenme çerçevesi önerilmektedir. Bu çerçeve, ImageNet nesne tespiti görevinde ve ILSVRC2015 yarışmasında sunulan verilerle birlikte VID (Video Object Detection) yarışmasında en iyi performansı elde etmiştir. Çalışmada, çerçevenin bileşenleri ayrıntılı bir şekilde incelenmiş ve tartışılmıştır. Ayrıca, çerçevenin kodları herkese açıktır.

VID görevi hala yeni ve yeterince keşfedilmemiş bir alandır. Bu nedenle önerilen çerçeve, mevcut hareketsiz görüntü nesne tespiti çerçevelerine dayanmakta ve özellikle videolar için tasarlanmış önemli bileşenler eklemektedir. Bu bileşenlerin bilgisi, ileriye dönük çalışmalarda end-to-end sistemlere dahil edilebileceğine inanılmaktadır ve bu, gelecekteki araştırma yönü olarak kabul edilmektedir.

Nesne tespiti alanında son zamanlarda önemli gelişmeler kaydedilmiştir, ancak videolar için özel olarak tasarlanmış nesne tespiti çerçeveleri hala eksikliktedir. Bu makalede, videolardan elde edilen "tubelet" adı verilen görüntülerdeki zamansal ve bağlamsal bilgileri içeren bir derin öğrenme çerçevesi olan T-CNN (tubelets with convolutional neural networks) önerilmektedir. Bu çerçeve, mevcut hareketsiz görüntü nesne tespiti çerçevelerini videolar için uyarlayarak temel performansı önemli ölçüde artırmaktadır. T-CNN çerçevesi, zamansal ve bağlamsal bilgiyi videolardan elde edilen tubeletler aracılığıyla başarıyla entegre etmektedir.

Bu çalışma, VID görevinde en iyi performansı sağlayarak videolardaki nesne tespiti alanında yeni bir başarı elde etmektedir. Ancak, VID görevinin hala yeni bir alan olduğu ve geliştirilmesi gereken bileşenler içerdiği belirtilmektedir. Bu nedenle, gelecekteki çalışmaların bu alanda daha fazla araştırma yapmayı ve çerçevenin geliştirilmesini içermesi beklenmektedir.

Sonuç olarak, nesne tespiti alanında derin öğrenme kullanımı önemli başarılar elde etmiştir, ancak videolardaki nesne tespiti için daha özelleştirilmiş çerçevelerin geliştirilmesi gerekmektedir. Bu alanda gelecekte yapılacak çalışmalar, videoların nesne tespiti alanındaki zorluklarını daha iyi anlamayı, zamansal ve bağlamsal bilgiyi daha etkili bir şekilde kullanmayı ve end-to-end sistemlerin incelenmesini içermelidir (Kang vd., 2017).

Çalışmada, yüksek çözünürlüklü görüntülerden hızlı hareket eden ve görünümü değişen bir hedefi 360 derece görüş alanında tespit edebilen ve takip edebilen 500 fps görüntü işleme sistemine sahip bir görüntü takip sistemi önerilmektedir. Sistem, yüksek hızlı bir kameradan, pan-tilt Galvano aynalı sistemden ve 360 derece dönebilen ayna kontrol sisteminden oluşmaktadır. Sistem sayesinde, hedef nesnenin yüksek çözünürlüklü görüntüleri elde edilerek karmaşık görsel özellikler kullanılarak uzaktaki bir nesnenin 360 derece görünümü takip edilebilir hale gelmektedir. Ayrıca, yüksek hızlı hedef takibi için karmaşık bir arka plana karşı görünümü değişen bir nesnenin aynı anda tespit edilmesini ve takip edilmesini sağlayan bir akıllı yüksek kare hızı (HFR) hedef takip algoritması tanıtılmaktadır. Önerilen gözetim sistemi aynı anda kontrol edilen 3D ışık algılama ve mesafe ölçme (LiDAR) sensör sistemi ve aktif spot ışık yansıtma sistemi kullanarak düşük ışık koşullarında güçlü bir görüntü takibine imkan sağlamaktadır. Önerilen omnidirectional görüntü takip sisteminin etkinliği, 25 mm odak uzaklığına sahip bir mercekle kullanılarak gündüz ve gece koşullarında birkaç metre uzaktaki insanların omnidirectional tespit ve takip deneyleriyle gösterilmiştir. Bu çalışmada, yüksek çözünürlüklü görüntülerden 360 derece görüş alanında prelearned nesneleri sağlam bir şekilde takip edebilen bir görüntü gözetleme sistemi geliştirildi. Elde edilen yüksek kare hızlı görüntülerden akıllı bir HFR hedef takip algoritması tanıtıldı ve görüntülerden görünümü değişen bir nesneyi karmaşık bir arka plandan tespit etme ve takip etme yeteneği sağlandı. Ayrıca, önerilen gözetim sistemi, düşük ışık koşullarında 3D LiDAR sensör sistemi ve eşzamanlı olarak kontrol edilen aktif spot ışık yansıtma sistemi kullanarak güçlü bir görüntü takibine imkan vermektedir. Önerilen omnidirectional takip sisteminin performansı, karmaşık doğal sahneler altında hem gündüz hem de gece ortamlarında insanların takibiyle deneysel olarak gösterilmiştir. Önerilen omnidirectional görüntü takipBu çalışmada, yüksek çözünürlüklü görüntülerden 360 derece görüş alanında prelearned nesneleri sağlam bir şekilde takip edebilen bir görüntü gözetleme sistemi geliştirildi. Elde edilen yüksek kare hızlı görüntülerden akıllı bir HFR hedef takip algoritması tanıtıldı ve görüntülerden görünümü değişen bir nesneyi karmaşık bir arka plandan tespit etme ve takip etme yeteneği sağlandı. Ayrıca, önerilen gözetim sistemi, düşük ışık koşullarında 3D LiDAR sensör sistemi ve eşzamanlı olarak kontrol edilen aktif spot ışık yansıtma sistemi kullanarak güçlü bir görüntü takibine imkan vermektedir. Önerilen omnidirectional takip sisteminin performansı, karmaşık doğal sahneler

altında hem gündüz hem de gece ortamlarında insanların takibiyle deneysel olarak gösterilmiştir. Önerilen omnidirectional görüntü takip sistemi, diğer belirtilmiş uygulamalar için daha fazla HFR takip algoritması uygulamayı hedeflemekte olup, ileriye dönük araştırma yönümüzdür (Jiang vd., 2021).

Yapılan çalışmada, video nesne tespiti için Single Shot Video Object Detector (SSVD) adlı bir derin öğrenme mimarisi tanıtılmıştır. SSVD, tek aşamalı dedektörlere göre daha hızlı ve basit olan tek çekim dedektörlerin videolara uyarlanmasını ele almaktadır. Video görüntülerinde görünüm bozulmaları (hareket bulanıklığı, kapatma) var olduğunda, tek çekim dedektörlerinin videolara uygulanması zor olabilmektedir. Bu çalışma, kareler arası zamansal tutarlılığın nesne tespitini artırmak için nasıl kullanılabileceğini incelemektedir.

SSVD, Feature Pyramid Network (FPN) temel ağı kullanarak çok ölçekli özellik haritaları üretmektedir. Diğer özellik birleştirme yöntemlerinden farklı olarak, SSVD, hareketi tahmin ederek ve bitişik karelerden özellikleri örnekleyerek özellikleri bir araya getirir. Hareket akışı, optik akıştan hareketi tahmin ederek yakındaki karelerin özellik haritalarını referans kareye doğru kaydırır. Örnekleme akışı ise bitişik karelerden özellik haritasını oluşturur. Her bir akışta birleştirilen özellik haritası, sınıf/box alt ağlarına giriş olarak verilerek çapa kutularını sınıflandırma ve sınırlayıcı kutu regresyonu işlemlerini yapar. ImageNet VID veri kümesi üzerinde yapılan deneyler, SSVD'nin diğer yöntemlerle karşılaştırıldığında rekabetçi sonuçlar verdiğini göstermiştir. Özellikle, 448x448 boyutunda giriş için SSVD, Nvidia Titan X Pascal GPU üzerinde 85 ms'de bir kareyi işleyerek ImageNet VID veri kümesinde %79.2 mAP başarısı elde etmiştir. Sonuç olarak, SSVD, zamansal tutarlılığı kullanarak video nesne tespitini artırmak için tasarlanmış bir derin öğrenme mimarisidir. İki akışlı özellik birleştirmeyi tek aşamalı bir dedektöre entegre ederek performansını göstermektedir. Yapılan deneyler, SSVD'nin ImageNet VID veri kümesinde en iyi performansı gösterdiğini ve hızlı bir şekilde çalışabildiğini ortaya koymuştur (Deng vd., 2020).

Yapılan çalışma, Drone tespiti için kullanılan farklı ESA mimarileri, veri seti oluşturma teknikleri, özellik çıkarma yaklaşımları ve eğitim-değerlendirme yöntemleri üzerine yapılan literatür taraması sonuçlarına dayanarak, çeşitli önemli bulgular elde edilmiştir. ESA'nin drone tespiti alanında büyük bir potansiyele sahip olduğu ve diğer yöntemlerle karşılaştırıldığında etkinliğinin vurgulandığı

görülmüştür. Farklı makalelerde kullanılan ESA mimarileri ve algoritmaları çeşitlilik göstermektedir. Örneğin, YOLOv3 ve SSD gibi algoritmaların hız ve doğruluk arasında bir trade-offu bulunmaktadır. Veri seti oluşturma teknikleri, özellik çıkarma yaklaşımları ve eğitim-değerlendirme yöntemleri konusunda makaleler arasında farklı yaklaşımlar bulunmaktadır. Örneğin, unsupervised öğrenme ve engel doğrulama algoritmalarının kullanıldığı, optik akış ve Magnitüd Histogramı gibi kavramların gözle görülemeyen nesnelerin hareketini analiz etmek için kullanıldığı yaklaşımlar önerilmiştir. Ayrıca, literatürdeki makalelerde tek nesne tespitinden çoklu nesne takibine kadar farklı konular ele alınmıştır. YOLOv3 gibi gelişmiş algoritmaların ince sınırlayıcı kutular ve bitişik pikselleri etkilemeden geliştirildiği, COCO veri kümesinde iyi sonuçlar verdiği ve daha hızlı işleme hızları sağladığı belirtilmiştir. Ayrıca, çoklu nesne takibinin kernelized correlation filter (KCF) gibi yöntemlerle gerçekleştirilerek arka plan çıkarma ile birlikte güvenilir sonuçlar elde edildiği görülmüştür. Bu literatür taramasından elde edilen bilgilere dayanarak, gelecekteki araştırma yönleri ve alanları şunlar olabilir: ESA mimarileri, veri kümesi toplama yöntemleri ve gerçek zamanlı uygulamalarda iyileştirmeler yapılabilir. Farklı ESA mimarilerinin daha detaylı bir şekilde karşılaştırmalı analizi gerçekleştirilebilir. Drone tespiti alanında karşılaşılan sınırlamalar ve zorluklar üzerine daha derinlemesine bir tartışma yapılabilir. Ayrıca, literatürdeki boşluklar ve daha fazla araştırmaya ihtiyaç duyulan alanlar belirlenerek gelecekteki çalışmalar için öneriler sunulabilir. Son olarak, ESA'nın drone tespiti için potansiyel Drone tespiti için kullanılan farklı ESA mimarileri, veri seti oluşturma teknikleri, özellik çıkarma yaklaşımları ve eğitim-değerlendirme yöntemleri üzerine yapılan literatür taraması sonuçlarına dayanarak çeşitli önemli bulgular elde edilmiştir. Drone tespiti alanında ESA'nın potansiyeli vurgulanmış ve diğer yöntemlerle karşılaştırıldığında etkinliği gösterilmiştir. Farklı makalelerde kullanılan ESA mimarileri ve algoritmaları çeşitlilik göstermektedir. Örneğin, YOLOv3 ve SSD gibi algoritmalar hız ve doğruluk arasında bir trade-off sunmaktadır. Veri seti oluşturma teknikleri, özellik çıkarma yaklaşımları ve eğitim-değerlendirme yöntemleri de makaleler arasında değişmektedir Aşağıdaki Çizelge 2.4, seçilen çalışmaların sonuçlarının özet bir bakışını sunmaktadır. Çizelge, her bir çalışmanın kullandığı ESA mimarilerini, tespit doğruluğunu, işleme hızını ve temel sonuçları içermektedir (Mohana ve Aradhya, 2019).

Çizelge 2.4: İHA Tespiti İçin ESA Mimarileri ve Bulguları

Çalışma	ESA Mimarisi	Tespit Doğruluğu	İşleme Hızı	Temel Bulgular
1	YOLOv3-tabanlı ESA	Yüksek	Hızlı	Hız ve doğruluk dengesini sağlayan etkili bir drone tespiti yöntemi.
2	SSD-tabanlı ESA	Orta	Hızlı	Hız ve doğruluk arasında denge sunan, özellikle COCO veri kümesinde etkili.
3	Özelleştirilmiş ESA Model	Yüksek	Hızlı	Uyarlanmış bir ESA mimarisi kullanarak önemli bir tespit doğruluğu.
4	Denetimsiz Öğrenme ile ESA	Orta	Orta	Tespiti artırmak için denetimsiz öğrenme tekniklerinin potansiyeli.
5	Çok Nesne Takibi için ESA	Yüksek	Hızlı	Çoklu nesne takiplerinde başarılı uygulama, özellikle arka plan çıkarma ile birlikte.

Bu çalışmalarda, havaalanlarında güvenlik tehditlerine neden olan drones ve kuşların etkili bir şekilde tespit edilmesi ve tanınması için derin öğrenmeye dayalı bir yöntem önermektedir. Drones'ların ve kuşların benzer davranış ve görünüşlerinden kaynaklanan zorlukları çözmek amacıyla önerilen yöntem, YOLOv4 mimarisini kullanan bir Konvolüsyonel Derin Öğrenme Ağı kullanmaktadır. Çalışma için, multirotorlar, helikopterler ve kuşlar olmak üzere iki tür drone'u içeren 10.000 görünür görüntüden oluşan bir veri seti toplanmıştır. Önerilen derin öğrenme yöntemi, drone'ların varlığını tespit etme, farklı drone türlerini tanımlama ve kuşlardan ayırma yeteneğine sahip olarak %83 doğruluk, %84 ortalama hassasiyet (mAP) ve %81 kesişim üzeri birleşme (IoU) elde etmektedir. Çalışma, ileride farklı derin öğrenme ağlarının performansını karşılaştırmak, drone-kuş tespiti ve tanımlamanın yanı sıra sabit kanatlı ve VTOL gibi diğer drone türlerini de tespit etmeyi hedeflemektedir. Dronların tespit, tanıma ve yerleşimini gerçek zamanlı ve taşıma sistemlerinde gerçekleştirebilmek için de çalışmalar yapılması planlanmaktadır (Samadzadegan vd., 2022).

Jurn, Mahmood, Aldhaibani 2021 yılında yazdığı makalesinde, drone tespiti ve sınıflandırmasında kullanılan farklı teknikler, görüntü tabanlı, termal görüntü tabanlı, akustik tabanlı, video tabanlı ve RF tabanlı yöntemler olarak tartışılmaktadır. Her bir yöntemin avantajları ve sınırlamaları vurgulanmakta ve özellikle makine öğrenimi ve derin öğrenme algoritmaları, özellikle konvolüsyonel sinir ağları

(ESA'ler), drone tespiti ve sınıflandırmasını geliştirmek için kullanılmaktadır. Makale, drone'ların farklı işletme tekniklerine sahip olması nedeniyle drone tespiti için çeşitli anti-drone teknolojileri gerektiğini belirtmektedir. Önerilen anti-drone sistemi, RF tespit tekniği ve ESA algoritmasına dayanmaktadır. RF tespit tekniği düşük maliyetli ve uzun menzilli bir tespit imkanı sağlarken, ESA tabanlı sınıflandırma süreci RF parmak izi veri setini kullanarak dronları kuşlardan ve farklı dron tiplerinden ayırt etmektedir. Makalenin sonuçları, drone tespiti, sınıflandırma, lokalizasyon ve müdahale gibi konuların önemli zorluklar içerdiğini vurgulamaktadır. Mekânsal olarak dağıtılmış ağ sensörlerinden oluşan modern anti-drone sistemlerinin, korunan alanın tam kapsamını sağlamak için umut verici bir teknik olduğu belirtilmektedir. Bununla birlikte, her bir teknik yaklaşımın avantajlarını ve sınırlamalarını dikkate almak önemlidir. Makalede sunulan bilgiler, drone tespiti ve sınıflandırması alanındaki mevcut yaklaşımların güçlü ve zayıf yönlerini tartışmakta ve gelecekteki araştırma yönelimleri için bir yol haritası sunmaktadır. ESA mimarileri, veri kümesi oluşturma teknikleri, özellik çıkarma yaklaşımları ve eğitim-değerlendirme yöntemleri gibi konular üzerinde daha fazla çalışma yapılabilir. Ayrıca, gerçek zamanlı uygulama, ESA mimarileri, veri toplama ve geliştirme gibi alanlarda iyileştirmeler yapılması gerekmektedir (Jurn, Mahmood, Aldhaibani 2021).

Garcia, 2020 yılında yayımladığı makalede, optik algılama kullanarak insansız hava aracı (İHA) savunma sistemi önermektedir. ResNet-101 ve R-CNN ağları kullanılmış ve eğitim için SafeShore projesinden bir veri seti kullanılmıştır. Sistem %93.40 doğruluk oranı elde etmekte ve SafeShore veri seti üzerinde yapılan simülasyonlarda İHA'ları başarılı bir şekilde tespit etmektedir. Veri setine kuşların da eklenmesiyle yapılan testlerde İHA'ları etkili bir şekilde ayırt edebildiği gösterilmiştir. Gelecek çalışmalar için yazarlar, daha hızlı bir R-CNN veya farklı bir yapay sinir ağı (YSA) ile diğer sinir ağlarının kombinasyonunu keşfetmeyi ve doğruluğu artırmak için görüş tabanlı küçük ölçekli bir İHA algılama sistemi geliştirmeyi önermektedirler. Ayrıca, kendi oluşturulan bir veri setiyle akustik sinyal algılama yaklaşımını kullanarak İHA'ları sınıflandırmak için çoklu modaliteye sahip bir sinir ağı geliştirmeyi önermektedirler. Bu literatür taraması, hırsızlık İHA'larından alanları korumak için talep edilen bir İHA savunma sistemi ihtiyacını ele almaktadır. İHA'lar geniş bir erişilebilirlik ve çeşitli amaçlar için yaygın olarak

kullanılmaktadır, ancak aynı zamanda hırsızlık, casusluk ve yasa dışı madde taşıma gibi riskleri de beraberinde getirmektedir. İHA tespiti için radar, ses, video ve radyo frekansı (RF) verileri gibi farklı gözetim teknolojileri önerilmiştir. Sonuç olarak, önerilen görsel algılama ağı yüksek bir doğruluk oranı elde etmekte ve İHA'ları başarılı bir şekilde tespit etmektedir. ESA kullanarak İHA tespiti için farklı yaklaşımların güçlü ve zayıf yönlerine vurgu yapılmaktadır. Literatürdeki boşlukları ele almak ve gelecekteki araştırma yönelimlerine dikkat çekmek amacıyla ESA'nın İHA tespiti için potansiyelini ve mimariler, veri seti toplama ve gerçek zamanlı uygulamalar gibi alanlarda yapılması gereken iyileştirmelerin önemi vurgulanmaktadır (Garcia vd., 2020).

3. MATERİYAL VE YÖNTEM

3.1. Veri Seti Hazırlama Araçları

Makine öğrenmesi tabanlı görüntü yorumlamaları, bilgisayar görüşü, robot görüşü ve yüz tanıma gibi çeşitli uygulamalar için kritik bir öneme sahiptir. Bu tür uygulamaları eğitmek için görüntüleri kimlikler, başlıklar veya anahtar kelimeler gibi meta verilerle ilişkilendirmek gereklidir. Örneğin, kendiliğinden sürücü araçları, ürünleri otomatik olarak tanıma ve sıralama yeteneğine sahip olmalıdır. Benzer şekilde, sağlık uygulamaları, tıbbi teşhisleri desteklemek için büyük miktarda etiketlenmiş görüntülere ihtiyaç duyar.

Etiketleme, bu sistemlerin doğruluğunu ve hassasiyetini artırarak verimli bir şekilde eğitilmesinde hayati bir rol oynamaktadır. Bu çalışma, bu amaca ulaşmak için temel araçları öğrenmeyi hedeflemektedir (Potter, 2021).

Tezde kullanılan veriler, gerçek dünya verileri ve herkese açık kaynaklardan alınan verilerden oluşmaktadır. Gerçek dünya verileri kişisel olarak saha çalışmalarıyla toplanmıştır, herkese açık veriler ise internet üzerinden elde edilmiştir. Tüm verilerin etiketleri, işlemi kolaylaştırmak ve uygun bir formatta kullanmak amacıyla YOLO formatına dönüştürülmüş veya bu formatta oluşturulmuştur.

3.1.1 Açık kaynak kullanılabilen veri kümesi

Bu tezde, çevrimiçi açık kaynak kaynaklarından iki veri kümesi kullanıldı. Biri "SimUAV" (Rui vd., 2021), diğeri ise "Wild Bird dataset" (R. Yoshihashi ve diğeri, 2017) idi. Çevrimiçi drone veri kümesi arayışında, mevcut drone veri kümesinin az sayıda küçük boyutta drone hedefleri içerdiği veya farklı drone türlerinin açıkça farklı kategoriler olarak etiketlendiği bulundu. "SimUAV" veri kümesi, Airsim ve UE4 tarafından uygulanan bir simüle edilmiş drone veri kümesidir (C. Rui ve diğeri, 2021). Airsim bir drone simülatörüdür ve UE4, dronların uçabileceği farklı ortamlar oluşturmak için kullanılır (C. Rui ve diğeri, 2021). Bu veri kümesinde, yazar Parrot A.R. Drone, DJI Inspire I, DJI Mavic 2 Pro ve DJI

Phantom 4 Pro olmak üzere dört farklı drone modeli kullanmış ve bu dronelar farklı etiketlerle etiketlenmiştir (C. Rui ve diğerleri, 2021).

SimUAV veri kümesinde sadece DJI Mavic 2 Pro içeren 4,095 adet görüntü bulunmaktadır (C. Rui ve diğerleri, 2021). Bu veri kümesi, bu tezde kullanılan modelin performansını, eğitim verisinin test verisinden farklı bir kamerayla alınması durumunda nasıl etkileneceğini karşılaştırmak için kullanılmıştır. Bu veri kümesindeki tüm görüntüler 640×640 pikseldir (C. Rui ve diğerleri, 2021). Wild Bird veri kümesi Japonya'da bir rüzgar çiftliğinde dijital bir fotoğraf makinesiyle toplanmıştır (R. Yoshihashi ve diğerleri, 2017). Görüntülerin çözünürlüğü 5616×3744 pikseldir. Bu veri kümesinde, kuş etiketleri içeren 2,371 adet görüntü bulunmaktadır. Bu görüntüler, modelin drone ve kuşları ayırt etme performansını geliştirip geliştirmeyeceğini araştırmak için kullanılmıştır (R. Yoshihashi ve diğerleri, 2017).

3.1.2 Gerçek dünya veri kümesi

Videodan saniyede 10 kare hızında görüntüler çıkarıldı. Toplamda 9,000 adet görüntü bulunuyordu (her kamera için 3,000 görüntü). Her görüntüde yalnızca bir drone bulunuyordu. Yukarıdaki görüntülerle sistemin uygulanmasından sonra, modelin bazen kuşları dronlar olarak tanıdığı tespit edildi. Bu nedenle, ekstra kuş görüntüleri Samsung s23 ultra ile çekildi. Kuşların kontrolü zor olduğu ve ne zaman ve nerede görüneceklerinin tahmin edilemediği için, yalnızca 1,069 kuş görüntüsü çekildi ve bu sayı dron görüntülerinden çok daha azdı.

3.1.3 Fotorealistik görüntülerle sentetik veri kümesi oluşturma

Bu bölümde, Blender adlı açık kaynaklı 3D modelleme programını kullanarak sentetik veri kümesi oluşturma süreci açıklanmaktadır (C. Rui ve diğerleri, 2021). Kamera, drone görüntülerini çekmek için Blender'da oluşturulan bir simülasyonu kullanmaktadır. Simülasyonun temel amacı, dronenin konumunu, yönelimini ve arka planını rastgeleleştirerek fotorealistik görüntüler oluşturmaktır. Her adımda bir drone görüntüsü oluşturulmakta ve ardından parametreler rastgeleleştirilerek başka bir görüntü elde edilmektedir. Bu şekilde teorik olarak sınırsız sayıda veri üretmek mümkündür.

Sentetik veri kümesi oluşturma, sinir ağı eğitimi sırasında bir zorluk teşkil etmektedir. Gerçek dünya veri kümesi oluştururken drone etrafına sınırlayıcı kutular çizmek zaman alıcı bir görevdir. Alan rastgeleleştirme gibi sentetik görüntü oluşturma yöntemleri, sinir ağı modelini sentetik veri üzerinde eğitip gerçek dünya problemlerinde kullanmanın mümkün olduğunu göstermektedir. Bu nedenle, bu çalışmada tamamen sentetik bir veri kümesi üzerinde bir model eğitmeye ve gerçek dünya Anti-UAV veri kümesinin video akışı üzerinde test etmeye karar verdik. Bu yaklaşımın avantajları şunlardır:


- Gerçek dünya deneylerinin maliyetinden ve zamanından tasarruf sağlar. Dronlar pahalıdır ve eğitimli operatörlere ve bir kamera operatörüne ihtiyaç duyarlar.
- Gerçek dünya videolarda her kareyi manuel olarak etiketlemek zaman alıcı bir işlemdir.
- Veri kümesinde daha fazla değişkenlik sağlar. Gerçek dünya deneylerinde oluşturulması zor olan özel senaryolar oluşturmak mümkündür. Örneğin, yağmur veya kar gibi hava koşulları simüle edilebilir. Bu koşullar, dronları içeren gerçek dünya deneylerinin zorluklarıdır. Bu çalışmada böyle senaryolar oluşturmasak da, gelecekteki çalışmalar için ilginç bir fikir olabilir.

Veri kümesini oluşturmak için öncelikle DJI Phantom ve DJI Mavic dronlarını modellendik. Ayrıca, Sketchfab web sitesinden DJI Inspire için ücretsiz bir 3D modeli keşfettik (Coupey, G., 2017). Blender kullanarak, dronların rastgele görüntülerini oluşturan bir betik geliştirdik. Görüntü oluşturma süreci Şekil 1'de gösterilmiştir. Şekil, bir dronun 3D modelinin nasıl kullanıldığını ve görüntülere dokuların ve yüksek dinamik aralıklı görüntülerin (HDRI) nasıl eklendiğini göstermektedir. Şekil 2'de, Blender'da oluşturulan simülasyonla elde edilen rastgeleleştirilmiş sentetik görüntüler görülmektedir. Farklı dron tipleri: DJI Phantom, DJI Mavic ve DJI Inspire gösterilmektedir. Ayrıca, "hiç dron" sınıfı da bulunmaktadır, bu sınıf sadece rastgele arka plan görüntüleri içermekte olup hiçbir dron görüntüsü içermemektedir.

3.1.4 Roboflow çerçevesi

En popüler veri kümesi işaretleme formatlarından ikisi Pascal VOC ve Microsoft COCO'dur. YOLOv5s modeli üzerinde çalıştığımız için, önceden COCO Veri Kümesi üzerinde eğitilmiş modellerle çalıştığımız için veri kümemizi Microsoft COCO veri kümesi işaretleme formatına göre hazırlayacağız. Bu nedenle, hedefimize ulaşmak için RoboFlow'a güveneceğiz. Bilgisayar görüşü geliştiricileri, iş akışlarını iyileştirmek için RoboFlow'un veri toplama, ön işleme ve model eğitim araçlarını kullanabilirler. Kullanıcılar, kendi verilerini RoboFlow'a ekleyebilirler ve ayrıca genel veri kümelerine erişebilirler. RoboFlow, çeşitli işaretleme formatlarını destekler. Veri ön işleme sürecinin bir parçası olarak görüntü döndürme ve yeniden boyutlandırma gibi adımlar, kontrast ayarları ve veri artırma gibi işlemler bulunmaktadır. Tüm süreci yönetebilen ekipler de bulunmaktadır. EtkinNet, MobileNet, Yolo, TensorFlow, PyTorch gibi model kütüphaneleri model eğitimi için kullanılabilir. Sonuç olarak, model dağıtımı ve görselleştirme seçenekleri aracılığıyla tamamiyle güncel teknolojiye erişim sağlanabilir (Bhattacharyya, 2020).

RoboFlow çerçevesi, YOLO V5 algoritmasının verilerini etiketlemek için kullanıldı. Bu ortam, üzerinde çalışmak için gereken algoritmaya bağlı olarak çeşitli çıktılar üretmeye yardımcı olduğu için, verinin merkezileştirilmesi için RoboFlow çerçevesi tercih edilir. Şekil 3.1, RoboFlow çerçevesi kullanılarak modeli eğitmek için ana veri dosyası olarak elde edilen sonucu göstermektedir. Şekil 3.2, nesnelerin RoboFlow çerçevesi kullanılarak nasıl etiketlendiğini göstermektedir.




```
0001.jpg.rf.29bd385304f7d8d7afc84ce0618dce1c.txt
~/cachefr-J5g2IY/train/labels

1 0 0.24453125 0.1625 0.4890625 0.325
2 0 0.396875 0.5234375 0.1158203125 0.1404296875
3 0 0.09453125 0.4921875 0.1890625 0.234375
4 0 0.74453125 0.16171875 0.5109375 0.3234375
5 0 0.25390625 0.728125 0.4703125 0.2375
6 0 0.27890625 0.925 0.2578125 0.15
7 0 0.74453125 0.8046875 0.5109375 0.390625

Plain Text ▾ Tab Width: 8 ▾ Ln1, Col1 ▾ INS
```

Şekil 3.1: RoboFlow Etiketlemek Sonuç



Şekil 3.2: İHA Etiketlemek İçin Roboflow Çerçevesini Kullanma

Kaynak: Uğuz, Şikaroğlu ve Yağız (2022)

3.1.5 Veri kümesi ön işleme

Ön işleme, toplanan veri kümesi üzerinde modeli eğitmeye başlama işlemini önceleyen adımdır. Daha önce veri kümesi hazırlama bölümünde belirtildiği gibi, ön işleme adımlarından biri boyutlandırma işlemidir; bu nedenle verilerin, verinin eğitileceği algoritmanın türüne göre boyutu değiştirilmiştir. Veri ön işleme sürecindeki kritik adımlardan biri, bu adımın dönme, ölçeklendirme, kaydırma vb. teknikler kullanarak veri kümesindeki veri miktarını artırmasıdır. Şekil 3.3 veri artırmanın türlerini göstermektedir. Bu bölümün başında belirttiğimiz gibi, küçük bir veri kümesine dayandığımız bir durumda, daha iyi tahmin sonuçları elde etmek için veri miktarını artırmak için veri artırma adımına ihtiyacımız var.


Augmentation Options



IMAGE LEVEL AUGMENTATIONS



BOUNDING BOX LEVEL AUGMENTATIONS




Şekil 3.3: RoboFlow Veri Artırma Kullanımı

Kaynak : (Uğuz, Şikaroğlu ve Yağız'ın (2022))

3.1.6 Modellerin eğitilmesi ve test edilmesi

Eğitim sürecine başlamadan önce veri kümesini üç bölüme ayırmalıyız: modelin eğitimi için bir bölüm, modelin etkinliğini kontrol etmek için başka bir bölüm ve son olarak modelin test edilmesi için bir bölüm. Şekil 3.4, RoboFlow çerçevesini kullanarak veri kümesinin bölünmesini göstermektedir. Eğitim için %70, doğrulama için %20 ve test için %10 şeklinde bir bölümlleme kullandık.



Şekil 3.4: Veri Kümesini Ayırmak İçin RoboFlow Kullanımı

Sonraki paragraflarda, her modelin ayrı ayrı nasıl eğitildiği ve her modelin sonuçlarının nasıl test edildiği, YOLOv5 ile açıklanacaktır.

Bu adımda, YOLOv5 modelini veri kümemizi eğitmek için hazırlamak için Google Colab platformunu kullanıyoruz. Google Colab kullanmanın faydası, yüksek GPU ve RAM kullanmamıza izin veren bir bulut tabanlı sanal makine (VM) oluşturabilmesidir. Başlangıçta, sanal makine üzerinde gerekli ortamı kurmamız gerekiyor. İlk olarak, GitHub'daki resmi depodan YOLOv5 kurulum dosyasını klonluyoruz, Şekil (3.5) şeklinde gösterildiği gibi.

```
Follow link (ctrl + click)
!git clone https://github.com/ultralytics/yolov5 # clone
%cd yolov5
%pip install -qr requirements.txt comet_ml # install

import torch
import utils
display = utils.notebook_init() # checks


YOLOv5 v7.0-212-g9974d51 Python-3.10.12 torch-2.0.1+cu118 CUDA:0 (Tesla T4, 15102MiB)
Setup complete (2 CPUs, 12.7 GB RAM, 26.3/78.2 GB disk)
```

Şekil 3.5: YOLOv5 Modelini Google VM'ye Klonlama

Kaynak : (Jocher'in (2020)

3.2 İnsansız Hava Aracı Tespit Sistemi Tasarımı ve Uygulaması

Birçok çalışma, çeşitli derin öğrenme algoritmalarını kullanarak nesne tespiti çözümler sunmaktadır. Bu nedenle, araştırmamızın bu bölümünde, derin öğrenme tekniklerini kullanmak için gereken adımları özellikle drone tespit sistemi bağlamında açıklamayı amaçlıyoruz. İstenilen hedefe ulaşmak için bu bölümün ilk süreci veri kümesinin oluşturulması ve başlatılmasıdır. Daha sonra, YOLOv5 teknikleri kullanılarak modelin kendi verilerimiz üzerinde eğitilmesi ve bu modelin daha önce görmediği görüntülerde nesneleri algılamak için kullanılması işlemi gerçekleştirildi. Modelleri eğitmek için Google Colab platformu kullanıldı. Şekil 3.1, drone tespit sistemimizin uygulama adımlarının özetini göstermektedir.



Şekil 3.6: Sistem Akışı

Google, Kaggle, Flickr, Instagram gibi kamu kaynaklarından drone ve kuş görüntüleri topladık. Drone görüntüleri farklı yüksekliklerden, açılardan, arka planlardan ve görünüşlerden geldi, veri kümesinde çeşitlilik sağlandı. Kuş görüntüleri 300 farklı türü içeriyordu. Tüm veri kümesi 479 kuş görüntüsü ve 1442 drone görüntüsü kullanılarak oluşturuldu; toplamda 2395 görüntüden oluşuyordu. YOLOv5 modelini eğitmek ve test etmek için 70:30 eğitim:test bölmesi kullandık. Eğitim veri kümesinde 1677 görüntü bulunurken, test veri kümesinde 718 görüntü bulunuyordu. Veri yetersizliğini aşmak için veri artırma teknikleri kullandık. Aslında, veri artırmanın 3 farklı varyantını kullanarak toplamda 5749 görüntü oluşturduk. Ücretsiz bir etiketleme aracı kullanarak görüntüleri etiketledik ve iki sınıfa böldük. Drone görüntüleri "birinci sınıf" olarak ve kuş görüntüleri "sıfır sınıfı" olarak etiketlendi. YOLO uygulaması, tüm görüntülerin nesnenin dört koordinatını

ve 0 veya 1 sınıfını içeren .txt formatında kaydedilmesini gerektirir. İki farklı drone ile iki video kaydedildi: DJI Mavic Pro ve DJI Phantom III. Videoları 60 feet, 40 feet ve 20 feet olmak üzere üç farklı yükseklikte çektik. Bu yükseklikler, özellikle drone hobileri için yaygın olarak kullanılan yüksekliklerdir. 60 feet'te drone neredeyse bir kuş gibi görünüyordu. Videoları YOLOv5 modelinin doğruluk ve hız performansını değerlendirmek için özellikle yüksek yüksekliklerde kullanıldı. Deneyi Google CoLab kullanarak gerçekleştirdik, kodu uygulamak için ücretsiz bir bulut defteri olan Google CoLab'ı kullandık. Orijinal YOLOv5'i özelleştirilmiş veri kümemizi eğitmek ve test etmek için ince ayar yaptık. Transfer öğrenme tekniği kullanarak tespit doğruluğunu hızlandırmak ve iyileştirmek için ağırlıkları kullandık. Orijinal YOLOv5 ile birlikte sunulan ağırlıkları uygulamak için YOLOv5 modelimizi COCO veri kümesini eğitirken kaydedilen YOLOv5s.pt ağırlığı üzerine eğittik. Orijinal YOLOv5, PyTorch kullanılarak uygulandı ve biz de PyTorch'u seçtik. Modeli eğitirken Google CoLab, 15110MiB belleğe sahip bir Tesla T4 ile donatılmış bir NVIDIA GPU tahsis etti. YOLOv5'i ince ayarlamak için aşağıdaki gibi önerilen çeşitli hiperparametre değerlerini seçtik: lr (öğrenme oranı) 0.01, momentum 0.937 ve decay (azalma) 0.0005. Model, stokastik gradyan inişini kullanarak optimize edildi. Albümentasyonlar Blur (p = 0.01, bulanıklık sınırları = (3,7)), MedianBlur (p = 0.01, bulanıklık sınırları = (3,7)), ToGray (p = 0.01) ve CLAHE (p = 0.01, kırpm sınırları = (1,4.0), title_grid_size = (8,8)) olarak kullanıldı. 80'den 2'ye sınıf sayısını değiştirdik, çünkü 2 sınıfımız vardı: drone ve kuş. Model 214 katmana sahipti ve 7,025,023 parametre, 7,025,023 gradyan ve 16.0 GFLOPs'a sahipti. Veri artırma ve ön işleme işlemlerini gerçekleştirmek için Roboflow API'sini kullandık. Daha önceki deneyimizde kullandığımız aynı veri kümesini kullandık. Veri ön işleme teknikleri olarak Auto-orient ve sınıfları değiştirme kullanıldı. Auto-orient, görüntülerin kaynak cihazın yönlendirmesine uygun olmasını sağlayan bir görüntü işleme tekniğidir. Bazı kameralardaki koordinatlar (x, y) ve (y, x) karıştırılabilir. Auto-orient, YOLOv5'e yanlış verilerin iletilmesini önler. Veri artırma işlemini Roboflow API kullanarak gerçekleştirdik, bu da veri yetersizlik sorununu azaltmaya yardımcı oldu. Parametreleri aşağıdaki gibi ayarladık: flip (çevirme): yatay, hue (ton): -25 derece ile +25 derece arasında, cutout: her biri %10 boyutta 3 kutu ve mozaik: 1. Veri artırma, veri çeşitliliğini sağladı, toplamda 5749 görüntüyü yapay olarak oluşturdu ve tüm veri kümesini rastgele 70:30 eğitim: test bölmesine ayırdı. Modeli 4000 iterasyon boyunca eğittik ve en iyi ağırlıkları kaydederek test görüntüleri ve videolarıyla


YOLOv5, nesne tespiti için kullanılan bir konvolüsyonel sinir ağı olan, ağın öğrenme dinamiklerini yönlendirmede kilit rol oynayan hiperparametrelerin dikkatli bir şekilde ayarlanmasını içerir. Bu hiperparametreler, öğrenme hızı (LR), momentum ve ağırlık azalma dahil olmak üzere, eğitim süreci sırasında ağırlık güncellemelerinin büyüklüğünü ve yönünü etkileyerek modelin yakınsama ve performansı üzerinde derin bir etki yapar. Bu hiperparametreleri belirli gereksinimlere uyacak şekilde özelleştirmek için, YOLOv5 eğitim yapılandırma dosyasını değiştirmek gerekir. Genellikle YAML dosyası olarak yapılandırılan bu dosya, eğitim sürecini yapılandırmak için kritik bir araç olarak işlev görür. Örneğin, YOLOv5 Small için 'yolov5s.yaml' olarak adlandırılır.

Yapılandırma dosyasında, hiperparametreleri belirlemek ve ayarlamak için ayrılmış özel bir bölüm bulunur. Bu bölümde, LR başlangıç öğrenme hızını belirler, momentum önceki ağırlık güncellemelerinin dahil edilmesini düzenler ve ağırlık azalma zaman içinde ağırlıkların azalmasını düzenler. Bu parametreler, istenen eğitim programına uyacak şekilde değiştirilebilir.

Örneğin, yapılandırma dosyası içinde, hiperparametre bölümü Şekil 3,7 gibi ve şekil 3.8 artırılması veri kümesi görünebilir.

```
# Hiperparametreler
lr0: 0.01 # İlk öğrenme hızı
momentum: 0.937
weight_decay: 0.0005 # Ağırlık azalma
```


Şekil 3.7: YMAL Dosya Ayarları



Şekil 3.8: Artırılmış Veri Kümesi


4. BULGULAR VE TARTIŞMA

Önerilen fine-tuned YOLOv5 modelinin performansını değerlendirmek için, transfer öğrenme için önceden eğitilmiş model ağırlıklarını kullandık. Bu önceden eğitilmiş ağırlıklar, COCO büyük veri kümesi üzerinde eğitildi. Eğitim süreci, önceki bölümde açıklanan fine-tuned parametrelere dayalı olarak kuruldu. Eğitim veri kümesi, genel veri kümesinin %70'ini oluştururken, doğrulama veri kümesi veri kümesindeki resimlerin %20'sini içeriyor ve nihayet test veri kümesi, veri kümesindeki diğer %10 resmi içeriyordu.



Şekil 4.1: Önerilen Fine-Tuned Modelin Eğitim Sürecindeki Performanstaki İlerleme

Şekil 4.1, fine-tuned YOLOv5 modelinin eğitim süreci boyunca performansını göstermektedir. Bu şekildeki üst sıradaki resimler, modelin eğitim veri kümesi için performansını gösterirken, alt sıradaki resimler doğrulama veri kümesini kullanarak modelin performansını gösterir. Bu resimlerden, eğitim veri kümesinde drone nesnelerini algılama kaybının 100 epoch sonrasında 0.01'in altına düştüğü görülebilir. Ancak, doğrulama veri kümesinde drone'ları algılama kaybı, yaklaşık olarak 50. epoch civarında minimum değere ulaştı, ardından 100. iterasyona yaklaşılrken hafifçe arttı. Doğrulama kaybı 100. iterasyondan sonra artmaya devam ettiği için ve eğitilmiş modelin daha iyi genelleştirilmesini sağlamak için, eğitim sürecini 150. iterasyonda durdurduk.



Şekil 4.2: Önerilen Fine-Tuned Model Kullanılarak Eğitim Setinde Drone Nesnelerinin Algılanması İçin Hassasiyet-Hatırlama Eğrisi

Model eğitim sürecinin performansını daha ayrıntılı bir şekilde analiz etmek için, Şekil 4.2, eğitim süreci sırasında drone algılama modelinin hassasiyet ve hatırlama oranının bir haritasını gösterir. Şekilde görüleceği üzere, modelin eğitilmiş hali, eğri altındaki alanı temsil eden %98,6'luk bir mAP elde edebilmiştir. Bu değer, eğitilmiş modelin drone nesnelerini yüksek hassasiyet ve hatırlama değerleri ile doğru bir şekilde algılama yeteneğini temsil eder. Eğitilmiş modelin geliştirilmesini vurgulamak için, bu modeli değerlendirmek için test veri kümesi kullanıldı ve çeşitli kriterler, diğer rekabetçi modellerle karşılaştırmak üzere değerlendirildi ve bir sonraki bölümde sunuldu. Şekil 4.3, eğitilmiş modeli kullanarak farklı türdeki drone nesnelerinin farklı türdeki görüntülerini ve algılama sonuçlarını içeren bir dizi resmi sunar. Şekilde gösterildiği gibi, önerilen yaklaşım, farklı türde ve boyuttaki drone nesnelerinin konumlarını doğru bir şekilde algılayabilmiştir, bu da bu görevi gerçekleştirmek için önerilen yaklaşımın etkinliğini gösterir.

Şekil 4.3, eğitilmiş modeli kullanarak farklı türdeki drone nesnelerini içeren bir dizi resmi ve algılama sonuçlarını sunmaktadır. Şekilde gösterildiği gibi, önerilen yaklaşım farklı türde ve boyuttaki drone nesnelerinin konumlarını doğru bir şekilde algılayabilmiştir, bu da bu görevi gerçekleştirmek için önerilen yaklaşımın etkinliğini göstermektedir.




Şekil 4.3: Önerilen Modelin, Test Veri Kümesindeki Görüntülerle Drone Algılama İşlemi



Şekil 4.4: Diğer Yaklaşımlarla Karşılaştırma

Önerilen yaklaşımın drone tespiti görevindeki üstünlüğünü göstermek için, önerilen modelle karşılaştırma yapmak amacıyla YOLOv3 ve YOLOv4 gibi diğer yaklaşımların performansını ölçmek için bir dizi deney gerçekleştirildi. İlk olarak, YOLOv3, eğitim ve doğrulama veri kümesindeki aynı görüntüler üzerinde eğilmek üzere kullanıldı.




Şekil 4.5: Behera ve Bazil Tarafından Önerilen Yaklaşımın Eğilirken Kayıp Değerinin İlerleyişi

Kaynak: Tan, L., Xinyue, L., Xiaofeng, L., & Wang, G. (2021)


Şekil 4.5, YOLOv3'ü eğitirken kayıp ve mAP değerlerinin ilerleyişini göstermektedir. Şekilde görüldüğü gibi, eğitim süreci kayıp ve mAP metriklerinin daha iyi değerlerine ulaşmak için yaklaşık 6000 iterasyon sürdü. En düşük ortalama kayıp değeri 0.0597 idi ve 6000 iterasyondan sonra en iyi ulaşılan mAP değeri %64.6 idi. Bu değerler genel eğitim döneminin ortalamasını temsil etmektedir. Öte yandan, YOLOv4 aynı veri kümesinde eğilmek üzere kullanıldı ve değerlendirme kriterlerinin ilerleyişi Şekil 10'da gösterilmektedir. Şekilde görüldüğü gibi, YOLOv4'ün mAP için elde ettiği ilerleme, YOLOv3 tarafından elde edilen ilerlemeye göre çok daha iyiydi. YOLOv4 tarafından elde edilen en iyi mAP değeri, eğitim verisi için 89.9 idi ve genel olarak eğitim dönemi boyunca bu değer elde

edildi. Ayrıca, YOLOv4 tarafından elde edilen en iyi ortalama kayıp değeri 0.5360 idi ve bu değer, YOLOv3 tarafından elde edilen karşılık gelen değerden daha yüksekti. Ancak, bu değerlerin etkileri bu modellerin genelleme yeteneğini kontrol ettiğimizde daha belirgin hale gelebilir. Üç model olan YOLOv3, YOLOv4 ve önerilen model eğitildikten sonra, bu modellerin genelleme özelliğini kontrol etmek için kullanıldı. Bu modeller, eğitim ve test veri kümesini kullanarak değerlendirme kriterleri olan hassasiyet, geri çağırma ve mAP'yi ölçmek için kullanıldı. Şekil 4.7, üç model için elde edilen değerlendirme sonuçlarını göstermektedir. Şekilde görüldüğü gibi, YOLOv4 tarafından elde edilen sonuçlar üç değerlendirme kriteri için diğer modeller tarafından elde edilen sonuçlardan daha iyiydi. Ancak bu, modelin genelleme yeteneğini yansıtmadı. Bu nedenle, genelleme, modelin daha önce görmediği test veri kümesinde değerlendirildiğinde kontrol edilebilir.




Şekil 4.6: Tan ve Diğerleri Tarafından Önerilen Yöntemin Eğitilirken Kayıp Değerinin İlerleyişi

Kaynak: (Tan, L., Xinyue, L., Xiaofeng, L., & Wang, G. (2021)).



Şekil 4.7: Eğitilmiş Modeller Tarafından Eğitim Veri Kümesi İçin Elde Edilen Hassasiyet (Precision), Geri Çağırma (Recall) ve mAP Sonuçları

Test veri kümesi, eğitilmiş modellerin genelleme yeteneğini kontrol etmek için kullanıldığından, Şekil 4.7, değerlendirme kriterleri için elde edilen sonuçları sunar. Bu şekilde, yolov4'ün eğitim veri kümesinde en iyi sonuçları elde etmesine rağmen, test veri kümesinde iyi bir genelleme yapamadığını gözlemleyebiliriz. Bununla birlikte, önerilen model test veri kümesi için en iyi genelleme sağlayabildi ve değerlendirme metriklerinin daha yüksek değerlerini elde edebildi. Ayrıca, yolov3 tarafından elde edilen hassasiyetin test veri kümesi için yolov4 tarafından elde edilene göre daha iyi olduğunu gözlemleyebiliriz; ancak yolov3'ün geri çağırma değeri yolov4'ün çok daha düşüktü. Öte yandan, önerilen model üç değerlendirme kriteri için denge ve en iyi değerleri elde etti. Bu sonuçlar, diğer rekabetçi modellerle karşılaştırıldığında önerilen modelin üstünlüğünü vurgular.



Şekil 4.8: (Behera ve Bazil (2020) ve (Tan ve diğ, 2021) Tarafından Elde Edilen Test Veri Kümesine Dayalı Tespit Doğruluğu ile Önerilen Modelin Karşılaştırılması

Şekil 4.8’ de, üç modelin test veri kümesinde elde edilen hassasiyet değerlerini gösteren bir ısı haritasını tasvir etmektedir. Bu şekilde, yolov3 ve yolov4 ile gerçekleştirilen drone tespiti hassasiyetinin sırasıyla %92 ve %91 olduğu gözlemlenebilir. Bununla birlikte, aynı test veri kümesinde önerilen model tarafından elde edilen hassasiyet %98 idi. Bu değerler, önerilen modelin etkinliğini yansıtmakta ve drone tespiti görevindeki umut verici performansını ortaya koymaktadır.

5. SONUÇ

İHA'ları tespit etmeye ve sınıflandırmaya odaklanmıştır. Temel amacımız, İHA tespitinin doğruluğunu ve etkinliğini artırarak savunma ve güvenlik uygulamaları için güvenilir bir araç oluşturmaktır. YOLOv5 model tabanlı yaklaşımın başarısı, İHA'ları doğru bir şekilde tespit etme ve sınıflandırma yeteneğini göstererek İHA tabanlı tehditlerle başa çıkma konusunda önemli bir ilerlemeyi temsil etmektedir. Bu araştırma sürecinde, gerçek dünya İHA görüntüleri ve sentetik veriler içeren bir veri seti oluşturuldu ve özelleştirilmiş bir ESA modelini eğitmek için kullanıldı. Bu süreç, modelin farklı koşullar altında İHA'ları tanıma yeteneğini geliştirmiştir. Eğitim sürecinde çeşitli teknikler ve hiperparametreler dikkatlice incelendi. Katmanların dondurulması ve sentetik Gauss gürültüsü eklenmesi gibi faktörler göz önünde bulunduruldu ve bu, modelin performansını daha da artırdı. İHA tespiti ve sınıflandırmanın önemi, güvenlik, savunma, hava sahası yönetimi ve endüstriyel uygulamalar gibi birçok alana yayılmaktadır. Bu çalışma, bu alanlarda daha güvenli ve verimli bir geleceğe katkı sağlayabilecek değerli bilgiler sunmaktadır.

Gelecekteki çalışmalar, bu tezin sonuçlarına dayalı olarak şunları ele alabilir: Problemin Tanımlanması: İHA tespiti, çoğu insan için belirli bir tehdidi ifade eder. Bu tezin temel amacı, İHA'ları tespit etme ve sınıflandırma yeteneğini artırmaktır. İHA'ların hava sahasında çeşitli amaçlarla kullanılması, bu teknolojinin etkin bir şekilde algılanmasını ve izlenmesini zorunlu kılmaktadır. Neden Bu Tez: İHA'lar, askeri operasyonlardan endüstriyel kullanıma kadar birçok alanda yaygın olarak kullanılmaktadır. Ancak, bu İHA'ların kötü niyetli amaçlarla kullanılma potansiyeli, güvenlik ve savunma toplulukları için önemli bir endişe kaynağıdır. Bu tez, İHA'ların güvenilir bir şekilde tespit edilmesine ve sınıflandırılmasına yönelik yeni bir yaklaşım sunarak bu tehdidi ele almayı amaçlamaktadır. Bu tez, İHA tespiti ve sınıflandırmasında ESA ve YOLOv5 algoritmalarının etkinliğini göstermektedir. Bu araştırma, güvenlik, savunma ve ilgili alanlarda İHA'ların daha fazla kullanımına önemli bir katkı sunmaktadır. Bu araştırma, İHA teknolojisinin önemli bir sorununu

ele almaya ve yenilikçi bir yaklaşım sunmaya yönelik bir çabanın ürünüdür. Gelecekteki Çalışmalar: İleriki çalışmalar, bu tezin sonuçlarına dayanarak daha fazla araştırma yapabilir. Özellikle: Veri Çeşitliliği ve Büyüklüğü: İHA tespiti ve sınıflandırması için kullanılan veri setlerinin çeşitlendirilmesi ve genişletilmesi, modelin daha fazla senaryoda başarılı olmasına yardımcı olabilir. Farklı hava koşulları, farklı İHA tipleri ve görevlerini içeren daha büyük ve çeşitli veri setleri kullanarak modelin genelleme yeteneği geliştirilebilir. Çoklu İHA Takibi: İHA'ların sadece tespiti ve sınıflandırılması değil, aynı zamanda takibi de önemlidir. Gelecekteki çalışmalar, birden fazla İHA'yı aynı anda izleme yeteneğini geliştirmek için odaklanabilir. Bu, hava sahası yönetimi ve güvenlik açısından önemli olabilir. Gerçek Zamanlı Uygulamalar: İHA tespiti ve sınıflandırması, gerçek zamanlı uygulamalarda büyük bir rol oynayabilir. Gelecekteki çalışmalar, bu teknolojinin hızlı ve güvenilir gerçek zamanlı uygulamalara entegrasyonunu ele alabilir. Özerk Savunma Sistemleri: İHA tabanlı tehditlerle başa çıkmak için otomatik veya yarı-otomatik savunma sistemleri geliştirmek önemlidir. Bu tür bir savunma sistemi, İHA'ları algılayabilir ve uygun tepkileri otomatik olarak başlatabilir. Başka Sensörlerle Entegrasyon: İHA tespiti ve sınıflandırması için görsel verilerin yanı sıra diğer sensörlerle entegrasyon da araştırılabilir. Örneğin, radar veya ses algılama sistemleri ile birlikte kullanarak daha kapsamlı bir İHA izleme sistemi oluşturmak mümkün olabilir. Bu tez, bu alanlardaki bilimsel ve teknolojik gelişmelere katkı sağlamayı amaçlamaktadır ve ailemize ve arkadaşlarımıza tamamlama sürecindeki kararlı destekleri için adanmıştır.

KAYNAKLAR

- Al Tameemi, M. I., & Oleiwi, B. K.** (2023). *Visual-infrared image monitoring system for moving object detection, classification and tracking using deep learning technique*. AIP Conference Proceedings, 2651(060011). <https://doi.org/10.1063/5.0107079>
- Aledhari, M., Razzak, R., Parizi, R. M., & Srivastava, G.** (2021, April). *Sensor fusion for drone detection*. In *2021 IEEE 93rd Vehicular Technology Conference (VTC2021-Spring)* (pp. 1-7). IEEE.
- Amini, A.** (Massachusetts Institute of Technology). (2022). **MIT 6.S191 Introduction to Deep Learning**. Available at: (Accessed: 2022).
- Anwar, M. Z., Kaleem, Z., and Jamalipour, A.** (2019). Machine learning inspired sound-based amateur drone detection for public safety applications. *IEEE Transactions on Vehicular Technology*, vol. 68, no. 3, pp. 2526–2534.
- Ajakwe, S. O., Ihekoronye, V. U., Akter, R., Kim, D. S., & Lee, J. M.** (2022, January). *Adaptive drone identification and neutralization scheme for real-time military tactical operations*. In *2022 International Conference on Information Networking (ICOIN)* (pp. 380-384). IEEE.
- Aydin B, Singha S.** **Drone Detection Using YOLOv5.** *Eng.* 2023; 4(1):416-433.
- Bamne, B., Shrivastava, N., Parashar, L., & Singh, U.** (2020). Transfer learning-based Object Detection by using Convolutional Neural Networks. In *2020 International Conference on Electronics and Sustainable Communication Systems* (ICESC). <https://doi.org/10.1109/ICESC48915.2020.9156060>
- Bengio, Y.** (2012, June). Deep learning of representations for unsupervised and transfer learning. In *Proceedings of ICML workshop on unsupervised and transfer learning* (pp. 17-36). JMLR Workshop and Conference Proceedings.
- Behera, D., & Bazil, A.** (2020). Drone Detection and Classification using Deep Learning. *International Conference on Intelligent Computing and Control Systems (ICICCS)*, 1012-1016.
- Bhattacharyya, J.** (2020). Step By Step Guide To Object Detection Using Roboflow. *Analytics India Magazine*. <https://analyticsindiamag.com/step-by-step-guide-to-object-detection-using-roboflow/>
- Bishop, C. M., & Nasrabadi, N. M.** (2006). *Pattern recognition and machine learning* (Vol. 4, No. 4, p. 738). New York: Springer.
- Breckon, T. P., and Shum, H. P. H.** (2021). Unmanned aerial vehicle visual detection and tracking using deep neural networks: A performance benchmark. In *Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV) Workshops*, pp. 1223–1232.

- Bochkovskiy, A., Wang, C. ve Liao, H. M.,** 2020. "Yolov4: Optimal speed and accuracy of object detection," CoRR, vol. abs/2004.10934. Erişim Linki: <https://arxiv.org/abs/2004.10934>
- Chen, X., Lv, J., Fang, Y. ve Du, S.,** 2022. "Online detection of surface defects based on improved yolov3." *Sensors (Basel)*, 22(3). doi: 10.3390/s22030817.
- Dadrass Javan, F., Samadzadegan, F., Gholamshahi, M., & Ashatari Mahini, F.** (2022). A Modified YOLOv4 Deep Learning Network for Vision-Based UAV Recognition. *Drones*, 6(7), 160.
- Dalal, N., & Triggs, B.** (2005, June). Histograms of oriented gradients for human detection. In *2005 IEEE computer society conference on computer vision and pattern recognition (CVPR'05)* (Vol. 1, pp. 886-893). IEEE.
- Deng, J., Pan, Y., Yao, T., Zhou, W., Li, H., & Mei, T.** (2020). Single shot video object detector. *IEEE Transactions on Multimedia*, 23, 846-858.
- Dickson, B.** (2021). *An Introduction To Object Detection With Deep Learning*. TechTalks. Erişim tarihi: 08.05.2022. URL: <https://bdtechtalks.com/2021/06/21/object-detection-deep-learning/>.
- X. Du, Y. Cai, S. Wang, L. Zhang.** (2016). "Overview of deep learning." 2016 31st Youth Academic Annual Conference of Chinese Association of Automation (YAC). IEEE, 2016.
- Ergunsah, Ş., & Kosunalp, S.** (2022). İnsansız Hava Araçları Tabanlı Çevresel Uygulamalara Genel Bir Bakış. *Uluslararası Yönetim Bilişim Sistemleri ve Bilgisayar Bilimleri Dergisi / International Journal of Management Information Systems and Computer Science*, 6(1), 43-53.
- Friedman, D. S.** (2015). *The Importance of Vision*. Retrieved from https://www.hopkinsmedicine.org/wilmer/services/general_opthalmology/importance_of_
- Fukushima, K.** (1988). Neocognitron: A hierarchical neural network capable of visual pattern recognition. *Neural networks*, 1(2), 119-130.
- Garcia, A. J., Lee, J. M., & Kim, D. S.** (2020, October). Anti-drone system: A visual-based drone detection using neural networks. In *2020 International Conference on Information and Communication Technology Convergence (ICTC)* (pp. 559-561). IEEE.
- Girshick, R., Donahue, J., Darrell, T. ve Malik, J.,** 2014. 'Rich feature hierarchies for accurate object detection and semantic segmentation'. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*.
- Girshick, R.** (2015). *Fast r-cnn*. In *Proceedings of the IEEE international conference on computer vision* (pp. 1440-1448).
- Göktürk Çetinkaya, S. & Koç, M.** (2023). Türkiye'nin İnsansız Hava Araçları Serüveni. *Anadolu Strateji Dergisi*, 5 (1), 1-27. Retrieved from <https://dergipark.org.tr/tr/pub/anasamasd/issue/78661/1321177>

- Ganti, S. R., & Kim, Y.** (2016). Implementation of detection and tracking mechanism for small uas. In *2016 International Conference on Unmanned Aircraft Systems (ICUAS)*, pp. 1254-1260. doi: 10.1109/ICUAS.2016.7502513
- Girshick, R., Donahue, J., Darrell, T., & Malik, J.** (2014). Rich feature hierarchies for accurate object detection and semantic segmentation. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 580-587).
- Girshick, R.** (2015) 'Fast r-cnn', *Proceedings of the IEEE International Conference on Computer Vision (ICCV)*.
- Goodfellow, I., Bengio, Y., & Courville, A.** (2016). Deep learning. MIT Press.
- Hayat, S., Kun, S., Tengtao, Z., Yu, Y., Tu, T., & Du, Y.** (2018, June). A deep learning framework using convolutional neural network for multi-class object recognition. In *2018 IEEE 3rd International Conference on Image, Vision and Computing (ICIVC)* (pp. 194-198). IEEE.
- Hornik, K.** (1991). Approximation capabilities of multilayer feedforward networks. *Neural networks*, 4(2), 251-257.
- Hubel, D. H., & Wiesel, T. N.** (1968). Receptive fields and functional architecture of monkey striate cortex. *The Journal of Physiology*, 195(1), 215–243.
- Jiang, M., Sogabe, R., Shimasaki, K., Hu, S., Senoo, T., & Ishii, I.** (2021). 500-fps omnidirectional visual tracking using three-axis active vision system. *IEEE Transactions on Instrumentation and Measurement*, 70, 1-11.
- Jiang, R., Zhou, Y., & Peng, Y.,** 2021. *A review on intrusion drone target detection based on deep learning*. In: 2021 IEEE 4th Advanced Information Management, Communicates, Electronic and Automation Control Conference (IMCEC), Vol. 4, pp.1032-1039. DOI: 10.1109/IMCEC51613.2021.9482092.
- J., G. et al.,** 2021. "ultralytics/yolov5: v6.0 - YOLOv5n 'Nano' models, Roboflow integration, TensorFlow export, OpenCV DNN support," Erişim Linki:
- Jocher, G.; Stoken, A.; Chaurasia, A.; Borovec, J.; NanoCode012; TaoXie; Kwon, Y.;...ve diğeleri;** (2021) ultralytics/yolov5: v6.0 - YOLOv5n 'Nano' models, Roboflow integration, TensorFlow export, OpenCV DNN support. Zenodo. Available at: (Accessed: September 28, 2023).
- Jocher, G.** (2020). *YOLOv5 by Ultralytics* (Version 7.0) [Computer software].
- Jurn, Y. N., Mahmood, S. A., & Aldhaibani, J. A.** (2021, August). Anti-drone system based different technologies: Architecture, threats and challenges. In *2021 11th IEEE International Conference on Control System, Computing and Engineering (ICCSCE)* (pp. 114-119). IEEE.
- Kang, K., Li, H., Yan, J., Zeng, X., Yang, B., Xiao, T., & Ouyang, W.** (2017). T-cnn: Tubelets with convolutional neural networks for object detection from videos. *IEEE Transactions on Circuits and Systems for Video Technology*, 28(10), 2896-2907.

- Krizhevsky, A., Sutskever, I., & Hinton, G. E.** (2012). Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems*, 25.
- Lee, Y., Kim, B., & Park, S.** (2021). The Role of Drone Detection in Sustainable Industrial Growth. *International Journal of Sustainable Technology*, 17(3), 213-231.
- LeCun, Y., Bengio, Y., & Hinton, G.** (2015). Deep learning. *Nature*, 521(7553), 436-444.
- LeCun, Y., Boser, B., Denker, J. S., Henderson, D., Howard, R. E., Hubbard, W., & Jackel, L. D.** (1989). Backpropagation applied to handwritten zip code recognition. *Neural computation*, 1(4), 541-551.
- Li, X.** (2022). Improved Drone Detection Using Sensor Fusion and Deep Learning. *IEEE Transactions on Vehicular Technology*, 71(6), 4974-4986.
- Liu, W., Anguelov, D., Erhan, D., Szegedy, C., Reed, S., Fu, C. Y., & Berg, A. C.** (2016). Ssd: Single shot multibox detector. In *Computer Vision–ECCV 2016: 14th European Conference, Amsterdam, The Netherlands, October 11–14, 2016, Proceedings, Part I* (pp. 21-37). Springer International Publishing.
- Tan, L., Xinyue, L., Xiaofeng, L., & Wang, G.** (2021). YOLOv4 Drone: UAV image target detection based on an improved YOLOv4 algorithm. *Computers & Electrical Engineering*, 93, 107261.
- Long, L. N., & Gupta, A.** (2008). Scalable massively parallel artificial neural networks. *Journal of Aerospace Computing, Information, and Communication*, 5(1), 3-15.
- Lowe, D. G.** (1999, September). Object recognition from local scale-invariant features. In *Proceedings of the seventh IEEE international conference on computer vision* (Vol. 2, pp. 1150-1157). IEEE.
- Liu, W., Anguelov, D., Erhan, D., Szegedy, C., Reed, S., Fu, C.-Y. ve Berg, A.C.** (2016) 'SSD: Single Shot Multibox Detector', in Leibe, B., Matas, J., Sebe, N. ve Welling, M. (eds.) *Computer Vision - ECCV 2016*. Cham: Springer International Publishing, pp. 21-37.
- L. Tan, L. Xinyue, L. Xiaofeng, G.Wang,** (2021)."YOLOv4 Drone: UAV image target detection based on an improved YOLOv4 algorithm," *Computers & Electrical Engineering*, vol. 93, pp. 107261
- Magdy William, M., Salah Zaki, P., Soliman, B. K., Alexsan, K. G., Mansour, M., El-Moursy, M., & Khalil, K.** (2019). *Traffic Signs Detection and Recognition System using Deep Learning*. In 2019 Ninth International Conference on Intelligent Computing and Information Systems (ICICIS). <https://doi.org/10.1109/ICICIS46948.2019.9014763>
- Marr, D., & Hildreth, E.** (1980). Theory of edge detection. *Proceedings of the Royal Society of London. Series B. Biological Sciences*, 207(1167), 187-217.
- Mendis, G. J., Randeny, T., Wei, J., & Madanayake, A.** (2016). Deep learning based doppler radar for micro uas detection and classification. In

- Mohana, R., & Aradhya, H. R.** (2019). Object Detection and Tracking using Deep Learning and Artificial Intelligence for Video Surveillance. *International Journal of Advanced Computer Science and Applications*, 10(12).
- Mueller, M., Smith, N., & Ghanem, B.** (2016). A benchmark and simulator for uav tracking. In *Computer Vision–ECCV 2016: 14th European Conference, Amsterdam, The Netherlands, October 11–14, 2016, Proceedings, Part I* (pp. 445-461). Springer International Publishing.
- Oinar, C.** (2021). *Object Detection Explained: R-CNN. Towards Data Science*. Erişim tarihi: 08.05.2022. URL: <https://towardsdatascience.com/object-detection-explained-r-cnn-a6c813937a76>.
- Potter, R.** (2021). *What Is Data Annotation and What Are Its Advantages Analytics*. Medium.
- Redmon, J. ve Farhadi, A.** (2018) 'Yolov3: An incremental improvement', CoRR, vol. abs/1804.02767. Erişim: <http://arxiv.org/abs/1804.02767>
- Ren, S., He, K., Girshick, R., & Sun, J.** (2015). Faster r-cnn: Towards real-time object detection with region proposal networks. *Advances in Neural Information Processing Systems* (pp. 91–99).
- Rojas, R.** (1996). *Neural Networks-A Systematic Introduction*. Springer-Verlag, Berlin, New-York.
- Rui, C., Youwei, G., Huafei, Z. ve Hongyu, J.** (2021) 'A comprehensive approach for UAV small object detection with simulation-based transfer learning and adaptive fusion', *Wind Energy*, 20, pp. 1983–1995.
- Rumelhart, D. E., Hinton, G. E., & Williams, R. J.** (1988). *Learning representations by back-propagating errors*. Cognitive Modeling ch 8.
- Russell, S. J., & Norvig, P.** (2016). *Artificial Intelligence: A Modern Approach*. Malaysia: Pearson Education Limited.
- Samadzadegan, F., Dadrass Javan, F., Ashtari Mahini, F., & Gholamshahi, M.** (2022). Detection and recognition of drones based on a deep convolutional neural network using visible imagery. *Aerospace*, 9(1), 31.
- Saqib, M., Khan, S. D., Sharma, N., & Blumenstein, M.** (2019). Crowd counting in low-resolution crowded scenes using region-based deep convolutional neural networks. *IEEE Access*, 7, 35317-35329.
- Sebe, N.** (2005). *Machine learning in computer vision* (Vol. 29). Springer Science & Business Media.
- Sharma, U., Goel, T., & Singh, J.** (2023). Real-Time Image Processing Using Deep Learning With OpenCV And Python. *Journal of Pharmaceutical Negative Results*, 1905-1908.
- Shoufan, A., Al-Angari, H. M., Sheikh, M. F. A., & Damiani, E.** (2018). Drone pilot identification by classifying radio-control signals. *IEEE Transactions on Information Forensics and Security*, 13(10), 2439-2447. doi: 10.1109/TIFS.2018.2819126

- Simonyan, K., & Zisserman, A.** (2014). *Very deep convolutional networks for large-scale image recognition*. arXiv preprint arXiv:1409.1556.
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., ve Salakhutdinov, R.** (2014). Dropout: A simple way to prevent neural networks from overfitting. *Journal of Machine Learning Research*, 15, 1929–1958.
- Smith, R., Watson, F., & Jones, S.** (2022). Military and Civil Implications of Drone Detection. *Journal of Defense and Security*, 8(2), 134-150.
- Steinkraus, D., Buck, I., & Simard, P. Y.** (2005, August). Using GPUs for machine learning algorithms. In *Eighth International Conference on Document Analysis and Recognition (ICDAR'05)* (pp. 1115-1120). IEEE.
- Stenroos, O.** (2023). *Object detection from images using convolutional neural networks*. Aalto University, School of Science, Master's Programme in Computer, Communication and Information Sciences.
- Szeliski, R.** (2022). *Computer vision: algorithms and applications*. Springer Nature.
- Tan, L., Lv, X., Lian, X., & Wang, G.** (2021). YOLOv4_Drone: UAV image target detection based on an improved YOLOv4 algorithm. *Computers & Electrical Engineering*, 93, 107261.
- Uğuz, Sinan & Şikaroğlu, Gulhan & Yağız, Abdullah.** (2022). Disease detection and physical disorders classification for citrus fruit images using convolutional neural network. *Journal of Food Measurement and Characterization*. 10.1007/s11694-022-01795-3
- Uijlings, J. R., Van De Sande, K. E., Gevers, T., & Smeulders, A. W.** (2013). Selective search for object recognition. *International journal of computer vision*, 104, 154-171.
- Unlu, E., Zenou, E., and Rivière, N.** (2018). *Generic fourier descriptors for autonomous uav detection*. In ICPRAM.
- Unlu, E., Zenou, E., Rivière, N., and Dupouy, P.-E.** (2019). Deep learning-based strategies for the detection and tracking of drones using several cameras. *IPSN Transactions on Computer Vision and Applications*, vol. 11, no. 1.
- Ünel, F., Özkalayci, B.O., & Çiğla, C.,** 2019. The power of tiling for small object detection. In: 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW), pp.582-591. DOI: 10.1109/CVPRW.2019.00084.
- Walther, D., Itti, L., Riesenhuber, M., Poggio, T., & Koch, C.** (2002). Attentional selection for object recognition—a gentle way. In *Biologically Motivated Computer Vision: Second International Workshop, BMCV 2002 Tübingen, Germany, November 22–24, 2002 Proceedings* (pp. 472-479). Springer Berlin Heidelberg.
- Wisniewski, M., Rana, Z. A., & Petrunin, I.** (2023). Drone Model Classification Using Convolutional Neural Network Trained on Synthetic Data.
- Yang, B., Yan, J., Lei, Z., & Li, S. Z.** (2016). Craft objects from images. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 6043-6051).

- Yang, J., Xu, Y., Wei, H., Zhang, Z., & Gao, R.** (2019). Real-time tiny part defect detection system in manufacturing using deep learning. *IEEE Access*, 7, 89278-89291. doi: 10.1109/ACCESS.2019.2921845
- Yoshihashi, R., Kawakami, R., Iida, M. ve Naemura, T.** (2017) 'Bird detection and species classification with time-lapse images around a wind farm: Dataset construction and evaluation', *Wind Energy*, 20, pp. 1983–1995.
- Zhang, H., Chen, X., & Wang, Y.** (2025). Real-time Drone Detection and Tracking using CNN and Reinforcement Learning. *Neurocomputing*, 386, 68-78.
- Zou, S., Li, C., Sun, H., Xu, P., Zhang, J., Ma, P., & Grzegorzec, M.** (2022). TOD-CNN: An effective convolutional neural network for tiny object detection in sperm videos. *Computers in Biology and Medicine*, 146, 105543.
- Isaac-Medina, B. K. S., Poyser, M., Organisciak, D., Willcocks, C. G. Chen, X., Lv, J., Fang, Y. ve Du, S.,** 2022. "Online detection of surface defects based on improved yolov3." *Sensors (Basel)*, 22(3). doi: 10.3390/s22030817.
- Coupey, G.** (2017). DJI Inspire 2 with Zenmuse X5S 3D Model. *Sketchfab*. Available at: <https://sketchfab.com/3d-models/dji-inspire-2-with-zenmuse-x5s-3979efe28b3a4221bdd462638582d0a6> (Accessed: September 28, 2023).

ÖZGEÇMİŞ

ÖĞRENİM DURUMU:

- Lisans : 2010, ALNAHRAIN Üniversitesi, Mühendislik Fakültesi, Elektronik ve Haberleşme Mühendisliği
- Yüksek Lisans : 2023, İstanbul Gedik Üniversitesi, Lisansüstü Eğitim Enstitüsü, Elektrik ve Elektronik Mühendisliği Anabilim Dalı, Elektrik ve Elektronik Mühendisliği Tezli Yüksek Lisans Programı

MESLEKİ DENEYİM:

- 2016- 2023 NEWTR HABER AJANSI A.Ş. Canlı Yayın ve Stüdyo Mühendisliği, Kameraman 2020 Vakıf Katılım Bankası AŞ. Sistem Analistliği
- 2015 NEWTR HABER AJANSI A.Ş. Canlı Yayın ve Stüdyo Mühendisliği, Kameraman
- 2013 ASIA Kanal Canlı Yayın ve Uydu Haberleşme
- 2010 ALBAGHDADİA KANALI Canlı Yayın ve Stüdyo Mühendisliği