



**DERİN ÖĞRENME AĞLARI İLE HAVA KOMUTA KONTROL  
SİSTEMLERİNDE OPTİK TANIMA VE SINIFLANDIRMA**

**Betül YILMAZ**

**YÜKSEK LİSANS TEZİ  
ELEKTRİK- ELEKTRONİK MÜHENDİSLİĞİ ANA BİLİM DALI**

**GAZİ ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ**

**OCAK 2025**

## ETİK BEYAN

Gazi Üniversitesi Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,
  - Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
  - Tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
  - Kullanılan verilerde herhangi bir değişiklik yapmadığımı,
  - Bu tezde sunduğum çalışmanın özgün olduğunu,
- bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

Betül YILMAZ

17/01/2025

# DERİN ÖĞRENME AĞLARI İLE HAVA KOMUTA KONTROL SİSTEMLERİNDE OPTİK TANIMA VE SINIFLANDIRMA

(Yüksek Lisans Tezi)

Betül YILMAZ

GAZİ ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ

Ocak 2025

## ÖZET

İnsansız hava araçlarının çeşitli alanlarda hızla artan kullanımı, güvenlik açısından hem fırsatlar hem de riskler doğurmaktadır ve erken tespit ihtiyaçlarını ön plana çıkarmaktadır. Bu çalışmada derin öğrenme teknikleri kullanılarak, insansız hava araçlarının erken tespitiyle kullanımının tehlikeli etkilerinin azaltılması amaçlanmıştır. Çalışmanın amacı, güvenlik sorunları için önceden eğitilmiş YOLOv8 gibi derin öğrenme yaklaşımlarının insansız hava aracı tespiti ile değerlendirilmesidir. Bu çalışma bir insansız hava aracı yarışması için toplanan ve GitHub'da herkese açık olarak paylaşılan bir veri seti kullanılarak, nesne tespiti görevlerinde optimal performans elde etmek amacıyla YOLOv8 modeline odaklanmaktadır. Bu görüntüler Roboflow kullanılarak etiketlenmiş ve model Google Colab üzerinde eğitilmiştir. Gerçek zamanlı tespit uygulamaları için uygunluğu ve karmaşık görsel verileri işleyebilme yeteneği nedeniyle gelişmiş mimarisine bilinen YOLOv8 tercih edilmiştir. Modelin performansını en üst düzeye çıkarmak amacıyla hiper parametre ayarlamaları ve veri artırma teknikleri uygulanmıştır. Öğrenme hızı, küme boyutu ve optimizasyon ayarları gibi temel hiper parametreler, en iyi performans sağlamak için yinelenmeli deneyler yoluyla optimize edilmiştir. Hiper parametre ayarlamalarının yanı sıra, modelin dayanıklılığını ve genelleme yeteneğini artırmak için çeşitli veri artırma stratejileri kullanılmıştır. Farklı koşulları ve varyasyonları simüle etmek amacıyla döndürme, ölçekleme, çevirme ve renk ayarlamaları gibi teknikler veri setine uygulanmıştır. Bu çalışmada belirli veri setine uygulanan artırma teknikleri arasında, döndürmenin en yüksek performansı sağladığı tespit edilmiştir. Bulanıklaştırma ve kırpma yöntemlerinin ise bu performansı yakından takip ettiği gözlemlenmiştir. Optimize edilmiş hiper parametreler ve stratejik veri artırma kombinasyonu, YOLOv8'in açık kaynak veri seti üzerinde yüksek tespit doğruluğu ve güvenilir performans elde etmesini sağlamıştır. Bu yöntem, YOLOv8'in gerçek dünya senaryolarında etkinliğini kanıtlarken, modelin yeteneklerini artırmada hiper parametre ayarlarının ve veri artırmanın önemini de vurgulamaktadır. Model performansını artırmak için, döndürme ve bulanıklaştırma gibi veri artırma teknikleri uygulanmıştır. Bu adımların ardından 0.946'lık önemli bir kesinlik değeri, 0.9605'lik dikkate değer bir duyarlılık değeri ve 0.978'lik bir kesinlik-duyarlılık değeri elde edilmiştir. Bu sonuçlarla modelin Mask CNN, CNN ve YOLOv5 gibi birçok popüler modelin üzerinde bir performans gösterdiği tespit edilmiştir.

Bilim Kodu : 93008

Anahtar Kelimeler : YOLOv8; İHA algılama, derin öğrenme

Sayfa Adedi : 49

Danışman : Doç. Dr. Uğurhan KUTBAY

# OPTICAL RECOGNITION AND CLASSIFICATION IN AIR COMMAND AND CONTROL SYSTEMS WITH DEEP LEARNING NETWORKS

(M. Sc. Thesis)

Betül YILMAZ

GAZİ UNIVERSITY

GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES

January 2025

## ABSTRACT

The extensive utilization of drones has led to numerous scenarios that encompass both advantageous and perilous outcomes. By using deep learning techniques, this study aimed to reduce the dangerous effects of drone use through early detection of drones. The purpose of this study is the evaluation of deep learning approaches such as pre-trained YOLOv8 drone detection for security issues. This study focuses on the YOLOv8 model to achieve optimal performance in object detection tasks using a publicly available dataset collected by Mehdi Özel for a UAV competition that is sourced from GitHub. These images are labeled using Roboflow, and the model is trained on Google Colab. YOLOv8, known for its advanced architecture, was selected due to its suitability for real-time detection applications and its ability to process complex visual data. Hyperparameter tuning and data augmentation techniques were applied to maximize the performance of the model. Basic hyperparameters such as learning rate, batch size, and optimization settings were optimized through iterative experiments to provide the best performance. In addition to hyperparameter tuning, various data augmentation strategies were used to increase the robustness and generalization ability of the model. Techniques such as rotation, scaling, flipping, and color adjustments were applied to the dataset to simulate different conditions and variations. Among the augmentation techniques applied to the specific dataset in this study, rotation was found to deliver the highest performance. Blurring and cropping methods were observed to follow closely behind. The combination of optimized hyperparameters and strategic data augmentation allowed YOLOv8 to achieve high detection accuracy and reliable performance on the publicly available dataset. This method demonstrates the effectiveness of YOLOv8 in real-world scenarios, while also highlighting the importance of hyperparameter tuning and data augmentation in increasing model capabilities. To enhance model performance, dataset augmentation techniques including rotation and blurring are implemented. Following these steps, a significant precision value of 0.946, a notable recall value of 0.9605, and a considerable precision–recall curve value of 0.978 are achieved, surpassing many popular models such as Mask CNN, CNN, and YOLOv5.

Science Code : 93008

Key Words : YOLOv8; drone detection; deep learning

Page Number : 49

Supervisor : Assoc. Prof. Dr. Ugurhan KUTBAY

## TEŐEKKÜR

Bu alıőmanın hazırlanmasında katkılarından dolayı danıőmanım Do. Dr. Uėurhan KUTBAY'a teőekkür ederim. Ayrıca, bu alıőmada iő birliėi iinde olduėum tm arkadaőlarıma ve ASELSAN Akademi'de birlikte alıőma fırsatı bulduėum Abdullah EHLİZ'e teőekkür etmek isterim.

Bu srete bana verdikleri destek, gsterdikleri anlayıő ve srekli motivasyonlarıyla yanımda olan aileme, zellikle sevgili eőim Oėuzhan YILMAZ'a sonsuz őkranlarımı sunarım. Hayatımın her aőamasında olduėu gibi bu nemli akademik srete de yanımda olan ailem, baőarıma byk katkı saėlamıőtır.

Zor anlarımda yanımda olan, bilgi ve deneyimlerini cmerte paylaőan dostlarımdın desteėi, bu tezin ortaya ıkmasında nemli rol oynamıőtır.

## İÇİNDEKİLER

	<b>Sayfa</b>
ÖZET .....	iv
ABSTRACT.....	v
TEŞEKKÜR.....	vi
İÇİNDEKİLER .....	vii
ÇİZELGELERİN LİSTESİ.....	ix
ŞEKİLLERİN LİSTESİ .....	x
RESİMLERİN LİSTESİ .....	xi
SİMGELER VE KISALTMALAR.....	xii
1. GİRİŞ.....	1
2. LİTERATÜR TARAMASI .....	5
2.1. Yapay Zekâ .....	7
2.1.1. Derin öğrenme.....	8
2.1.2. Derin öğrenme mimarileri.....	10
2.2. Görüntü İşleme.....	16
2.2.1. YOLO'nun tarihçesi.....	17
2.2.2. YOLOv8 teknolojik iyileştirmeler .....	19
2.3. İnsansız Hava Araçları .....	20
3. MATERYALLER VE YÖNTEMLER.....	23
3.1. Deneysel Ortam ve Veri Seti.....	23
3.2. Değerlendirme Kriterleri .....	25
4. SONUÇLARIN TARTIŞILMASI .....	27
4.1. Hiper Parametre Ayarları .....	27
4.2. Veri Seti Artırımı .....	29
4.3. Model Performansı.....	31

	<b>Sayfa</b>
4.4. Diğer Modellerle Karşılaştırma.....	37
4.4.1. Mimari ve performans karşılaştırması .....	38
4.4.2. Mask R-CNN ve YOLOv8 kıyaslaması.....	39
4.4.3. Geleneksel algoritmalar: CNN, SVM, KNN ve YOLOv8 kıyaslaması....	39
4.4.4. Transfer öğrenme: YOLOv5 ve YOLOv8'in eğitim farklılıkları .....	39
4.4.5. Artırılmış veri kullanımı ile performans artışı .....	40
4.4.6. Önerilen modelin avantajları.....	40
5. GELECEK ÇALIŞMALAR .....	41
6. SONUÇLAR VE ÖNERİLER .....	43
KAYNAKLAR .....	45
ÖZGEÇMİŞ .....	49

## ÇİZELGELERİN LİSTESİ

<b>Çizelge</b>	<b>Sayfa</b>
Çizelge 3.1. Karışıklık Matrisi.....	25
Çizelge 4.1. Karşılaştırma Tablosu.....	38



## ŞEKİLLERİN LİSTESİ

<b>Şekil</b>	<b>Sayfa</b>
Şekil 2.1. Yapay Zekâ Uygulama Alanları .....	8
Şekil 2.2. Bilinen İlk Derin Ağ Mimarisi .....	9
Şekil 2.3. LeNet Mimarisi .....	11
Şekil 2.4. AlexNet Mimarisi .....	12
Şekil 2.5. Basit Tekrarlayan Sinir Ağları .....	13
Şekil 2.6. YOLO Ailesi Zaman Çizelgesi .....	17
Şekil 3.1. (a) Veri Setindeki İnsansız Hava Araçlarının Konum Dağılımı. (b) Veri Setindeki İnsansız Hava Araçlarının Boyut Dağılımı. ....	24
Şekil 4.1. (a) 50 Epok'daki Kesinlik-Duyarlılık Eğrisi. (b) 100 Epok'daki Kesinlik-Duyarlılık Eğrisi. (c) 150 Epok'daki Kesinlik-Duyarlılık Eğrisi. (d) 200 Epok'daki Kesinlik-Duyarlılık Eğrisi .....	27
Şekil 4.2. (a) 640 Görüntü Boyutundaki Belirli Veri Seti İçin Kesinlik-Duyarlılık Eğrisi. (b) 800 Görüntü Boyutundaki Belirli Veri Seti İçin Kesinlik- Duyarlılık Eğrisi. ....	28
Şekil 4.3. (a) Flip Artırmalı Kesinlik-Duyarlılık Eğrisi. (b) Dönme Artırmalı Kesinlik-Duyarlılık Eğrisi. (c) Kırpma Artırmalı Kesinlik-Duyarlılık Eğrisi. (d) Bulanıklaştırma Artırmalı Kesinlik-Duyarlılık Eğrisi. (e) Gri Tonlama Artırmalı Kesinlik-Duyarlılık Eğrisi.....	30
Şekil 4.4. Belirli Bir Veri Seti İçin Yolov8 Model Sonuçları.....	32
Şekil 4.5. Belirli Veri Seti İçin Kesinlik-Duyarlılık Eğrisi.....	32
Şekil 4.6. (a) Belirli Bir Veri Seti İçin F1–Güven Eğrisi. (b) Belirli Bir Veri Seti İçin Duyarlılık–Güven Eğrisi. (c) Belirli Bir Veri Seti İçin Kesinlik– Güven Eğrisi. ....	33
Şekil 4.7. Yüksek Boyutlu Veri Seti İçin Yolov8 Model Sonuçları .....	35
Şekil 4.8. Artırılmış Veri Seti İçin Kesinlik-Duyarlılık Eğrisi .....	35
Şekil 4.9. (a) Artırılmış Belirli Veri Seti İçin F1-Güven Eğrisi (b) Artırılmış Belirli Veri Seti İçin Duyarlılık-Güven Eğrisi (c) Artırılmış Belirli Veri Seti İçin Kesinlik-Güven Eğrisi .....	36

## RESİMLERİN LİSTESİ

<b>Resim</b>	<b>Sayfa</b>
Resim 3.1. Veri Setinden İnsansız Hava Aracı Görüntü Örnekleri .....	24
Resim 4.1. Belirli Veri Seti İçin Test Sonuçları .....	34
Resim 4.2. Artırılmış Veri Seti Sonucu .....	37



## SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış simgeler ve kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

<b>Kısaltmalar</b>	<b>Açıklamalar</b>
<b>BiFPN</b>	Bidirectional Feature Pyramid Network
<b>CIoU</b>	Complete Intersection over Union
<b>CNN</b>	Convolutional Neural Networks
<b>CSP</b>	Cross Stage Partial
<b>DBN</b>	Deep Belief Networks
<b>DOTA</b>	Dataset for Object deTecton in Aerial Images
<b>ELAN</b>	Efficient Layer Aggregation Network
<b>EMA</b>	Efficient Multiscale Attention
<b>FPN</b>	Feature Pyramid Network
<b>IoU</b>	Intersection over Union
<b>İHA</b>	İnsansız Hava Aracı
<b>JPL</b>	Jet Propulsion Library
<b>LSTM</b>	Long Short-Term Memory
<b>NLP</b>	Natural Language Processing
<b>PAN</b>	Path Aggregation Network
<b>RBM</b>	Restricted Boltzman Machines
<b>RNN</b>	Recurrent Neural Networks
<b>YOLO</b>	You Only Look Once

## 1. GİRİŞ

Son yıllarda insansız hava araçları birçok endüstride büyük potansiyeli olan önemli bir teknolojik gelişme olarak öne çıkmıştır [1]. Bu cihazların geniş kullanım alanı, paket teslimatından tarım uygulamalarına ve güvenlik gözetimine kadar çeşitli alanlarda yenilikçi çözümler sunmalarına olanak sağlamıştır [2]. Ancak insansız hava araçlarının artan kullanımı, bu cihazların yasadışı veya zararlı amaçlarla kötüye kullanılmasına ilişkin kamu güvenliği açısından yeni zorlukları da beraberinde getirmiştir. Özellikle kameralı insansız hava araçlarının kullanımı, mahremiyet ve terörizm gibi çeşitli alanlarda endişelere yol açmıştır. [3–5]. Bu nedenle güvenlik otoriteleri insansız hava araçlarını etkili bir şekilde tespit edip tanıyabilen sistemler oluşturmak için araştırmaları hızlandırmıştır. Bu durum geleneksel tespit yöntemlerinin sınırlamalarına yönelik yeni bir araştırma alanının doğmasına ve daha etkili çözümler arayışına yol açmıştır [6]. Sonuç olarak derin öğrenme tekniklerinin kullanımı, bu alandaki çalışmaların önemli bir parçası haline gelmiştir. Derin öğrenme yapay zekanın bir alt kümesi olup, karmaşık veri kalıplarının otomatik olarak tanınmasını sağlar ve daha güvenli çözümler bulmak amacıyla kapsamlı veri analizleri aracılığıyla daha kesin ve uyarlanabilir tespit sistemleri sunar.

Günümüzde insansız hava aracı tespit yöntemleri, ses sinyali tabanlı, radar tabanlı, radyo frekansı tabanlı ve görüntü-video tabanlı yaklaşımlar olarak sıralanabilir [7,8]. Radarlar uzun menziller için etkili, sis ve yağmur gibi kötü hava koşullarına dayanıklı ve gece görüşü gibi avantajlara sahip olsalar da insansız hava araçlarından yayılan elektromanyetik dalgaların tespit edilebilmesi için yeterli bulunmamaktadır [9]. Radarların genellikle yalnızca hedef hakkında konum ve hız gibi bilgiler vermesi, bu sınırlı veri için bile yüksek maliyetler ortaya çıkarır [10], bu da görüntü tabanlı tespit yöntemlerini daha kullanışlı hale getirir. Radyo frekansı tabanlı yöntemler, geniş kapsama alanına sahip olmaları, çevresel faktörlerden çok az etkilenmeleri ve hedef konumunu doğru şekilde tespit edebilmeleri gibi birçok avantaja sahiptir. Ancak insansız hava araçlarının düşük radyo frekanslarına sahip olmaları, farklı insansız hava aracı türleri için farklı frekans değerlerinin kullanılması ve çok sayıda sinyal kaynağı olduğunda radyo frekansı tabanlı yöntemin çok maliyetli hale gelmesi, bu yöntemi insansız hava araçlarının tespitinde dezavantajlı kılmaktadır [11]. Ses tabanlı yöntemler kısa menzilde hedefleri tespit etmede etkili olabilir ancak gürültü hassasiyeti nedeniyle uzun menzildeki performansları oldukça düşüktür. Ayrıca farklı insansız hava aracı modelleri ve motor tipleri farklı frekanslarda ses üretebilir, bu da ses tabanlı bir modelle

hedef tespitini oldukça karmaşık ve maliyetli hale getirir [12]. Görüntü tabanlı yöntemler, nesnelerin yüksek çözünürlük ve ayrıntılarını sağlayabildikleri için derin öğrenme kullanımına oldukça uygundur ve yüksek performans elde edilebilir. Kötü hava koşulları görüntü tabanlı yöntemlerin performansını düşürse de bu etki artırma yöntemleri ile azaltılabilir. Ancak, bu yüksek performans elde etmek için kullanılan tüm bu yöntemler, genellikle yüksek hesaplama gücü ve veri işleme kapasitesi gerektirir.

Bu çalışma ile derin öğrenmede performansı artıran ve birçok avantaj sunan görüntü odaklı teknikler incelenmektedir. Çeşitli katkılarından biri, görüntü tabanlı yaklaşımların, görüntüler, nesneler, desenler ve renkler yardımıyla zengin bilgiler toplanmasına olanak tanınmasıdır. Ayrıca, yüksek boyutluluk sayesinde, derin ağların karmaşıklığını yönetirler. Bu yaklaşım, savunma sanayii gibi çeşitli alanlarda geniş bir uygulama yelpazesine yol açabilir. Ayrıca, görüntü tabanlı yaklaşım veri artırma yeteneği sunar ve gürültülü ortamlarda dayanıklılık gösterir [13].

Bu çalışmada görüntü tabanlı bir yöntem olarak YOLOv8 modeli kullanılmıştır. YOLOv8 modeli, nesne tespit performansını artırmak amacıyla yeni bir omurga ve baş yapısı tanıtmaktadır. Bu güncellenmiş yapı, modelin daha verimli çalışmasına olanak sağlar. YOLOv8'in mimarisi, farklı boyut ve şekillerdeki nesneleri tespit etme yeteneğini artıran dikkat mekanizmaları ve derin ayırık evrişim gibi modern teknikleri içermektedir. Ayrıca, model performansını önemli ölçüde artırmak için otomatik karmaşıklık ayarı ve hiper parametre optimizasyonu için daha gelişmiş algoritmalar kullanır. Bu yenilikler sayesinde, YOLOv8, önceki sürümler olan YOLOv5 ve YOLOv4'e kıyasla daha yüksek kesinlik ve daha düşük hata oranlarına ulaşır [14]. YOLOv8 modeli genel performans açısından üstün olsa da olumsuz hava koşulları gibi zorlayıcı durumlarda bazı sınırlamalara sahip olabilir. Bulanıklaştırma gibi kullanılan artırma yöntemleri, olumsuz hava koşullarını simüle etmek ve modelin bu duruma tepkisini gözlemlemek açısından çalışmaya katkı sağlamıştır.

Bu çalışmadan elde edilen çıktılar hem askeri hem de sivil alanlarda çeşitli tehditlere karşı güvenliği artırmak ve korunma sağlamak amacıyla uygulanabilir. Bu çalışmanın sonuçları, şu amaçlar için de kullanılabilir: İlk olarak, tehdit tespiti ve tanımlama. Kameralar aracılığıyla elde edilen görüntüler kullanılarak olası tehditler (insansız hava araçları) tespit edilebilir ve tanımlanabilir. Ayrıca, uyarı sistemleri için de faydalı olabilir. Bir tehdit tespit edildiğinde, personeli veya kullanıcıları uyarmak için sesli, görsel veya diğer uyarılar

sağlanabilir. Bu, tehlikenin varlığını zamanında bildirmeyi ve gerekli önlemlerin alınmasını sağlar. Sivil veya askeri tesislerin, alanların veya araçların korunması için kullanılabilir. Potansiyel tehditlerin erken tespiti ve uyarısı, saldırıların önlenmesine veya en azından etkilerinin azaltılmasına yardımcı olur. Son olarak, askeri operasyonlarda taktiksel kullanım için değerlendirilebilir. Düşmanın yaklaşmasını tespit etmek ve askeri birlikleri uyararak savunma hazırlıklarını başlatmak için kullanılabilir. Ayrıca, modelin taşınabilir cihazlarda çalışabilme yeteneği, gerçek zamanlı tespit gerektiren askeri operasyonlar veya acil müdahaleler sırasında kullanımını kolaylaştırır.

Bu çalışma, şu şekilde devam etmektedir: Bölüm 2 mevcut araştırmaları özetlemekte, Bölüm 3 deneysel ayrıntılar dahil olmak üzere kurulum, değerlendirme, parametre ayarı, sonuçlar ve karşılaştırmalar hakkında bilgi vermekte, Bölüm 4 ise bu çalışmanın bulgularının bir özetini sunmaktadır. Bölüm 5 gelecekteki çalışmalar için kısa bir öneri sunmaktadır.



## 2. LİTERATÜR TARAMASI

Yıllar boyunca insansız hava aracı tespiti için birçok yöntem denenmiş, önerilmiş ve ilgili çalışmalar yürütülmüştür. Radarlar ve alternatif yöntemler kullanarak insansız hava aracı tespiti üzerine birçok farklı çalışma yapılmıştır [15] ve insansız hava araçlarından yayılan elektromanyetik dalgaların radarlar tarafından tespit edilmesinin yeterli olmadığı değerlendirilmiştir [9]. İlgili yöntemler üzerine yapılan çalışmalar sonucunda ses tabanlı ve radyo frekansı tabanlı yöntemlerin fiyat/performans oranının düşük olduğu görülmüştür [11]. İnsansız hava aracı tespiti için en öne çıkan yöntem görüntü işleme olmuştur.

Coluccia ve meslektaşları [15] insansız hava aracı tespitinde radar sensör ağlarını kullanarak bu alandaki ana zorluklara çözüm üretmeye odaklanmıştır. Literatürü inceleyerek insansız hava araçlarının varlığını tespit etme, hedef doğrulama ve sınıflandırma gibi zorluklara yönelik en umut verici yaklaşımları değerlendirmişlerdir. Çalışmalarının sonucunda insansız hava aracı tespiti için en verimli yöntemin görüntü işleme olduğunu belirlemişlerdir.

Görüntü işleme insansız hava aracı tespiti için hayati öneme sahiptir. B. Srinivasa ve arkadaşları [16] insansız hava araçlarını tespit etmek için balık gözü kameraları kullanmışlardır. 180 derece veya daha geniş görüş açısına sahip olan bu kameralar, geniş bir alanı tek bir karede yakalamaktadırlar. Çalışmalarında insansız hava araçlarının tespitini konvolüsyonel sinir ağı (CNN), destek vektör makinesi (SVM) ve en yakın komşu sınıflandırma yöntemleriyle gerçekleştirmişlerdir. Bu yöntemler arasında konvolüsyonel sinir ağı sınıflandırıcısını daha tatmin edici bir doğrulukla öne çıkarmışlardır [16].

Wisniewski ve meslektaşları, oluşturdukları insansız hava aracı sınıflandırma modelini, sentetik olarak ürettikleri bir veri kümesi ile eğitmişlerdir. Modeli eğitirken sentetik gürültü, veri kümesi boyutu ve simülasyon parametrelerinin model üzerindeki etkilerini detaylı bir şekilde incelemeyi amaçlamışlardır. Ayrıca yeni insansız hava aracı türlerini sınıflandırmak için sentetik veri modeline eklemeler yaparak sınıflandırma maliyetlerini azaltmayı hedeflemişlerdir. Bu modeli açık kaynaklı gerçek dünya verileriyle test ederek, literatüre yeni bir katkı sağlamışlardır [17].

Demir ve arkadaşları, 20 MP çözünürlüğe sahip 16 kamera kullanarak insansız hava aracı tespiti için görsel tabanlı bir sistemle uzun menzilde insansız hava aracı tespit etmeyi

amaçlamışlardır. Gömülü sistemlerin işlem gücünü yazılımın esnekliğiyle birleştirerek, insansız hava aracı tespiti ve takibi için kapsamlı bir platform sağlamışlardır [18].

Literatürde yer alan bir diğer çalışma yüksek doğrulukta gerçek zamanlı insansız hava aracı tespiti üzerine odaklanmıştır. Bu çalışmada hareketli nesnelerin (insansız hava aracı, kuş veya arka plan) tespiti ve tespit edilen nesnenin sınıflandırılması şeklinde iki aşamalı bir yöntem uygulanmıştır. Bu yaklaşımla insansız hava aracı tespitinde yüksek işlem hızı ve yüksek doğruluk elde edilmesi hedeflenmiştir. Hareketli nesnelerin tespiti için arka plan çıkarma yapılırken, sınıflandırma için konvolüsyonel sinir ağı (CNN) kullanılmıştır [19].

Bir diğer çalışmada derin öğrenme tabanlı nesne tespit algoritması YOLOv5, yasaklı bölgeler veya özel alanların yasa dışı insansız hava aracı müdahalesinden korunması için kullanılmıştır [20]. Gözetim videoları bağlamında insansız hava aracı tespitinde en zorlu sorunlardan biri, insansız hava araçlarının farklı arka planlarda belirgin benzerliklerini ayırt etmektir. Bu nedenle modelin performansını artırmayı hedeflemiştir. Veri setinde yeterli örnek bulunmadığından, modeli önceden eğitmek için transfer öğrenmesi kullanılmıştır. Böylece kayıp değeri, insansız hava aracı konum tespiti, kesinlik ve duyarlılık açısından çok yüksek sonuçlar elde edilmiştir.

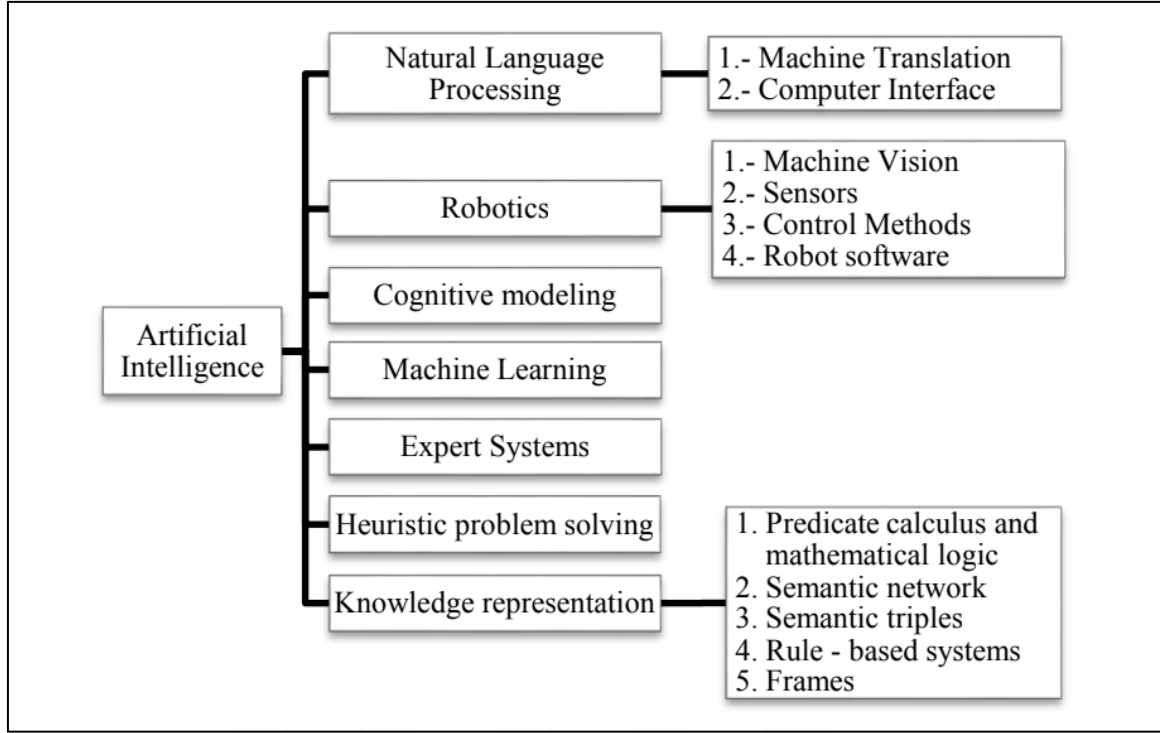
Wang ve arkadaşları [21], çalışmalarında üç ana soruna odaklanmış ve bu şekilde DOTA V1.0 veri seti için orijinal YOLOv8 algoritmasının performansını artırmayı amaçlamışlardır. İlk olarak, görüntülerdeki küçük hedefler hakkında daha fazla bilgi çıkarmak için, görüntülerdeki farklı boyutlardaki hedefleri tespit etmek amacıyla temel ağ katmanında ek bir tespit gerçekleştirilmiştir. Görüntülerdeki farklı boyutlardaki hedefleri tespit etmek için, EMA modülüne dayalı C2f-E yapısını kullanmanın faydalı olacağı vurgulanmıştır. Son olarak, modelin dayanıklılığını artırmak için orijinal algoritmadaki CIOU kayıp fonksiyonu yerine Wise-IoU kullanılmıştır. Geliştirilmiş algoritmanın, DOTA V1.0 verileri için %1,3 daha iyi performans sergilediği ve uzaktan algılama görüntülerinde hedef tespit doğruluğunu etkili bir şekilde artırabileceği kanıtlanmıştır. Bu çalışma, uzaktan algılama görüntülerinin arka plan karmaşıklığına odaklanarak, çok sayıda küçük hedefi ve çeşitli hedef ölçeklerini hedef alan YOLOv8 tabanlı bir uzaktan algılama görüntü hedef tespit algoritması sunmaktadır.

Başka bir çalışmada YOLOv8 Srinivasa ve meslektaşları tarafından gerçek zamanlı insansız hava aracı tespiti için kullanılmıştır [16]. Gerçek zamanlı tespit, zamanında kimlik doğrulama ve yanıt hizmeti için zorunlu bir ön koşuldur. Bu hedefe ulaşmak için YOLOv8 modeli TensorFlow.JS ile entegre edilmiştir, böylece sunucu tarafı işlemeye gerek kalmadan sistem kurulumu ve web tabanlı uygulamalara entegrasyon sağlanmıştır. Önerilen gerçek zamanlı insansız hava aracı tespit sistemi, olağanüstü doğruluk oranlarına sahip olup, güvenilirlik açısından sağlam bir kriter ortaya koymuştur. Bu araştırma insansız hava araçları, uçaklar ve kuşlar hakkında görüntüler içeren MS COCO veri setini kullanmıştır. Model duyarlılık, kesinlik, F1 skoru ve ortalama kesinlik değerleri açısından son derece başarılı sonuçlar vermiştir.

## 2.1. Yapay Zekâ

Son yıllarda yapay zekâ çeşitli alanlarda hızla ilerleyerek önemli bir inceleme ve geliştirme alanı haline gelmiştir. Bilgisayar bilimleri, matematik, sanat ve mimarlık gibi pek çok disiplinde etkin bir şekilde kullanılmaktadır. Yapay zekâ temelde bilgisayar sistemlerine insana özgü düşünme, öğrenme ve karar alma yeteneklerini kazandırmaya yönelik bir teknoloji olarak tanımlanabilmektedir [22].

Yapay zekâ alanında önemli bir dönüm noktası 1950'lerde Alan Turing'in bir bilgisayarın insan zihnine benzer şekilde nasıl işlev gösterebileceğine dair tatmin edici bir açıklama yapmasıyla gerçekleşmiştir [23]. Günümüzde yapay zekâ çeşitli alt alanlarda önemli ilerlemeler göstermiştir. Robotikte ileri karar verme kabiliyetine sahip robotlar tasarlamayı, doğal dil işleme ile yazma deneyimi geliştirmeyi ve ulaştırmada otonom araçların sorunsuz bir şekilde hareket etmelerini mümkün kılmayı amaçlamaktadır. Böylece birçok alanda insan zekâsına benzer şekilde hareket etmeyi amaçlayan çözümler sunmaktadır.



Şekil 2.1. Yapay Zekâ Uygulama Alanları [22]

### 2.1.1. Derin öğrenme

Öğrenme net bir tanıma sahip olmayan ve bir dizi farklı süreci kapsayan karmaşık bir kavramdır. Makineler açısından bakıldığında bir makine, yapısı, programı veya verisi üzerinde yapılan değişiklikler sayesinde gelecekteki performansını iyileştirebiliyorsa, bu durum "öğrenme" olarak kabul edilir [24].

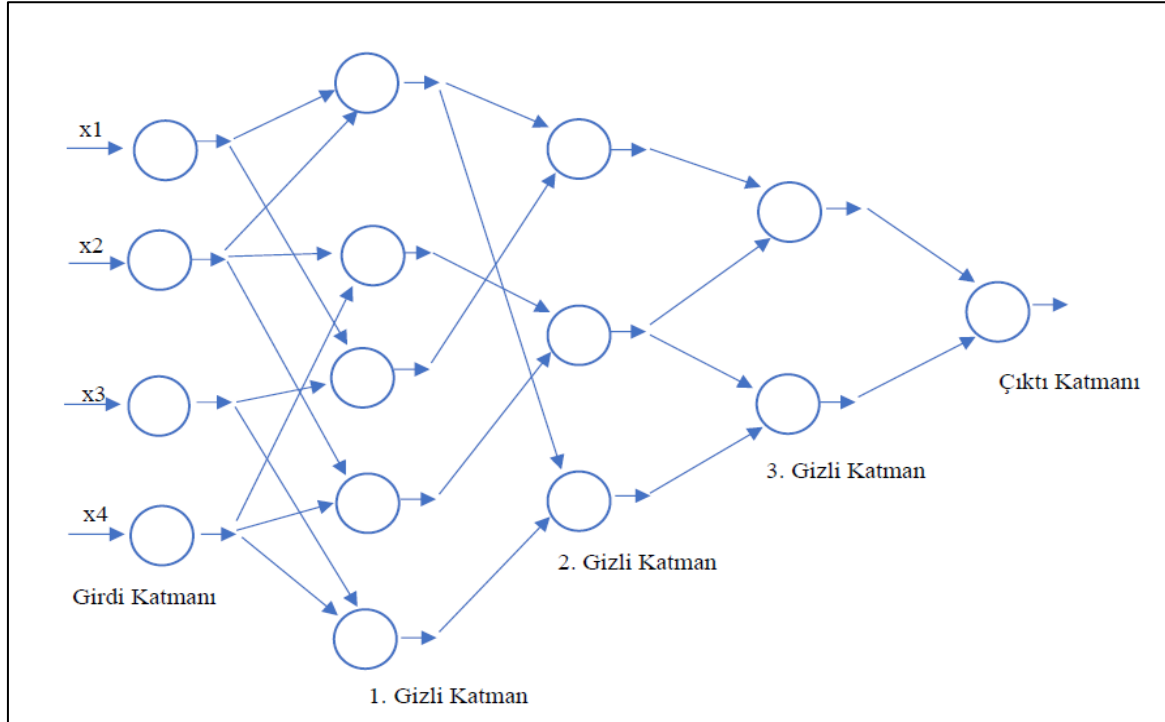
Makine öğrenimi toplumun pek çok alanında dönüşüm yaratmaktadır ve web aramaları, sosyal medya içerik filtreleme, e-ticaret öneri sistemleri, kameralar ve akıllı telefonlar gibi tüketici ürünlerinde yaygın olarak kullanılmaktadır. Makine öğrenimi sistemleri; nesne tanıma, konuşmayı metne çevirme, haber ve ürünleri kullanıcıların ilgi alanlarına göre sıralama ve alakalı arama sonuçlarını sunma gibi uygulamalarda önemli bir rol üstlenmektedir. Bu uygulamalar giderek derin öğrenme olarak adlandırılan bir teknik sınıfı tarafından desteklenmektedir [25].

Derin öğrenmede büyük veri kullanımı esastır. Bu alandaki önemli bir avantaj, derin öğrenme algoritmalarının, denetimli ya da denetimsiz şekilde verilerin temsilde kullanılan özellik vektörleri ve kenar kümelerini öğrenme yeteneğine sahip olmasıdır [26].

1958 yılında Frank Rosenblatt yapay sinir ağlarını kullanarak öğretimli bir desen tanıma algoritması yaratmıştır. Ancak, Rosenblatt'ın geliştirdiği iki katmanlı sinir ağı, karmaşık verilerle başa çıkmada yetersiz kalmıştır. Derin öğrenme, çok katmanlı sinir ağları kullanarak bu sorunu aşmış ve verilerden daha etkili şekilde bilgi çıkarmayı mümkün kılmaktadır. Derin öğrenmede, bilginin her katmanda ayrı ayrı eğitilmesi önemli bir avantaj olarak öne çıkmaktadır [26].

Makine öğrenimi, 2006'dan günümüze kadar daha derin ve hiyerarşik bir öğrenme biçimi olarak evrilmiştir. Günümüzde derin öğrenme teknolojisi, devletler, şirketler ve akademik dünya tarafından yoğun şekilde kullanılmaktadır. Derin öğrenme, büyük veri setlerinden insan müdahalesi olmadan öğrenme kapasitesine sahip olup, yapay zekâ alanındaki bilgisayar algoritmalarının insan beyninin deneyimlerinden faydalandığını gösterir. Derin öğrenme mimarisi, her yeni görevde, girilen verileri kullanarak sonuçları sürekli olarak geliştirir [27].

Ivakhnenko ve Lapa çok katmanlı algılayıcılar için derin öğrenme mimarileri tasarlamıştır. Katmanlar arasında özel yöntemler seçilerek uçtan uca eğitim gerçekleştirilmiş ve bu süreçte en küçük kareler yöntemi kullanılmıştır [28].



Şekil 2.2. Bilinen İlk Derin Ağ Mimarisi [29]

İlk bilinen derin ağ mimarisi, kendi kendini düzenleyen cognitron modelinin bir uzantısı olan neocognitron'dur ve bu model, denetimsiz öğrenme özelliğine sahiptir. Neocognitron, çok katmanlı bir yapıya sahiptir ve sınıflandırma işlemi sırasında "öğretici"ye ihtiyaç duymaz; yalnızca ağın giriş katmanına bir uyarıcı modelin eklenmesi yeterlidir [30].

1993 yılında, Jurgen Schmidhuber yaklaşık 1000 katmandan oluşan bir devirli sinir ağı kullanarak derin öğrenme alanında önemli bir yenilik yapmıştır. 1997'de uzun-kısa dönem hafıza (LSTM) modeli tanıtılmıştır. 1998'de ise geri yayılım ve gradyan tabanlı öğrenme modeli birleştirilmiştir. 2009-2011 yılları arasında derin öğrenme daha ileri bir düzeye taşınmış ve bu dönemde görüntü tanıma ve konvolüsyonel sinir ağları kullanılmaya başlanmıştır.

### **2.1.2. Derin öğrenme mimarileri**

Derin öğrenme, yapay sinir ağlarının çok katmanlı bir yapıda eğitildiği ve daha karmaşık temsil ve öğrenme süreçlerini gerçekleştirebildiği bir alan olarak son yıllarda büyük bir gelişim göstermiştir. Derin öğrenme mimarileri, çok katmanlı ağlar kullanarak verilerden anlamlı özellikler çıkarabilir ve bu sayede çeşitli uygulamalarda başarıya ulaşabilirler. Bu mimariler, görsel tanıma, dil işleme, ses tanıma ve daha pek çok alanda yaygın olarak kullanılmaktadır.

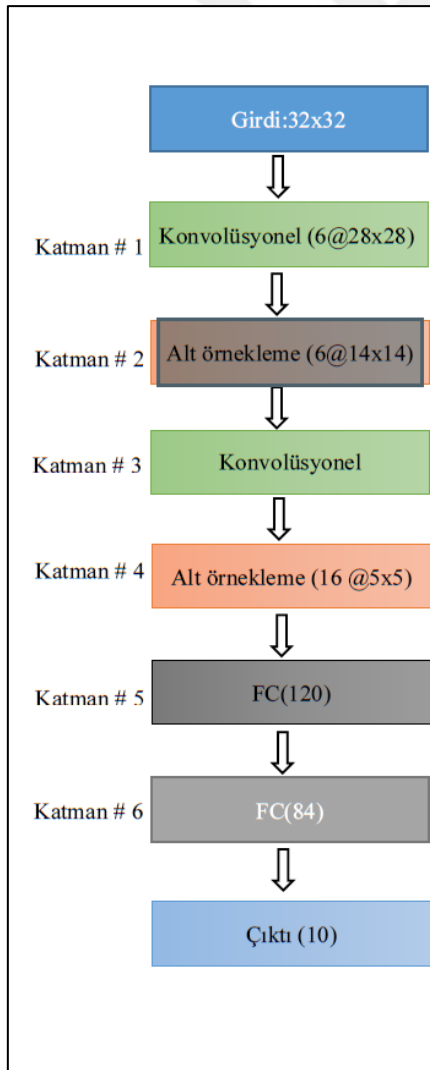
#### Evrişimsel sinir ağları (Convolutional neural networks- CNN)

Evrişimsel sinir ağları özellikle görüntü işleme alanında önemli bir yere sahiptir. Evrişimsel Sinir Ağları görüntülerdeki uzaysal hiyerarşiyi öğrenebilen, yerel özellikleri çıkaran ve katmanlar arasında paylaşılmış ağırlıklarla modelleme yapan ağlardır. Bu ağlar görüntü tanıma, nesne tespiti, segmentasyon gibi alanlarda yaygın olarak kullanılır [31].

Evrişimsel Sinir Ağları farklı işlevleri yerine getiren 3 önemli katmandan oluşur. Evrişim katmanı yerel özellikleri çıkarır ve bu özellikleri daha anlamlı temsillere dönüştürür. Bu katman görüntü gibi verilerde önemli detayları yakalayıp, daha derinlemesine analiz yapabilme yeteneği kazandırır. Ardından havuzlama katmanı devreye girer ve çıkarılan özellik haritalarının boyutlarını küçültür. Bu işlem modelin hesaplama yükünü hafifletirken, aynı zamanda genelleme yeteneğini artırır, yani aşırı uyum riskini azaltır. Son olarak tam

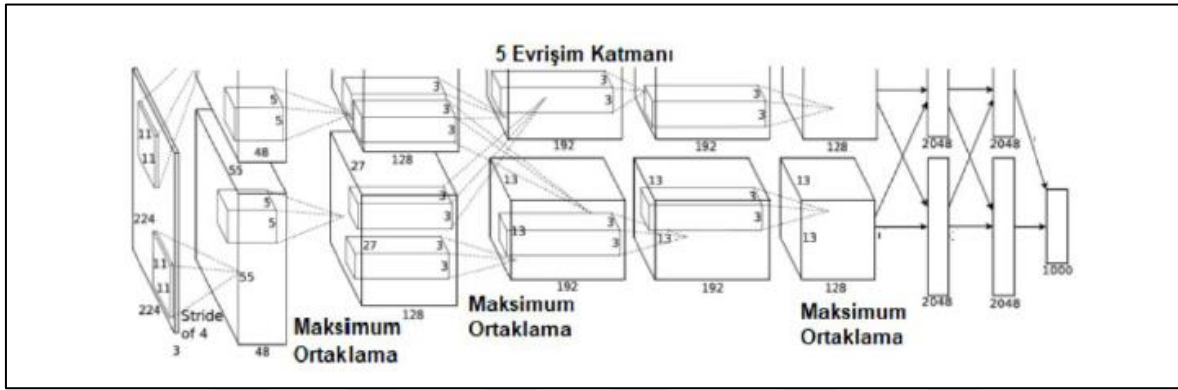
bağlantılı katman özelliklerin öğrenildiği yerden alarak, sınıflandırma veya regresyon gibi görevlerde kullanılmak üzere sonuçları işler ve modelin nihai tahminini üretir. Bu yapı CNN'lerin görüntü tanıma, nesne tespiti gibi görevlerde yüksek performans göstermesini sağlar [32].

Le Cun ve arkadaşları, çok katmanlı bir yapıya sahip olan ve gradyan tabanlı öğrenme tekniğiyle eğitilen CNN mimarisini, el yazısı tanıma görevinde başarıyla kullanmışlardır [31]. Bu süreçte geri yayılım algoritmasını kullanarak ağı eğitmişler ve modelin öğrenmesini sağlamışlardır. Bu yaklaşım ilk kez LeNet mimarisi ile somut bir şekilde uygulanmış ve CNN'lerin görüntü tanıma gibi görevlerde ne kadar etkili olabileceğini göstermiştir [31]. LeNet, o dönemde el yazısı rakamları tanımada büyük başarı elde ederek, derin öğrenme tekniklerinin potansiyelini ortaya koyan önemli bir kilometre taşı olmuştur.



Şekil 2.3. LeNet Mimarisi [35].

Krizhevesk ve ekibi milyonlarca görsel üzerinden binlerce nesne sınıflandırmak için büyük öğrenme kapasitesine ihtiyaç duyulduğunu ve nesne tanıma işleminin yüksek karmaşıklığını göz önünde bulundurarak, evrişimli sinir ağı olan AlexNet modelini kullanmışlardır [32]. AlexNet'in en büyük avantajı modelin kapasitesinin, derinliğinin ve genişliğinin ayarlanabilir olması, ayrıca görseller hakkında yapılan güçlü ve genellikle doğru varsayımlar sayesinde daha verimli çalışmasıdır. Bu özellikler, CNN'lerin, benzer boyutlardaki katmanlara sahip geleneksel ileri beslemeli sinir ağlarına kıyasla çok daha az bağlantı ve parametre içerdiği için daha kolay eğitilebilmesini sağlar.

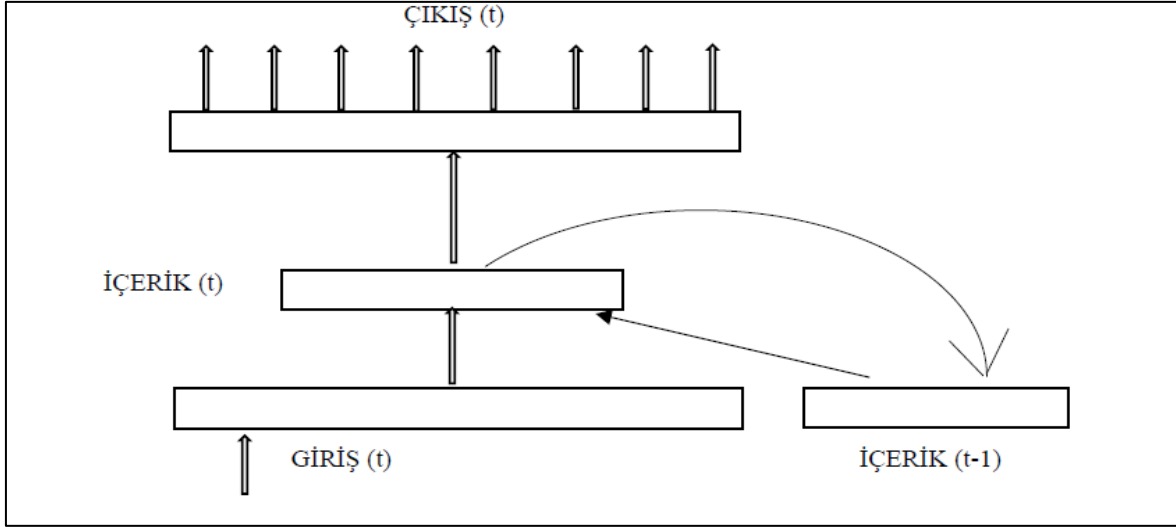


Şekil 2.4. AlexNet Mimarisini [32]

### Tekrarlayan sinir ağları (Recurrent neural networks - RNN)

Tekrarlayan sinir ağları ardışık verilerle çalışabilen modellerdir. Tekrarlayan Sinir Ağları önceki zaman dilimlerinden gelen bilgileri hatırlayarak sıralı verilerdeki bağımlılıkları öğrenir. Bu özellik dil modelleme, ses tanıma ve zaman serisi tahminleri gibi uygulamalarda faydalıdır[33].

RNN gizli katmandan alınan çıktıyı tekrar gizli katmana geri besleyerek art arda gelen bilgileri işleyebilen bir derin öğrenme modelidir [26]. RNN temelde sıralı verilerden faydalanır. Görüntü gibi verilerde giriş ve çıkışların sıralı olmasının önemi yokken doğal dil işleme (NLP) gibi alanlarda sıralamanın büyük bir rolü vardır. Örneğin, bir cümledeki kelimelerin sırası, anlamın doğru bir şekilde anlaşılabilmesi için kritik önem taşır ve RNN, kelimelerin sırasına göre tahmin yapabilme yeteneği gösterir [28].



Şekil 2.5. Basit Tekrarlayan Sinir Ağları [28]

RNN'ler bilgi elde etmede yetersiz kaldığında, bu sorunu çözmek için birden fazla algoritmanın birlikte kullanılmasıyla başarılı sonuçlar elde edebilir [30]. Bir cümledeki kelime dizilimlerini hesaplamak, sınırsız etkileşimleri modellemek ve bağımlılık ağaçlarını oluşturmak gibi karmaşık işlemler için çift yönlü RNN gibi yöntemlerden faydalanılabilir. Bu yaklaşım daha doğru ve etkili analizler yapılmasını sağlar [34].

#### Uzun kısa süreli bellek ağları (Long short-term memory- LSTM)

LSTM RNN'lerin uzun vadeli bağımlılıkları öğrenme konusundaki zorluklarını aşmak için geliştirilmiş bir modeldir. LSTM hücre durumu ve kapı mekanizmaları (giriş, çıkış ve unutma kapıları) kullanarak, daha uzun süreli bilgiyi hafızasında tutabilir. Bu nedenle LSTM, özellikle dil modelleme, metin oluşturma ve ses tanıma gibi uygulamalarda oldukça etkilidir [35].

Hochreiter ve arkadaşları tarafından geliştirilen LSTM, önceki RNN öğrenme algoritmalarının çözemediği birçok görevi çözmek amacıyla tasarlanmıştır. LSTM uygun bir gradyan tabanlı öğrenme algoritmasıyla birlikte çalışarak, hata geri yayılım (backpropagation) sorunlarının üstesinden gelmek için geliştirilmiş yeni bir RNN modelidir.

LTSM mimarisinde 4 katman bulunmaktadır, bunlar giriş, unutma, çıkış ve hücredir. LTSM mimarisinde bulunan ve kapı olarak ifade edilen unsurlar sayesinde mimarinin anahtarı konumundaki hücreler bilgi tutabilmekte ya da bilgiyi silebilmektedir. Mimaride yer alan

diğer katmanlar yani giriş, çıkış ve unutmaya katmanları hücre durumunda söz konusu ağı hafızasını meydana getirmektedir [36].

En yaygın LSTM mimarisi olan vanilya LSTM ve bu mimarinin 8 farklı modeli, üç temel problem üzerinde incelenmiştir: akustik modelleme, el yazısı tanıma ve polifonik müzik modellemesi [41]. LSTM özellikle müzik besteleme alanında etkili bir şekilde kullanılmaktadır. Bu alanda, sürekli hata akışını sağlayarak gradyan kaybolma sorunlarını ortadan kaldırır ve verideki uzun vadeli bağımlılıkları tespit eder. Böylece, ritmik zamanlama ve sayma gibi görevler LSTM sayesinde başarıyla çözülebilmektedir.

Vanilya LSTM'den türetilen her bir varyant yalnızca tek bir farklılık ile diğerlerinden ayrılmaktadır. Bu farklılıkların her biri LSTM mimarisinin performansını etkileyen unsurların iyileştirilmesini ve analiz edilmesini sağlamaktadır. Mimarideki tüm kapılar, tekrarlanan girdileri tüm kapılardan alacak şekilde tasarlanmıştır [37].

#### Kısıtlı boltzmann makineleri (Restricted boltzmann machines)

Kısıtlı Boltzmann Makinesi görünür birimler katmanından ve gizli birimler katmanından oluşur; gizli katman ise görünür-görünür ya da gizli-gizli bağlantılara sahip değildir. Gizli katman bir kez öğrenildikten sonra, gerçek birimler tarafından aktive edilen gizli birimlerin aktivite vektörleri, başka bir Kısıtlı Boltzmann Makinesi için giriş verisi olarak kullanılabilir. Bu işlem gereken kadar gizli katman öğrenene kadar tekrarlanabilir. Birden fazla gizli katman öğrenildikten sonra, tüm ağ, çok katmanlı bir üretken model olarak kabul edilir ve her ek gizli katman, modelin eğitim verilerini üretme olasılığı üzerinde bir alt sınır oluşturur [38].

Her seferinde bir gizli katmanı öğrenmek, birçok gizli katmana ve milyonlarca ağırlığa sahip derin sinir ağlarını eğitmenin önemli bir yöntemidir. Bu öğrenme süreci gözetimsiz olmasına rağmen, üst düzey özellikler genellikle ham veri vektörlerine kıyasla sınıflandırma işlemlerinde çok daha faydalı olmaktadır. Derin ağlar, geri yayılım algoritmasından yararlanarak kategorize etme veya boyut küçültme gibi işlemler için daha etkili bir şekilde optimize edilebilmektedir [38].

### Derin inanç ağı (Deep belief networks)

Derin İnanç Ağı, temel yapı taşı olarak Kısıtlı Boltzmann Makinesi (RBM) adını verdiğimiz olasılıksal bir modeli kullanır. Kısıtlı Boltzmann Makinesi, her seferinde yalnızca bir özellik katmanını keşfetmeye yönelik tasarlanmıştır. Derin İnanç Ağı eğitilirken, her bir Kısıtlı Boltzmann Makinesi, elde ettiği özellik aktivasyonlarını, bir sonraki Kısıtlı Boltzmann Makinesinin eğitiminde veri olarak kullanır. Bu işlem, RBM'lerin tekrarlı olarak uygulanmasıyla gerçekleştirilir.

Kısıtlı Boltzmann Makinesi, tek başına sınırlı bir temsil gücüne sahiptir. Ancak, bir dizi katmandan oluşan Derin İnanç Ağı modelinde kullanıldığında gerçek potansiyelini gösterir. Derin İnanç Ağındaki her katman, ikili ya da sürekli değerli birimlerden oluşur. İki ardışık katman, tamamen birbirine bağlıdır, fakat aynı katmandaki birimler arasında bağlantı bulunmaz [39].

Hinton ve arkadaşları derin öğrenmeyi Derin İnanç Ağları sayesinde her seferinde bir katmanı öğrenmenin mümkün olduğu bir süreç olarak tanımlamışlardır. Bu yöntemin temel prensibi, alt katmanlar öğrenilirken daha üst katmanların var olmadığını varsaymaktır. Her bir katman öğrenildikten sonra, ağırlıklar bir üst katmandaki ağırlıklardan bağımsız hale gelir. Ancak üst katmanlardaki ağırlıklar değiştiğinde, alt katmanlar için başlangıçta tamamlayıcı olan öncelikler uyumsuz hale gelebilir.

Derin İnanç Ağı giriş ve çıkış katmanlarına sahip, olasılıksal bir ileri besleme tahmin aracı olarak tanımlanabilir. Derin İnanç Ağı'nın temel yapı taşı olan Kısıtlı Boltzmann Makinesi, sinir ağındaki ağırlıkların başlangıç değerlerini belirlemek için katman denetimsiz bir öğrenme yöntemini kullanır. Bu yöntem, her katmanın bir önceki katmandaki özellikleri öğrenip bir sonrakine aktarması prensibine dayanır.

Her bir katman Kısıtlı Boltzmann Makinesi ile önceden eğitilir ve derin bir yapıya sahip bu ağ, birbirine bağlı iki farklı katmandan oluşur: birinde görünür düğümler (nöronlar), diğerinde ise gizli düğümler (nöronlar) yer alır. Her katmandaki düğümler yalnızca diğer katmanlardaki birimlerle bağlantılıdır; aynı katman içerisindeki birimler arasında doğrudan bir bağlantı bulunmaz. Bu bağlantılar simetrik ve çift yönlüdür, yani bilgiyi her iki yönde de taşıyabilir [39].

## 2.2. Görüntü İşleme

Görüntü işleme bilgisayar bilimlerinde dijital görüntülerin belirli algoritmalarla işlenmesi sürecini ifade eder. Dijital görüntü işleme, bilgisayarla görmenin temel unsurlarından biridir. Bilgisayarla görme çeşitli disiplinleri kapsayan bir alan olup, dijital görsellerden anlamlı veriler çıkarmayı amaçlar. Aynı zamanda mühendislik perspektifinden, insan görme sisteminin gerçekleştirdiği işleri otomatik hale getirmeyi hedefler [46].

Bilgisayarla görme alanındaki ana görevler dijital görsellerin elde edilmesi, işlenmesi, analiz edilmesi, anlaşılması, çıkarımlar yapılması ve bu verilerle karar verilmesidir. Görüntü işleme ve bilgisayarla görme kavramları genellikle birbirinin yerine kullanılsa da bazen bu terimler örtüşmektedir [40].

Dijital görüntü işlemenin ilk yıllarındaki ana hedef, görüntü kalitesini iyileştirmektir. Bu alandaki erken başarılı örneklerden biri 1964 yılında ABD'de JPL tarafından yapılan bir görevde elde edilmiştir. Bu projede, Güneş ve Ay'ın konumları göz önünde bulundurularak, binlerce Ay fotoğrafına geometrik düzeltme, gradyan dönüşümü ve gürültü temizleme gibi işlemler uygulanmıştır. Bu tekniklerle Ay yüzeyinin detaylı haritası çıkarılmıştır. Sonrasında 100.000'den fazla fotoğraf üzerinde daha gelişmiş görüntü işleme yöntemleri kullanılarak, Ay'ın topografik haritası, renk haritası ve panoramik mozaïği oluşturulmuştur. Bu önemli çalışma, Ay'a yapılan ilk insanlı yolculuk için temel bir hazırlık sağlamıştır [41].

Dönemin donanım sınırlamaları nedeniyle dijital görüntü işleme maliyetliydi, ancak 1970'lerde daha ucuz ve erişilebilir bilgisayarların üretilmeye başlanmasıyla bu maliyetler azalmış ve gerçek zamanlı görüntü işleme mümkün hale gelmiştir. Günümüzde, genel amaçlı bilgisayarların güçlenmesi ve yaygınlaşması ile görüntü işleme her zamankinden daha yaygın bir şekilde kullanılmaktadır.

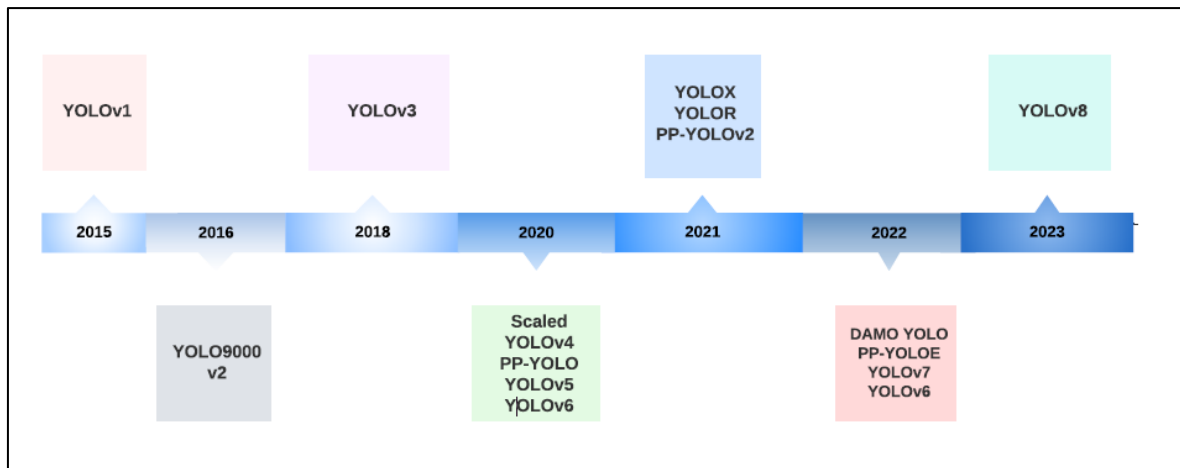
Bugün, görüntü işleme tıp, sanat, mühendislik ve askeri alanlarda geniş bir kullanım alanına sahiptir. İnternetin yaygınlaşmasıyla birlikte, video ve fotoğrafların sıkıştırılması gibi ihtiyaçlarda da görüntü işleme tekniklerinden sıkça faydalanılmaktadır. Ayrıca, görüntü işleme, derin öğrenme modellerinin eğitiminden önce görsel verilerin ön işleminde yoğun bir şekilde kullanılmakta ve modellerin eğitim süresini kısaltarak başarımını artırmaktadır.

Görüntü işleme, dijital ortamda yer alan görsellerin bir bilgisayar aracılığıyla işlenmesi sürecidir. Bu süreç, görüntüdeki bilgi ve verilerin anlamlı hale getirilmesi, analiz edilmesi ve gerektiğinde karar verilmesi için çeşitli algoritmaların kullanılmasıdır. Dijital görüntü işleme, bilgisayarlı görü alanının temel bir bileşeni olup, özellikle tıp, mühendislik, askeri alanlar ve sanat gibi geniş bir yelpazede uygulanmaktadır [40]. Bu alanın en önemli amaçlarından biri, insan görme sistemini taklit ederek, bilgisayarların çevrelerini algılaması ve anlamlandırmasını sağlamaktır.

Bu noktada YOLO görüntü işleme ve bilgisayarlı görü alanında devrim niteliğinde bir yaklaşım olarak karşımıza çıkmaktadır. YOLO nesne tespiti ve görüntü üzerindeki nesnelere etiketlenmesi görevinde yüksek doğruluk ve hız sağlamak için geliştirilmiş bir algoritmadır. Diğer nesne tespiti yöntemlerinden farklı olarak, YOLO algoritması görüntüyü tek bir işlemde analiz eder. Bu, onu hem hızlı hem de verimli kılar, bu yüzden gerçek zamanlı uygulamalarda sıklıkla tercih edilmektedir.

### 2.2.1. YOLO'nun tarihçesi

Derin öğrenme alanında birçok algoritma bulunmaktadır; ancak You Only Look Once (YOLO), hızlı işlem hızı ve daha doğru sonuçlar sağlaması nedeniyle özellikle tercih edilmektedir. YOLO'nun hızının temel sebebi, işlem geliştirme ve çalışma mekanizmasından kaynaklanmaktadır. YOLO ailesi, her biri önceki sürümlerin sınırlamalarını ele alarak ve performansı artırarak, birçok yineleme ile gelişim göstermiştir, Şekil 2.6:



Şekil 2.6. YOLO Ailesi Zaman Çizelgesi [14]

YOLO, Washington Üniversitesi'nden Joseph Redmon ve Ali Farhadi tarafından geliştirilmiştir. 2015 yılında piyasaya sürülen YOLO, yüksek hızı ve doğruluğuyla hızla popülerlik kazandı.

YOLO versiyonlarının gelişimini değerlendirebilmek için backbone, çerçeve ve performans gibi anahtar kalıplar bulunmaktadır [14].

YOLOv2, 2016 yılında yayımlanmış ve YOLOv1'in farklı boyutlardaki nesnelere tespit edememe sorununu çözmek için geliştirilmiştir. Bu sorunu çözebilmek adına, batch normalization, anchor boxes ve boyut kümeleri geliştirilmiştir.

YOLOv3, 2018'de piyasaya sürüldüğünde modelin performansını artırmıştır. Bunun için backbone ağı, çoklu ankrajlar ve uzamsal piramit havuzlama geliştirilmiştir. YOLOv4, 2020'de piyasaya sürüldüğünde ise, önemli değişiklikler açısından YOLOv3 ile minimal bir sapma göstermektedir. YOLOv4, YOLOv3'e kıyasla daha fazla CNN katmanına sahiptir.

YOLOv5, öncekilere kıyasla en belirgin versiyon olarak öne çıkmaktadır; bunun başlıca nedeni Darknet yerine PyTorch kullanmasıdır. Bu değişiklik, modelin performansında bir artışa yol açmıştır. Ayrıca, hiper parametre optimizasyonu, entegre deney takibi ve otomatik ihracat özelliklerinin eklenmesi, ilerlemelerine katkıda bulunmaktadır.

YOLOv6, daha iyi performans, daha hızlı eğitim ve daha iyi tespit sağlamak üzere geliştirilmiştir. Başarılı olabilmek için, bu modelin mimarisi geliştirilmiştir.

YOLOv7, COCO anahtar noktası veri setini kullanarak poz tahmini gibi yeni görevleri entegre ederek yeteneklerini genişletmiştir.

YOLOv8, gerçek zamanlı nesne tespitinde en son yineleme olup, doğruluk ve hız açısından en üst düzey performansı sunmaktadır. Önceki versiyonların gelişmelerine dayanarak, çeşitli nesne tespit görevleri için ideal bir seçenek haline getiren yeni özellikler ve optimizasyonlar sunmaktadır.

YOLO'nun ilerlemelerini keşfetmek, çerçevenin gelişimini derinlemesine anlamayı sağlamaktadır. Bu ilerleme, ağ tasarımı, kayıp fonksiyonundaki ayarlamalar, ankraj kutularındaki değişiklikler ve giriş çözünürlüğündeki değişiklikler gibi çeşitli alanlarda

özetlenebilir. Ayrıca, her yeni YOLO versiyonu hız ve doğruluk açısından iyileştirmeler göstermektedir. Bir YOLO versiyonu seçerken, belirli uygulamanın bağlamı ve gereksinimleri dikkate alınmalıdır.

### 2.2.2. YOLOv8 teknolojik iyileştirmeler

YOLOv8'in diğer modellere göre daha yüksek performansa sahip olma sebeplerinden birisi Mosaic ve MixUp gibi gelişmiş veri artırma teknikleriyle modelin genelleme kabiliyetini artırmasıdır. Ayrıca uyarlanabilir çapa hesaplama yöntemi kullanılarak nesnelerin daha doğru tespit edilmesi anlamında gelişim sağlar. YOLOv8 diğer modellerden farklı olarak giriş katmanında uyarlanabilir gri tonlama dolgusu uygulanarak görüntülerin boyutlarının sabitlenmesini sağlar, böylece nesne tespitinde daha verimli olmasını sağlar [41].

YOLOv8'i diğer modellerden daha ileri taşıyan en büyük yeniliklerden biri mimarisinin Cross Stage Partial (CSP) bloklarıyla geliştirilmiş olmasıdır. Eski modellerde kullanılan C3 yerine CSP bloklarının geliştirilmesiyle elde edilen C2f modelinin kullanımı YOLOv8'i ileriye taşımıştır [42]. ConvNeXt mimarisinden esinlenilerek modern konvolüsyon katmanları modele entegre edilmiş ve bu sayede modelin zorlu tespit senaryolarında performansı artırılmıştır [43]. Modelin omurga katmanında yapılan bu iyileştirmeler Verimli Katman Toplama Ağı (ELAN) yaklaşımından esinlenilerek yapılmıştır.

YOLOv8'in boyun katmanındaki iyileştirmeler, modelin tespit doğruluğunu ve hesaplama verimliliğini artırmak amacıyla önemli yapısal değişiklikler içerir. Bu iyileştirmelerden biri, çok ölçekli özelliklerin verimli bir şekilde birleştirilmesini sağlayan Path Aggregation Network - Feature Pyramid Network (PAN-FPN) yapısının kullanılmasıdır. PAN-FPN, küçük, orta ve büyük ölçekli nesnelerin doğru bir şekilde tespit edilmesine yardımcı olur [42]. Ayrıca, BiFPN (Bidirectional Feature Pyramid Network) entegrasyonu, özelliklerin hem yukarıdan aşağıya hem de aşağıdan yukarıya doğru verimli bir şekilde birleştirilmesine olanak tanır, bu da daha güçlü bir özellik çıkarımı sağlar. Bu yapılar, modelin hesaplama verimliliğini artırırken aynı zamanda daha doğru sonuçlar elde edilmesine yardımcı olur. Boyun katmanında ayrıca anchor-free yaklaşımına geçiş yapılmış ve bu yöntem, nesne tespitinde daha esnek ve verimli sonuçlar sunmuştur. Tüm bu iyileştirmeler, YOLOv8'in tespit doğruluğunu artırırken, modelin daha hızlı ve verimli çalışmasına katkı sağlamaktadır.

YOLOv8'in çıkış katmanındaki geliřtirmeler, sınıflandırma ve nesne tespiti işlemlerini ayrı ayrı optimize etme, anchor-free tespit yaklaşımını benimseme, gelişmiş kayıp hesaplama teknikleri kullanma ve daha hızlı çıkarım (inference) süreçleri ile modelin doğruluğunu önemli ölçüde artırmıştır. Bu iyileřtirmeler, modelin farklı senaryolarda daha esnek, doğru ve verimli sonuçlar elde etmesine olanak tanımaktadır [41].

### 2.3. İnsansız Hava Araçları

İnsansız Hava Araçları (İHA), insan müdahalesi olmadan uçuş gerçekleřtirebilen hava araçları olarak tanımlanır. İlk başlarda, tehlikeli ve zor görevler için çeşitli askeri kuvvetler tarafından kullanılan İHA'lar, zamanla ticaret, bilim, tarım, güvenlik, fotoğrafçılık ve lojistik gibi farklı alanlarda da kullanım alanı bulmuştur. İHA teknolojisinin gelişimi hem askeri hem de sivil sektörlerde önemli bir yer tutmaktadır.

20. yüzyılın başlarında, İHA'lar askeri eğitimde ve atış hedefi olarak kullanılıyordu. Ancak, Birinci Dünya Savaşı sırasında İHA teknolojisinde önemli gelişmeler yaşandı. Bu dönemde Dayton-Wright Airplane Company tarafından geliştirilen ve önceden belirlenen bir zamanda patlayan pilotsuz hava torpidosu gibi örneklerle İHA'lar daha işlevsel hale geldi [44]. 1916 yılında A. M. Low tarafından yapılan ilk motorlu İHA denemesi ise, bu teknolojinin askeri alandaki kullanımını hızlandırdı. Ayrıca, Reginald Denny tarafından 1935 yılında geliştirilen ilk büyük ölçekli İHA, teknolojinin ivme kazanmasında önemli bir rol oynadı.

İkinci Dünya Savaşı'nda ise İHA'lar, hem uçaksavar eğitimi için hedef olarak kullanılmış, hem de hava saldırılarında yer alacak şekilde geliřtirilmeye başlanmıştır. 1959 yılında, Amerikan ordusu, pilot güvenliğini artırmak ve riski en aza indirmek amacıyla insansız hava araçlarına (İHA) yönelik yatırımlara odaklanarak bu alandaki teknolojik gelişimin öncüsü olmuştur. Bu kapsamda 1960'lı yıllarda başlatılan projeler, İHA teknolojisinin hızla ilerlemesine zemin hazırlamıştır. Özellikle 1964 yılında Vietnam Savaşı sırasında Ryan Model 147 ve Lockheed D-21 gibi erken dönem İHA'lar, keşif ve istihbarat toplama görevlerinde başarıyla kullanılarak savaşın seyrinde önemli bir rol oynamıştır. Aynı dönemde İsrail, Yıpratma Harbi sırasında keşif kameralarıyla donatılmış İHA'ları devreye sokarak düşman bölgelerinden kritik bilgiler elde etmiş ve bu teknolojiyi savaş taktiklerine entegre etmiştir.

1973 Yom Kippur Savaşı, İHA teknolojisinin askeri stratejilerdeki önemini daha da belirgin hale getiren bir dönüm noktası olmuştur. İsrail, bu süreçte İHA'ları hem düşman uçaksavar sistemlerini yanıltmak amacıyla sahte hedefler yaratmak için hem de gözetleme faaliyetlerinde etkili bir şekilde kullanmıştır. Benzer şekilde, ABD ordusu da Güney Asya'daki askeri operasyonlarda İHA'ları keşif görevlerinde kullanarak teknolojinin potansiyelini değerlendirmiştir.

1980'ler ve 1990'lar, İHA teknolojisinin hem tasarım hem de operasyonel kabiliyetler açısından olgunlaştığı yıllar olmuştur. ABD ordusu, bu dönemde İHA'ları daha geniş kapsamda kullanmaya başlamış ve özellikle 1991 Körfez Savaşı sırasında bu araçların etkinliği bir kez daha kanıtlanmıştır.

Günümüzde İHA'lar, hem askeri hem de sivil alanda geniş bir kullanım yelpazesine sahiptir. 2012 yılı itibariyle, ABD Hava Kuvvetleri filosunda 7494 İHA bulunduğu ve bu sayının toplam uçak filosunun yaklaşık üçte birine denk geldiği bildirilmiştir. Bunun yanı sıra, İHA'lar artık yalnızca savaş alanlarında değil, günlük hayatın birçok alanında da yer edinmiştir. Örneğin, 2013 yılında Deutsche Post'un "Parcelcopter" projesi kapsamında tıbbi malzemelerin taşınmasında İHA'ları test etmesi, bu teknolojinin lojistikteki potansiyelini göstermiştir. Aynı şekilde, medya kuruluşları da haber materyalleri veya ünlülerin görüntülerini elde etmek için İHA'ları yaygın şekilde kullanmaktadır.

İHA'lar ayrıca, tıp, güvenlik, arama-kurtarma, video ve fotoğrafçılık gibi alanlarda da etkin bir şekilde kullanılmaktadır. Bu araçlar, düşük maliyetli ve kolay bakım gerektirmeleri sayesinde pratik ve erişilebilir hale gelmiş olup, kullanım alanları her geçen gün genişlemektedir. Özellikle gelişmiş navigasyon sistemleri, sensörler ve yapay zekâ teknolojileriyle donatılan İHA'lar, gelecekte çok daha fazla sektörde önemli bir rol oynayacaktır.

Sonuç olarak, İHA'lar, askeri alandaki kökenlerinden günümüze kadar olan süreçte büyük bir evrim geçirmiş ve çeşitli endüstrilerdeki kullanımı ile günlük hayatımızda önemli bir yer edinmiştir. Teknolojik gelişmelerle daha da verimli hale gelen İHA'lar, gelecekteki uygulamalarıyla birçok sektörde devrim yaratmaya devam edecektir.



### 3. MATERYALLER VE YÖNTEMLER


Bu bölüm YOLOv8'in değerlendirilmesi için kullanılan materyalleri ve deney gerçekleştirildikten sonraki değerlendirme kriterlerini ele almaktadır.

#### 3.1. Deneysel Ortam ve Veri Seti


Bu çalışmada YOLOv8 modeli açık kaynak bulut tabanlı Jupyter notebook olan Google Colab kullanılarak uygulanmıştır. Google Colab'ın en büyük avantajı model eğitimi sırasında 15110MiB bellek kapasitesine sahip bir Tesla T4 NVIDIA GPU sağlamasıdır. Ayrıca Google Colab projeleri saklama olanağı sunmakta ve Google Drive ile entegre olduğu için kolayca erişilebilmektedir.

Bu çalışmada Mehdi Özel tarafından bir İHA yarışması için toplanan ücretsiz veri seti kullanılmıştır [45]. Bu veri seti Darknet (YOLO), TensorFlow ve PyTorch modellerinde eğitim yapmayı kolaylaştıran “.txt” ve “.xml” dosyalarını içermektedir. Veri seti insansız hava araçlarını tespit ve tanıma amacıyla titizlikle etiketlenmiş ve anotasyon yapılmış toplam 1359 görüntü içermektedir. Veri setinde birden fazla insansız hava aracı kategorisi bulunmaktadır ve görüntüler farklı mesafelerde çekilmiştir. Veri setinde bulunan görüntülerde, veri çeşitliliği sağlamak amacıyla farklı açılar, yükseklikler ve arka planlar bulunmaktadır. Bu çalışmada tüm insansız hava aracı kategorileri tek bir sınıf olarak ele alınmaktadır. Veri seti YOLOv8 modelinin eğitimi, doğrulaması ve test edilmesi için Roboflow kullanılarak %70: %20: %10 oranında bölünmüştür.

Veri setinin örnekleri çeşitli kategori ve alt kategorileri içermekte olup Resim 3.1'de görülebilir. Veri seti Şekil 3.1'te gösterildiği gibi çeşitli insansız hava aracı yönelimleri ve boyutları içermektedir. Şekil 3.1 (a) veri setindeki insansız hava aracı konumlarının dağılımını göstermekte iken, Şekil 3.1 (b) insansız hava aracı boyut dağılımını göstermektedir.



Resim 3.1. Veri Setinden İnsansız Hava Aracı Görüntü Örnekleri [46]



Şekil 3.1. (a) Veri Setindeki İnsansız Hava Araçlarının Konum Dağılımı. (b) Veri Setindeki İnsansız Hava Araçlarının Boyut Dağılımı.

İnsansız hava aracı nesnelерinin boyutlarındaki varyasyon aşırı sayıda hesaplama parametresine yol açabilmektedir. Yüksek yoğunluklu hesaplama parametresinin önüne geçmek için eğitimden önce orijinal görüntü boyutu, piksel dönüşümü ile 640 piksel × 640 piksel olarak eşit şekilde küçültülmektedir. Yeniden boyutlandırmanın yanı sıra, veri setine ön işleme adımı olarak otomatik yönlendirme uygulanmaktadır. Veri setindeki çeşitli artırma yöntemlerinin etkilerini karşılaştırmak amacıyla, döndürme, çevirme, bulanıklaştırma, kırpma ve gri tonlama gibi teknikler uygulanmıştır. Artırma yöntemlerinin sonuçları, Bölüm 4.2 Veri Seti Artırması başlığında ayrıntılı olarak ele alınacaktır.

### 3.2. Değerlendirme Kriterleri

Tespit edilen örneklerin değerlendirilmesini kolaylaştırmak için bir karışıklık matrisinin değerli bir araç olarak kullanılması mümkündür. Bu matris dört farklı sonucu belirler: doğru pozitif (TP), yanlış pozitif (FP), doğru negatif (TN) ve yanlış negatif (FN). Gerçek parametreler sütunlara, tahmin edilen parametreler ise satırlara karşılık gelir; bu sayede bu dört sonucun gösterimi, Çizelge 3.1'de olduğu gibi sağlanabilir:

Çizelge 3.1. Karışıklık Matrisi

Confussion Matrix		Real Parameters	
		POSITIVE	NEGATIVE
Predicted Parameter	POSITIVE	TP	FP
	NEGATIVE	FN	TN

Eğitilen modelin insansız hava aracı tespitindeki etkinliğini değerlendirmek için üç ana ölçüt kullanılmaktadır: duyarlılık (R), kesinlik (P) ve ortalama kesinlik (AP). Duyarlılık parametresi, doğru bir şekilde tanımlanan pozitif hedeflerin sayısının toplam pozitif hedef sayısına bölünmesiyle belirlenir; aşağıda gösterildiği gibi:

$$Duyarlılık (R) = \frac{TP}{TP+FN} \quad (3.1)$$

TP algoritma tarafından doğru bir şekilde tanımlanan pozitif örneklerin sayısını, FN ise algoritma tarafından negatif örnekler olarak yanlış tespit edilen pozitif örneklerin sayısını temsil eder. Kesinlik parametresi, doğru bir şekilde tanımlanan pozitif hedeflerin sayısının

toplam pozitif tespit sayısına bölünmesiyle belirlenir; aşağıda gösterildiği gibi:

$$\text{Kesinlik (P)} = \frac{TP}{TP+FP} \quad (3.2)$$

TP algoritma tarafından doğru bir şekilde tanımlanan pozitif örneklerin sayısını; FP ise algoritma tarafından pozitif örnekler olarak yanlış tespit edilen negatif örneklerin sayısını temsil eder.

Kesinlik (P) ve duyarlılık (R) parametreleri hesaplandıktan sonra ortalama kesinlik (AP) hesaplanabilir. Kesinlik y eksenine, duyarlılık ise x eksenine yerleştirilerek bir grafikte görselleştirilebilir. Ortalama kesinlik (mAP) parametresi birden fazla sınıf üzerindeki AP değerlerinin ortalamasını temsil eder. Ortalama kesinlik (AP) ve ortalama ortalama kesinlik (mAP) hesaplama formülleri aşağıda verilmiştir:

$$\text{Ortalama Kesinlik (AP)} = \int_0^1 PRdR \quad (3.3)$$

$$\text{Ortalama Ortalama Kesinlik (mAP)} = \frac{\sum_{k=1}^n AP_k}{n} \quad (3.4)$$


Yukarıda listelenen her bir parametre, modelin değerlendirilmesinde önemli bir öneme sahiptir ve tüm sonuçlar değerlendirme amaçları için kullanılacaktır.

## 4. SONUÇLARIN TARTIŞILMASI

### 4.1. Hiper Parametre Ayarları

YOLO'daki hiper parametre ayarları modelin performansını, hızını ve doğruluğunu belirlemede kritik bir rol oynamaktadır. Bu ayarlar YOLO modelinin geliştirme aşamalarının her birinde eğitim, doğrulama ve test davranışını önemli ölçüde etkiler. Bu çalışmada sistemin davranışını değerlendirmek için hiper parametrelerde değişiklikler yapılmıştır.

Epok tüm veri setinde bir tam geçişi temsil eder. Bu değer ayarlanması eğitim süresini ve modelin performansını etkileyebilir. Bu çalışmada tüm denemelerde en iyi sonuçların 150 epok ile sürekli olarak elde edildiği gözlemlenmiştir. Epok sayısı 150 olarak ayarlandığında eğitilen modelin kararlı ve istikrarlı hale geldiği fark edilmiştir. Diğer hiper parametrelere varsayılan olmayan değerler atandığında, maksimum değeri elde etmek için 150 epok'un en iyi seçim olduğu ortaya çıkmıştır. Şekil 4.1 bu çalışmada elde edilen bazı sonuçları temsil etmektedir.



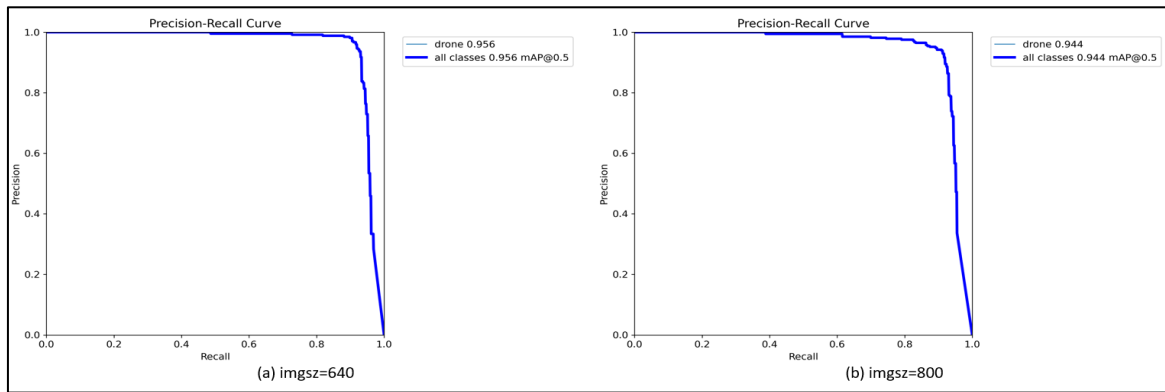
Şekil 4.1. (a) 50 Epok'daki Kesinlik-Duyarlılık Eğrisi. (b) 100 Epok'daki Kesinlik-Duyarlılık Eğrisi. (c) 150 Epok'daki Kesinlik-Duyarlılık Eğrisi. (d) 200 Epok'daki Kesinlik-Duyarlılık Eğrisi

Şekil 4.1.(a) 50 epok'da 0.939'luk bir kesinlik-duyarlılık değerini gösterirken, Şekil 4.1.(b) daha yüksek bir epok'da 0.941'lik hafifçe daha yüksek bir kesinlik-duyarlılık değeri göstermektedir. Şekil 4.1.(c) maksimum kesinlik-duyarlılık performans değeri olan 0.956'yı sergilemektedir. Şekil 4.1.(d), 150 epok'da kesinlik-duyarlılık değerinin dramatik bir şekilde 0.919'a düştüğünü göstermektedir.

Görüntü boyutu hiper parametresi, girdi görüntülerinin boyutlarını ayarlamak için kullanılır ve YOLOv8 modelinin hem doğruluğunu hem de hesaplama verimliliğini artırmayı hedefler. Bu çalışmada görüntü boyutunun ön işleme sırasında belirlenen 640'a ayarlanmasının, alternatif değerlerle karşılaştırıldığında modelin doğruluğunu artırdığı gözlemlenmiştir. Farklı görüntü boyutunun yapılan deneyler, alternatiflerin 640 ile karşılaştırıldığında daha düşük performans gösterdiğini ortaya koymuştur. Şekil 4.2 bu çalışmada elde edilen bazı sonuçları temsil etmektedir.

Şekil 4.2 (a) 640'lık bir görüntü boyutunun 0.956'lık daha yüksek bir kesinlik-duyarlılık değeri sağladığını göstermektedir. Şekil 4.2 (b) ön işleme boyutundan farklı bir görüntü boyutunun kullanılmasının kesinlik-duyarlılık değerini 0.944'e düşürdüğünü göstermektedir.

Yığın boyutu parametresi aynı anda işlenen görüntü miktarını düzenlemek için kullanılır. -1 olarak ayarlandığında GPU bellek kullanılabilirliğine göre dinamik olarak görüntü sayısını ayarlayan otomatik toplama işlevini etkinleştirir. Bu çalışmada yoğun boyutu parametresinin -1 olarak ayarlanması hassasiyette önemli bir düşüşe neden olmuştur. Bu nedenle varsayılan değer olan 16 korunmuştur.



Şekil 4.2. (a) 640 Görüntü Boyutundaki Belirli Veri Seti İçin Kesinlik-Duyarlılık Eğrisi. (b) 800 Görüntü Boyutundaki Belirli Veri Seti İçin Kesinlik-Duyarlılık Eğrisi.

Warmup epok parametresi öğrenme oranını başlangıçta yavaşça artırmak için kullanılır ve bu şekilde eğitim sürecini stabilize etmeyi amaçlar. Bu sayede model başlangıçtan itibaren daha tutarlı bir şekilde çalışarak daha doğru sonuçlar elde eder. Bu çalışmada varsayılan warmup epok değeri 3 iken 5 olarak güncellendi ve bu güncellenmenin kesinlik-duyarlılık eğrisi değerlerinde iyileşme sağladığı gözlemlendi.

YOLOv8'de momentum, warmup\_momentum, weight\_decay gibi birçok hiper parametre kullanılmaktadır. Bu çalışma kapsamında, diğer tüm hiper parametreler varsayılan değerlerinde tutulmuştur.

#### **4.2. Veri Seti Artırımı**

Bu çalışmada YOLOv8 modeli, Kaggle'da yayımlanan ve özel olarak yapılandırılmış insansız hava aracı veri seti kullanılarak eğitilmiştir [23]. Veri setinin ön işleme ve artırımı Roboflow kullanılarak gerçekleştirilmiştir. Artırma tekniklerinin etkinliği gerçek dünya görüntüleri, yakın mesafe çekimleri, uzak mesafe görüntüleri, gürültülü görseller, açılı perspektifler gibi farklı unsurları içerebilecek veri setine bağlı olarak değişiklik göstermektedir. Bu çalışmada çeşitli veri artırma teknikleri uygulanmış ve bunların sonuçları gözlemlenmiştir.

Flip artırımı veri setini örnek görüntüleri simetrik olarak yansıtarak artırma işlemidir. Bu teknik modelin örnek görüntülerin çeşitli yönlerini tanınmasına yönelik olarak eğitilmesini amaçlar. Çalışmamızda bu yöntemin sonuçları olumlu etkilemediğini gördük; dolayısıyla daha iyi sonuçlar elde etmek için kullanılmadı.

Dönme artırımı orijinal görüntüleri birkaç derece döndürerek yeni görüntü örnekleri oluşturma işlemidir. Bu yaklaşım modelin performansını artırmak için görüntüleri modelin farklı perspektiflerden görmesini amaçlar. Bu çalışmada sadece döndürme artırımı uygulamak önemli derecede olumlu sonuçlar vermiştir ve kesinlik-duyarlılık eğrisinde bir artış gözlemlenmiştir. Döndürme artırımının bu veri seti için gerçekten etkili bir teknik olduğu gözlemlenmiştir.


Kırpma artırımı örnek görüntü sayısını artırmak için belirli bölümleri kırparak gerçekleştirilir. Bu yaklaşım modelin öğrendiği hedefin yönlerini çeşitlendirmeyi amaçlar.

Bu çalışmada kırpma yönteminin kullanılmasının sonuçları deęiřtirmedięi gözlemlenmiřtir, bu da bu veri setinde insansız hava aracı tespiti için gerekli kritik bileřenlerin varlıęını göstermektedir.

Bulanıklařtırma artırımı mevcut veri setine bulanıklık ekleyerek ek görüntü örnekleri oluřturma iřlemidir. Görüntülerdeki detay seviyesini azaltarak modeli daha zorlu örnekler üzerinde eęitmek amaçlanmaktadır. Çalışmamızda yalnızca bulanıklařtırma artırımı kullanılması, kesinlik-duyarlılık deęerinde artış göstermesine neden oldu ve bu artırma yönteminin bu veri seti için model kombinasyonu ile uyumlu olduęunu gösterdi.

Gri tonlama artırımı, renkli görüntüleri gri tonlamalı versiyonlara dönüřtürerek ekstra görüntüler üretme iřlemidir. Bu ayar, modelin görüntülerin temel özelliklerine öncelik vermesini teşvik eder. Ancak, çalışmamızda gri tonlama artırımı model performansını deęiřtirmede ve renk deęiřkenlięinin bu veri seti için kritik bir faktör olmayabileceęini öne sürdü.

YOLOv8'in çeřitli veri seti artırımları üzerindeki performansının deęerlendirme kriterleri ve kesinlik-duyarlılık eęrileri řekil 4.3'de gösterilmektedir.



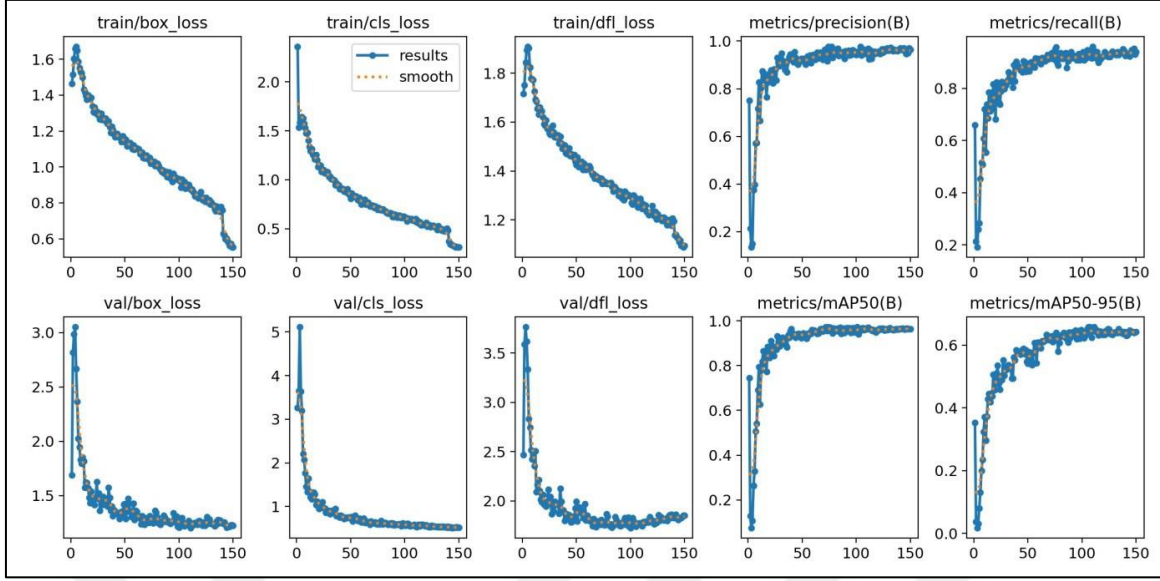
řekil 4.3. (a) Flip Artırımlı Kesinlik-Duyarlılık Eęrisi. (b) Dönme Artırımlı Kesinlik-Duyarlılık Eęrisi. (c) Kırpma Artırımlı Kesinlik-Duyarlılık Eęrisi. (d) Bulanıklařtırma Artırımlı Kesinlik-Duyarlılık Eęrisi. (e) Gri Tonlama Artırımlı Kesinlik-Duyarlılık Eęrisi.

Şekil 4.3 (a) flip artırımı bir veri setinde YOLOv8 modelinin performansını göstererek 0.957'lik bir kesinlik-duyarlılık değeri elde etmiştir. Şekil 4.3 (b) döndürme artırımı bir veri setindeki modelin performansını sunarak 0.977'lik bir kesinlik-duyarlılık değeri elde etmiştir. Şekil 4.3 (c) kırpma artırımı bir veri setindeki modelin sonuçlarını göstererek 0.971'lik bir kesinlik-duyarlılık değeri elde etmiştir. Şekil 4.3 (d) bulanıklaştırma artırımı bir veri setindeki modelin performansını sergileyerek yine 0.971'lik bir kesinlik-duyarlılık değeri elde etmiştir. Son olarak, Şekil 4.3 (e) gri tonlama artırımı bir veri setindeki modelin performansını göstererek 0.969'luk bir kesinlik-duyarlılık değeri elde etmiştir. Bu deneyler sonucunda hem döndürme hem de bulanıklaştırma artırma yöntemlerinin veri setine uygulanmasının model performansını artırabileceği sonucuna varılmıştır.

### 4.3. Model Performansı

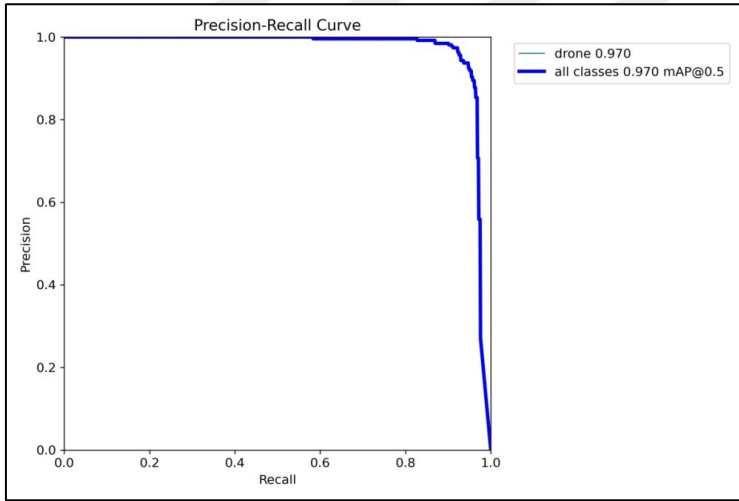
Başarıyla sonuç elde etmek için hem model hem de veri seti üzerinde hiper parametrelerin ayarlanması ve belirli veri setinin artırılması şeklinde iki temel yaklaşım uygulanmıştır. Bu iki yöntem sırasıyla uygulanmıştır. İlk olarak sonuçları optimize etmek için hiper parametreler ayarlanmış, ardından performansı daha da artırmak amacıyla veri artırma teknikleri uygulanmıştır.

Şekil 4.4 YOLOv8 modelinin tüm eğitim süreci boyunca performansını özetlemek için sunulmuştur. Elde edilen sonuçlara dayanarak bu veri seti ve model için 150 epok değerinin optimal değer olarak seçilmesinin birkaç nedeni olduğu görülebilir. Eğitim performansı sonuçlarını temsil eden ilk satır incelendiğinde kayıp değerlerinin 100 ile 150 epok arasında sürekli olarak düştüğü açıkça görülmektedir. Ayrıca hem doğruluk hem de hatırlama değerleri 150 epok civarında istikrar kazanmaktadır. Benzer şekilde, doğrulama performansını temsil eden ikinci satırda, mAP değerleri de 150 epok civarında istikrar kazanmaktadır. Genel olarak sonuçlar küçük dalgalanmalar göstermekte olup, bu dalgalanmalar kritik değildir ve eğitim sürecinde kullanılan ağırlıklara atfedilebilir.



Şekil 4.4. Belirli Bir Veri Seti İçin Yolov8 Model Sonuçları


Model için hiper parametre ayarlamasına ek olarak kesinlik eğrisi, duyarlılık eğrisi, F1 skoru ve kesinlik-duyarlılık eğrisi mevcuttur ve Şekil 4.5'de gösterilebilir:



Şekil 4.5. Belirli Veri Seti İçin Kesinlik-Duyarlılık Eğrisi.

Kesinlik-duyarlılık eğrisi değeri hiper parametre ayarlaması ile önemli ölçüde iyileşerek dikkat çekici bir yüksek değere, 0.970'e ulaşmaktadır.

Şekil 4.6 (a) F1 eğrisinin belirli bir noktada 0.588'lik en yüksek değere ulaştığını göstermektedir. Şekil 4.6 (b)'de duyarlılık değeri 0.97 olarak belirtilirken, Şekil 4.6 (c)'de kesinlik değeri 0.832 olarak gösterilmektedir.



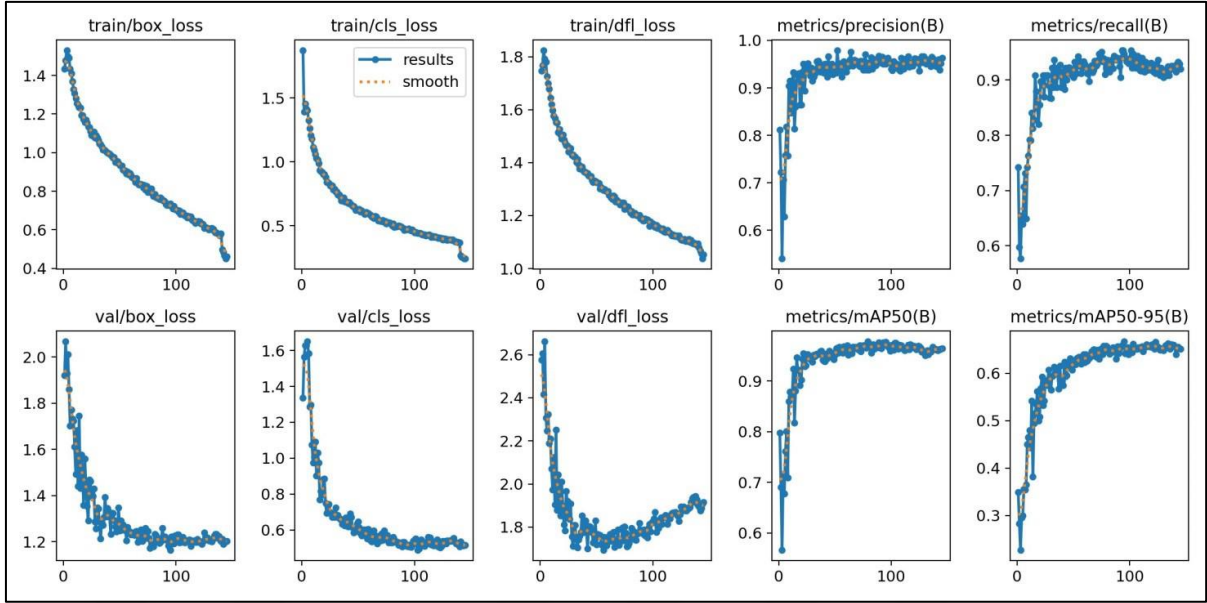
Şekil 4.6. (a) Belirli Bir Veri Seti İçin F1–Güven Eğrisi. (b) Belirli Bir Veri Seti İçin Duyarlılık–Güven Eğrisi. (c) Belirli Bir Veri Seti İçin Kesinlik–Güven Eğrisi.

Resim 4.1 elde edilen test sonuçlarını göstermekte olup, modelin test görüntülerindeki farklı boyut ve açılardaki insansız hava aracı tanıma yeteneğini sergilemektedir. Kesinlik değerlerinin 0.6 ile 0.9 arasında değiştiği gözlemlenmektedir.




Resim 4.1. Belirli Veri Seti İçin Test Sonuçları

Hiper parametre ayarlamalarının ardından çeşitli artırma yöntemleri uygulanmış ve bunlar arasından en iyisi seçilerek Şekil 4.7’de verilen sonuçlar elde edilmiştir.



Şekil 4.7. Yüksek Boyutlu Veri Seti İçin Yolov8 Model Sonuçları


Şekil 4.4 ile Şekil 4.7 arasındaki önemli fark Şekil 4.4’de daha yüksek maksimum ve minimum değerlere sahip kayıp değerlerine sahip olmasıdır. Bu sonuç daha büyük veri setlerinin daha yüksek kayıp değerlerine yol açtığının göstergesidir. Veri artırmanın bir diğer önemli etkisi kesinlik-duyarlılık eğrisinde gözlemlenmektedir. Kesinlik-duyarlılık değeri bulanıklaştırma ve döndürme veri artırma yöntemleri kullanılarak artırılmıştır. Bu yöntemler önceki bölümlerde detaylandırıldığı gibi yinelenmeli deneyimler sonucunda belirlenmiştir.



Şekil 4.8. Artırılmış Veri Seti İçin Kesinlik-Duyarlılık Eğrisi

Veri seti artırımı ile kesinlik-duyarlılık eğrisi değeri önemli ölçüde iyileşerek 0.97 yüksek bir değere ulaşıyor, bu durum Şekil 4.8'de gösterilmektedir.

Şekil 4.9 (a) F1 eğrisinin belirli bir noktada maksimum değer olan 0.236'ya ulaştığını göstermektedir. Şekil 4.9 (b)'de duyarlılık değeri 0.98 olarak belirtilirken, Şekil 4.9 (c) 'de kesinlik değeri 0.840 olarak gösterilmektedir.



Şekil 4.9. (a) Artırılmış Belirli Veri Seti İçin F1-Güven Eğrisi (b) Artırılmış Belirli Veri Seti İçin Duyarlılık-Güven Eğrisi (c) Artırılmış Belirli Veri Seti İçin Kesinlik-Güven Eğrisi

Resim 4.2 modelin test görüntülerindeki farklı boyut ve yönlerdeki insansız hava araçlarını tespit etme yeteneğini sergilemektedir. Bu tespitlerdeki kesinlik değerleri 0.8 ile 0.9 arasında değişmektedir.



Resim 4.2. Artırılmış Veri Seti Sonucu

#### 4.4. Diğer Modellerle Karşılaştırma

Bu çalışmada YOLOv8 modeli belirli bir veri setinde eğitilmiş ve önemli başarılar elde edilmiştir. YOLOv8'in diğer modellere göre konumunu değerlendirmek için aynı veri seti üzerinde YOLOv4, YOLOv3, transfer öğrenme uygulanan YOLOv5 ve Mask R-CNN modelinin sonuçları kullanılmıştır [20]. Bu çalışmadan elde edilen sonuçlar Çizelge 4.1'de özetlenmiştir.

Çizelge 4.1. Karşılaştırma Tablosu

Model	Veri Seti Boyutu	Kesinlik (P)	Duyarlılık(R)	Ortalama Kesinlik (mAP)
CNN [16]	712	96 %	94 %	95 %
SVM [16]	712	82 %	91 %	88 %
KNN [16]	712	74 %	94 %	80 %
MaskRCNN [47]	1359	93.6 %	89,4	92,5 %
YOLOv3 [20]	1359	92 %	70 %	78,5 %
YOLOv4 [20]	1359	91 %	89 %	93,8 %
YOLOv5 [20] (Transfer Learning)	1359	94.7 %	92,5 %	94,1 %
YOLOv8	1359	95.4 %	93,4 %	97 %
Önerilen Model	3212	94.6 %	96,05 %	97,8 %

Bu çalışmada performans kriterleri, önceki bölümlerde belirtilen kesinlik ve duyarlılık değerlerini doğrudan etkileyen, kesinlik-duyarlılık eğrisi, kesinlik, duyarlılık ve doğru pozitif değerleri gibi çoklu parametreler temel alınarak belirlenmiştir. Doğru pozitif değerleri, referans alınan diğer çalışmalarda performans değerlendirmesi için kullanıldıkları için karşılaştırma parametresi olarak kullanılmıştır. YOLOv8 için doğru pozitif (TP) değerleri incelendiğinde, transfer öğrenimi kullanılmadan bile oldukça başarılı sonuçlar elde edilmiştir. Ayrıca YOLOv8 için artırılmış ve artırılmamış veri setleri ile elde edilen PR eğrisi değerleri sırasıyla 0.978 ve 0.970 olarak belirlenmiş, her ikisi de diğer modellerden elde edilen değerleri aşmıştır.

#### 4.4.1. Mimari ve performans karşılaştırması

YOLOv8 YOLO serisinin önceki sürümlerinden farklı olarak yeni bir omurga ve baş yapısına sahiptir. Bu yenilikler modelin karmaşık nesne tespiti görevlerinde doğruluğunu artırırken daha düşük hata oranlarına ulaşmasını sağlar. YOLOv8 diğer YOLO modelleri (YOLOv3, YOLOv4, YOLOv5) ile karşılaştırıldığında %95.4 gibi yüksek bir kesinlik değerine sahip olduğu gözlemlenmiştir. Bu başarı YOLOv8'in detayları yakalamadaki üstün yeteneğini, nesne boyut ve şekillerine uyum sağlama kapasitesini gösterir. YOLOv4 ve YOLOv5 gibi modeller insansız hava aracı tespitinde başarılı sonuçlar sunsa da YOLOv8

daha yüksek bir kesinlik elde ederek güvenlik uygulamalarında daha etkin bir araç haline gelmiştir.

#### **4.4.2. Mask R-CNN ve YOLOv8 kıyaslaması**

Mask R-CNN nesne tespiti ve ayrıştırması için tercih edilen oldukça popüler bir derin öğrenme modelidir. Mask R-CNN %93.6 kesinlik ile YOLOv8'e kıyasla nispeten yüksek bir performans sergilemektedir. Ancak Mask R-CNN, YOLOv8'e göre daha fazla işlem gücü ve bellek kullanımı gerektirdiğinden gerçek zamanlı uygulamalarda verimlilik açısından sınırlamalara sahiptir. YOLOv8'in bu gibi durumlarda tercih edilmesinin nedeni, hız ve doğruluk oranlarını optimize etmesi ve nispeten daha az işlem gücü ile çalışabilmesidir. Bu özellik, özellikle insansız hava aracı tespitinde anlık kararların alınması gerektiği askeri ve güvenlik uygulamalarında YOLOv8'in tercih edilmesine yol açmaktadır.

#### **4.4.3. Geleneksel algoritmalar: CNN, SVM, KNN ve YOLOv8 kıyaslaması**

Geleneksel makine öğrenimi algoritmaları olan CNN, SVM ve KNN, belirli doğruluk seviyelerine ulaşmış olsalar da günümüzün kompleks güvenlik gereksinimlerini karşılamak için yeterli değildirler. CNN algoritması, insansız hava aracı tespitinde %96 gibi yüksek bir kesinlik oranına ulaşsa da sınırlı veri ve karmaşık veri işleme gereksinimleri nedeniyle derin öğrenme tabanlı modellerin hızına ve adaptasyon yeteneğine erişemez. SVM ve KNN modelleri de düşük kesinlik oranları ile yüksek doğruluk ve hassasiyet gerektiren güvenlik uygulamalarında yetersiz kalmaktadır. YOLOv8 bu tür durumlarda daha derin ve ayrıntılı öğrenme yetenekleri ile öne çıkar.

#### **4.4.4. Transfer öğrenme: YOLOv5 ve YOLOv8'in eğitim farklılıkları**

YOLOv5 modeline transfer öğrenme uygulandığında elde edilen %94.7 kesinlik oranı, YOLOv8'in transfer öğrenme olmaksızın ulaştığı %95.4 kesinlik oranına çok yakındır. Bu durum YOLOv8'in mimari olarak, eğitimi sırasında transfer öğrenme gibi destekleyici unsurlar olmadan dahi yüksek performans sağlayabildiğini göstermektedir. YOLOv8'in bu özelliği daha düşük miktarda ön bilgi ile bile yüksek doğrulukla nesne tespiti gerçekleştirmesine olanak tanır. Transfer öğrenme, verilerin önceden etiketlenmiş büyük bir veri setinde eğitilmiş bir modelin farklı bir veri setine uyarlanmasıdır. YOLOv8'in bu

avantajı modelin adaptasyon yeteneğini artırarak daha geniş veri çeşitliliğine sahip ortamlarda etkin tespit yapabilmesini sağlar.

#### **4.4.5. Artırılmış veri kullanımı ile performans artışı**

YOLOv8 modelinin artırılmış veri setleri ile test edilmesi sonucu elde edilen kesinlik-duyarlılık değeri %97.8 olarak kaydedilmiştir. Artırılmamış veri seti ile bu değer %97.0 iken, bu sonuçlar YOLOv8'in farklı hava koşulları, ışıklandırma ve gürültü seviyelerine karşı uyum sağlama becerisini ortaya koyar. YOLOv8'in artırılmış veri kullanımı ile sağladığı bu başarı, insansız hava araçlarının doğal ortamlarda tespiti için güvenilir bir çözüm sunmakta olup, gürültülü ortamlarda dahi performans kaybını minimuma indirmektedir. Bu da özellikle kötü hava koşulları veya zayıf ışık gibi zorluklarla karşılaşılan durumlarda YOLOv8'in tercih edilmesinin avantajını göstermektedir.

#### **4.4.6. Önerilen modelin avantajları**

Bu çalışmada önerilen model, YOLOv8 temelinde geliştirilmiş olup, genişletilmiş veri seti ile daha yüksek bir doğruluk oranına ulaşmayı hedeflemektedir. 3212 görüntüden oluşan veri setinde %94.6 kesinlik değeri elde edilmiştir. Bu durum, YOLOv8'in veri büyüklüğü arttıkça stabil ve yüksek doğruluk oranlarını koruyabildiğini gösterir. Modelin geniş veri setlerinde sağladığı bu istikrarlı performans, güvenlik alanında farklı durumlarda karşılaşılan potansiyel tehditlerin erken tespiti ve güvenilir uyarı sistemlerinin oluşturulması için önemli bir avantaj sunmaktadır.

## 5. GELECEK ÇALIŞMALAR

Gelecekte YOLOv8'in performansı daha geniş bir veri seti ile değerlendirilecektir. Bu veri seti kara araçları ve deniz taşıtları gibi ek veri kategorilerinin entegrasyonu ile genişletilebilir. Ayrıca veri seti insansız hava araçları, kara araçları ve deniz taşıtlarını içeren görüntüler eklenerek zenginleştirilecektir. Bu araç kategorilerindeki çeşitliliğin artırılması, YOLOv8'in etkinliğini artıracak ve modelin daha geniş bir senaryo yelpazesinde uygulanabilir olmasını sağlayacaktır.





## 6. SONUÇLAR VE ÖNERİLER

Bu çalışma YOLOv8'in yüksek performans gösterdiğini ve kullanılan belirli veri setinde başarılı sonuçlar elde ettiğini sonuçlandırmaktadır. Modelin performansını artırmak için çeşitli artırma teknikleri uygulanmış ve hiper parametrelerde ayarlamalar yapılmıştır; belirli öneriler geliştirilmiştir. Dönme ve bulanıklaştırma artırma yöntemlerinin bu veri seti için uygun olduğu ve model performansını artırdığı gösterilmiştir. Optimal değerler önerilmiş ve bunların etkileri sergilenmiştir. Bu ayarlamalar, YOLOv5, YOLOv4 ve YOLOv3 gibi diğer popüler ve benzer derin öğrenme modelleri ile karşılaştırılmış ve YOLOv8'in aynı belirli veri setinde onlardan daha iyi performans gösterdiği ortaya konmuştur. Gelecek çalışmalar için, insansız hava aracı tespiti konusundaki YOLOv8'in performansını keşfetmek, çeşitli veri setleri kullanmayı içerebilir. Veri setinin kapsamının daha geniş bir senaryo ve karmaşıklık yelpazesini kapsayacak şekilde genişletilmesi, modelin daha kapsamlı bir şekilde eğitilmesini sağlayacaktır.

Bu kıyaslamalar ışığında, YOLOv8 modeli, insansız hava aracı tespiti için kullanılan diğer yöntemlere göre doğruluk, hız ve gerçek zamanlı uygulamalarda verimlilik gibi açılardan öne çıkmaktadır. YOLOv8'in diğer modellerle karşılaştırıldığında yüksek kesinlik oranları sunması, insansız hava aracı tespiti gibi güvenlik odaklı uygulamalarda tercih edilmesinin temel nedenlerinden biridir. Mask R-CNN gibi ileri düzey modeller yüksek kesinlik sağlamasına rağmen, işleme hızı açısından daha yavaş kalmaktadır. Geleneksel algoritmalar ise, hız ve kesinlik oranlarının günümüz güvenlik gereksinimlerini karşılamada yetersiz kaldığını göstermektedir. Bu nedenle, YOLOv8'in sunduğu hız, kesinlik ve düşük hesaplama maliyeti özellikleri, modelin güvenlik ve savunma uygulamalarında tercih edilen bir çözüm olmasını sağlamaktadır.



## KAYNAKLAR

1. Mohsan, S. A. H., Khan, M. A., Noor, F., Ullah, I., ve Alsharif, M. H. (2022). Towards the Unmanned Aerial Vehicles (UAVs): A comprehensive review. *Drones*, 6(6), 147.
2. Niu, R., Zhi, X., Jiang, S., Gong, J., Zhang, W., ve Yu, L. (2023). Aircraft target detection in Low Signal-to-Noise ratio visible remote sensing images. *Remote Sensing*, 15(8), 1971.
3. Sivakumar, M., ve Tyj, N. M. (2021). A literature survey of unmanned aerial vehicle usage for civil applications. *Journal of Aerospace Technology and Management*, 4(2), 13.
4. Udeanu, G., Dobrescu, A., ve Oltean, M. (2016). Unmanned aerial vehicle in military operations. *Scientific Research and Education in the Air Force*, 18(1), 199–206.
5. Pedrozo, S. (2017). Swiss military drones and the border space: a critical study of the surveillance exercised by border guards. *Geographica Helvetica*, 72(1), 97–107.
6. Zheng, Z., Lei, L., Sun, H., ve Kuang, G. (2020, 10-12 July). *A review of remote sensing image object detection algorithms based on deep learning*. 2020 IEEE 5th International Conference on Image, Vision and Computing (ICIVC), Beijing, 34–43.
7. Elsayed, M., Reda, M., Mashaly, A. S., ve Amein, A. S. (2021, 05-07 December). *Review on Real-Time drone detection based on Visual Band Electro-Optical (EO) sensor*. 2021 Tenth International Conference on Intelligent Computing and Information Systems (ICICIS), Cairo, 57-65.
8. Basak, S., Rajendran, S., Pollin, S., ve Scheers, B. (2021). Combined RF-Based Drone Detection and Classification. *IEEE Transactions on Cognitive Communications and Networking*, 8(1), 111–120.
9. Ren, S., He, K., Girshick, R., ve Sun, J. (2016). Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 39(6), 1137–1149.
10. Li, J., Hummel, R., Stoica, P., ve Zelnio, E. G. (2013). *Radar Signal Processing and its applications*. (14). New York: Springer, 140.
11. Simonyan, K., ve Zisserman, A. (2014). Very deep convolutional networks for Large-Scale image recognition. *Computer Vision and Pattern Recognition*, 6(1), 2-3.
12. Anwar, M. Z., Kaleem, Z., ve Jamalipour, A. (2019). Machine Learning inspired Sound-Based Amateur Drone Detection for public safety applications. *IEEE Transactions on Vehicular Technology*, 68(3), 2526–2534.
13. Liu, B., ve Luo, H. (2022). An improved Yolov5 for Multi-Rotor UAV detection. *Electronics*, 11(15), 2330.
14. Terven, J., Córdova-Esparza, D., ve Romero-González, J. (2023). A comprehensive review of YOLO architectures in computer vision: from YOLOV1 to YOLOV8 and YOLO-NAS. *Machine Learning and Knowledge Extraction*, 5(4), 1680–1716.

15. Coluccia, A., Fascista, A., Schumann, A., Sommer, L., Ghenescu, M., Piatrik, T., De Cubber, G., Nalamati, M., Kapoor, A., Saqib, M., Sharma, N., Blumenstein, M., Magoulianitis, V., Ataloglou, D., Dimou, A., Zarpalas, D., Daras, P., Craye, C., Ardjoune, S., . . . Gonzalez, I. (2019, 19-21 September). *Drone-vs-Bird Detection Challenge at IEEE AVSS2019*. 2019 16th IEEE International Conference on Advanced Video and Signal Based Surveillance (AVSS), Taipei, 1-8.
16. Mahdavi, F., ve Rajabi, R. (2020, 23-24 December). *Drone detection using convolutional neural networks*. 2020 6th Iranian Conference on Signal Processing and Intelligent Systems (ICSPIS), Mashhad, 1-5.
17. Wisniewski, M., Rana, Z. A., ve Petrunin, I. (2022). Drone model classification using convolutional neural network trained on synthetic data. *Journal of Imaging*, 8(8), 218.
18. Demir, B., Ergunay, S., Nurlu, G., Popovic, V., Ott, B., Wellig, P., Thiran, J., ve Leblebici, Y. (2020). Real-time high-resolution omnidirectional imaging platform for drone detection and tracking. *Journal of Real-Time Image Processing*, 17(5), 1625–1635.
19. Seidaliyeva, U., Akhmetov, D., Ilipbayeva, L., ve Matson, E. T. (2020). Real-Time and Accurate Drone Detection in a Video with a Static Background. *Sensors*, 20(14), 3856.
20. Al-Qubaydhi, N., Alenezi, A., Alanazi, T., Senyor, A., Alanezi, N., Alotaibi, B., Alotaibi, M., Razaque, A., Abdelhamid, A. A., ve Alotaibi, A. (2022). Detection of unauthorized unmanned aerial vehicles using YOLOV5 and transfer learning. *Electronics*, 11(17), 2669.
21. Wang, H., Yang, H., Chen, H., Wang, J., Zhou, X., ve Xu, Y. (2024). A remote sensing image target detection algorithm based on improved YOLOV8. *Applied Sciences*, 14(4), 1557.
22. Millington, I., ve Funge, J. (2009). *Artificial Intelligence for Games*. (2). London: CRC Press, 4.
23. Mosavi, A., ve Varkonyi-Koczy, A. R. (2017). *Recent Global Research and Education: Technological Challenges*. (519). New York: Springer, 349–355.
24. Nilson, N. J. (1998). *Introduction to machine learning*. Yayınlanmamış Yüksek Lisans Tezi, Department of Computer Science Stanford University, Stanford.
25. LeCun, Y., Bengio, Y., ve Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436-444.
26. KAYAALP, K., ve SÜZEN, A. A. (2018). *Derin Öğrenme ve Türkiye'deki Uygulamaları*. Adıyaman: İKSAD Yayınevi, 25-28.
27. Süberk, N. T. (2019). *Deep learning techniques for building density estimation from remotely sensed imagery*. Yayınlanmamış Yüksek Lisan Tezi, Işık Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.

28. Şeker, A., Diri, B., ve Balık, H. H. (2017). Derin öğrenme yöntemleri ve uygulamaları hakkında bir inceleme. *Gazi Mühendislik Bilimleri Dergisi*, 3(3), 47-64.
29. Ivakhnenko, A. G., ve Lapa, V. G. (1966). *Cybernetic Predicting Devices*. (1). New York: CCM Information Corporation, 5-17.
30. Fukushima, K. (1980). Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position. *Biological cybernetics*, 36(4), 193-202.
31. LeCun, Y., ve Bengio, Y. (1995). Convolutional networks for images, speech, and time series. *The handbook of brain theory and neural networks*, 3361(10), 1995.
32. Nielsen, M. (2015). *Neural networks and deep learning*. (5). San Francisco: San Francisco Information Corporation, 34-57.
33. Hochreiter, S. (1997). Long Short-term Memory. *Neural Computation MIT-Press*, 1735-1780.
34. Karpathy, A., ve Fei-Fei, L. (2015). *Deep visual-semantic alignments for generating image descriptions*. Proceedings of the IEEE conference on computer vision and pattern recognition, Boston, 3128-3137.
35. Graves, A., ve Schmidhuber, J. (2005, 31 July-04 August). *Framewise phoneme classification with bidirectional LSTM networks*. Proceedings of the IEEE International Joint Conference on Neural Networks, Montreal, 2047-2052.
36. Pervan, N. (2019). *Derin öğrenme yaklaşımları kullanarak Türkçe metinlerden anlamsal çıkarım yapma*. Yüksek Lisans Tezi, Ankara Üniversitesi Fen Bilimleri Enstitüsü, Ankara.
37. Greff, K., Srivastava, R. K., Koutník, J., Steunebrink, B. R., ve Schmidhuber, J. (2016). LSTM: A search space odyssey. *IEEE transactions on neural networks and learning systems*, 28(10), 2222-2232.
38. Hinton, G. (2014). Encyclopedia of Machine Learning and Data Mining. *Springer*, 1-7.
39. Karathanasopoulos, A. (2017). Modelling and trading commodities with a new deep belief network. *Modelling and trading commodities with a new deep belief network*, 28-34.
40. Sonka, M., Hlavac, V., ve Boyle, R. (2013). Image processing, analysis and machine vision. *Springer*, 13-19.
41. Zhang, H., Cisse, M., Dauphin, Y. N., ve Lopez-Paz, D. (2017). Beyond Empirical Risk Minimization. *arXiv*, 2(5), 3-12.
42. Wang, X., Gao, H., Jia, Z., ve Li, Z. (2023). BL-YOLOv8: An improved road defect detection model based on YOLOv8. *Sensors*, 23(20), 8361

43. Liu, Z., Mao, H., Wu, C. Y., Feichtenhofer, C., Darrell, T., ve Xie, S. (2022, 19-24 June). *A convnet for the 2020s*. Proceedings of the IEEE/CVF conference on computer vision and pattern recognition, New Orleans, 11976-11986.
44. İnternet: Kanyike, R. (2012). History of US drones. URL: <https://understandingempire.wordpress.com/2-0-a-brief-history-of-u-s-drones/>, Eriřim Tarihi: 17.08.2024.
45. Kumar, B. S. S., ve Wani, I. A. (2024). Realtime Drone Detection Using YOLOv8 and TensorFlow. JS. *Journal of Engineering Sciences*, 15(02), 101-108.
46. İnternet: Özel, M. (2020). Drone Dataset (UAV). URL: <https://www.kaggle.com/datasets/dasmehdixtr/drone-dataset-uav>, Eriřim Tarihi: 24.04.2024.
47. Wu, Q., Feng, D., Cao, C., Zeng, X., Feng, Z., Wu, J., ve Huang, Z. (2021). Improved mask R-CNN for aircraft detection in remote sensing images. *Sensors*, 21(8), 2618.



*Gazili olmak ayrıcalıktır*