

**RADAR VERİLERİNDEN DERİN ÖĞRENME İLE DRON,
ARAÇ VE İNSANLARIN GERÇEK ZAMANLI TESPİTİ VE
SINIFLANDIRILMASI**

**REAL-TIME DETECTION AND CLASSIFICATION OF
DRONES, VEHICLES AND HUMANS FROM RADAR DATA
USING DEEP LEARNING**

AHMET GÜNEY ŞENOCAKLI

PROF. DR. SENİHA ESEN YÜKSEL ERDEM

Danışman

Hacettepe Üniversitesi

Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliğinin

Elektrik ve Elektronik Mühendisliği Anabilim Dalı için Öngördüğü

YÜKSEK LİSANS TEZİ olarak hazırlanmıştır.

Haziran 2025

ÖZET

RADAR VERİLERİNDEN DERİN ÖĞRENME İLE DRON, ARAÇ VE İNSANLARIN GERÇEK ZAMANLI TESPİTİ VE SINIFLANDIRILMASI

Ahmet Güney Şenocaklı

Yüksek Lisans, Elektrik ve Elektronik Mühendisliği

Danışman: Prof. Dr. Seniha Esen YÜKSEL ERDEM

Mayıs 2025, 113 sayfa

Bu tez, *RAD-DAR* menzıl-Doppler veri kümesinden türetilen radar görüntülerini kullanarak **dron**, **araba** ve **insan** hedeflerinin gerçek zamanlı tespitini ve sınıflandırılmasını amaçlamaktadır. İlk aşamada, mekânsal özellikleri çıkarmak üzere temel bir **CNN** mimarisi kurulmuş; ardından zamansal bağımlılıkları yakalamak için **CNN-LSTM** modeli tasarlanmış ve dikkat mekanizması ile desteklenmiştir. Üçüncü aşamada, radar ısı haritalarına uyarlanan **YOLOv8** nesne tespit çerçevesi ile hem sınıflandırma hem de hassas konum belirleme gerçekleştirilmiştir. Son olarak, Transformer tabanlı **RT-DETR** modeli eğitilerek IoU-duyarlı sorgu seçimi ve *verimli hibrit kodlayıcı* yapıları sayesinde tüm sınıflarda en yüksek doğruluk ve hatasız dron tespiti elde edilmiştir. Gürültü, düşük çözünürlük ve sınıflar arası imza benzerliği gibi radar kaynaklı zorluklar; normalizasyon, sabit renk ölçekli ısı haritaları ve derin öğrenmenin otomatik özellik çıkarımıyla bastırılmıştır. Deneysel sonuçlar, %99'un üzerinde doğruluk ve kesinlik değerleriyle **RT-DETR**'in genel olarak en başarılı yöntem olduğunu; **YOLOv8**'in yüksek hız ve konumlama yetenekleriyle pratik uygulamalarda güçlü bir alternatif sunduğunu; **CNN-LSTM**'nin zamansal örüntülerde üstünlük sergilediğini; basit **CNN** yaklaşımının ise kaynak kısıtlı

senaryolarda uygulanabilirliğini koruduğunu ortaya koymuştur. Böylece derin öğrenme ve radar teknolojisinin birleşimiyle yüksek doğrulukta, gerçek zamanlı ve çok yönlü bir hedef tespit sistemi geliştirilebileceği gösterilmiştir.

Anahtar Kelimeler: Radar Görüntüleme, Menzil-Doppler Analizi, Dron Tespiti, Evrişimli Sinir Ağları (CNN), Uzun Kısa Süreli Bellek (LSTM), YOLOv8, RT-DETR, Transformer, Nesne Tespiti, Zamansal Modelleme, Gerçek Zamanlı İzleme



ABSTRACT

REAL-TIME DETECTION AND CLASSIFICATION OF DRONES, VEHICLES AND HUMANS FROM RADAR DATA USING DEEP LEARNING

Ahmet Güney Şenocaklı

Master of Science, Department of Electrical and Electronics Engineering

Supervisor: Prof. Dr. Seniha Esen YÜKSEL ERDEM

Haziran 2025, 113 pages

This thesis targets the real-time detection and classification of **drones**, **cars**, and **humans** in range–Doppler radar imagery derived from the *RAD-DAR* dataset. A four-stage deep-learning pipeline is proposed. First, a baseline **CNN** automatically extracts spatial features. Second, temporal dependencies are modelled with a **CNN-LSTM** architecture enhanced by an attention mechanism. Third, the **YOLOv8** object-detection framework is adapted to radar heat-maps, enabling simultaneous classification and precise localisation. Finally, a Transformer-based **RT-DETR** detector is trained; thanks to its IoU-aware query selection and efficient hybrid encoder, it achieves the highest overall accuracy and flawless drone recognition.

Radar-specific challenges such as noise, low resolution and inter-class signature overlap are mitigated through normalisation, fixed colormap heat-maps and the automatic feature-learning capability of deep networks. Experiments surpass 99% accuracy and precision, showing that **RT-DETR** is the best-performing model, while **YOLOv8** offers superior speed and bounding-box quality, **CNN-LSTM** excels in temporal

pattern exploitation, and the lightweight **CNN** remains attractive for resource-constrained deployments. Overall, the study demonstrates that combining radar sensing with modern deep learning yields a highly accurate, real-time and versatile target-detection system.

Keywords: Radar Imaging, Range–Doppler Analysis, Drone Detection, Convolutional Neural Networks (CNN), Long Short-Term Memory (LSTM), YOLOv8, RT-DETR, Transformer, Object Detection, Temporal Modelling, Real-Time Surveillance



TEŞEKKÜR

Bu tez, önemli zorluklar ve başarılar ile dolu bir yolculuğun doruk noktasını temsil etmektedir. Bu süreç boyunca bana destek olan ve rehberlik eden herkese derin bir minnettarlık duyuyorum.

Her şeyden önce, danışmanım Prof. Dr. Seniha Esen Yüksel Erdem'e, paha biçilmez rehberliği, desteği ve bilgi paylaşımı için içten teşekkürlerimi sunmak isterim. Kendisinin teşvik edici yaklaşımı ve yapıcı geri bildirimleri bu çalışmayı tamamlamamda çok önemli rol oynamıştır.

Her zaman yanımda olan, sabırları, sevgileri ve desteğiyle en büyük motivasyon kaynağım olan ailem ve kız arkadaşım; babam Şener Şenocaklı, annem Reyhan Şenocaklı'ya, kardeşim Deniz Şenocaklı'ya ve sevgili kız arkadaşım Selen Akyol'a en derin şükranlarımı sunuyorum. Bana olan inançları, en zorlu anlarda dayanma gücü verdi.

ASELSAN'daki ekip arkadaşlarıma da sürekli destekleri ve motivasyonları için teşekkür etmek isterim. Katkıları ve rehberliği için Ayşegül Güleriyüz'e, Yıldız Ebru Çetin Yıldırım'a, Dr. Alaettin Zubaroğlu'na, Kerem Tütüncüoğlu'na, Mert Paşa Çukur'a, Okan Çalış'a, Duygu Dil'e, Elif Gaye Aytekin'e, Orhun Oktar'a, Burak Yücel'e, Emir Un'a ve Hüseyin Totan'a teşekkür ederim.

Ayrıca, bu yolculuk boyunca yanımda olan, desteğini ve dostluğunu esirgemeyen kıymetli arkadaşlarıma da gönülden teşekkür ederim. Onur Parlak'a, Anıl Karaca'ya, Begüm Yelekin'e, Elif Sadıkoğlu'na, Azra Defne Eroğlu'na, Batu Torun'a, Bora Baş'a, Ali Özer'e, Boran Karaçalık'a teşekkür ediyorum.

Haziran 2025

Ahmet Güney Şenocaklı

İÇİNDEKİLER

	<u>Sayfa</u>
ÖZET	i
ABSTRACT	iii
TEŞEKKÜR	v
İÇİNDEKİLER	vi
TABLolar	ix
ŞEKİLLER	x
KISALTMALAR	xii
1. GİRİŞ	1
1.1. Dron Tespitinin Önemi	1
1.2. Tezin Kapsamı	5
1.3. Katkılar	6
1.4. Tezin Organizasyonu	7
2. TEMEL KAVRAMLAR ve VERİ KÜMESİ	8
2.1. Radar Görüntüleri	8
2.1.1. Temel Kavramlar	9
2.1.2. Radar Görüntü Türleri	9
2.1.3. Matematiksel Temsil	9
2.1.4. Radar Görüntülerinin Yorumlanması	11
2.2. Radar Görüntüsü Oluşturma ve Sinyal İşleme Adımları	11
2.2.1. Sinyal İletimi (FMCW)	12
2.2.2. Sinyalin Alınması ve Karıştırma	12
2.2.3. Analog-Dijital Dönüşüm	13
2.2.4. Hızlı Zaman FFT ve Menzil Çıkartımı	14
2.2.5. Yavaş Zaman FFT ve Hız Çıkartımı	14
2.2.6. Işın Şekillendirme (Beamforming)	15
2.2.7. Tek Darbe İşleme (Monopulse Processing)	16
2.2.8. Menzil ve Hız Tahmini	17

2.2.9. Menzil-Doppler Haritasının Oluşturulması	17
2.2.10. Hedef Tespiti ve CFAR Algoritmaları Kullanılarak Çıkarım	18
2.3. Radar Görüntüsü Oluşturmak İçin Alternatif Yöntemler	19
2.3.1. Darbe-Doppler Radarı	20
2.3.2. Sentetik Açıklıklı Radar (SAR)	20
2.4. RAD-DAR Veri Kümesi.....	20
2.4.1. Genel Bakış	20
2.4.2. Kayıt Ortamı ve Kurulum	21
2.4.3. Dron Verilerinin Toplanması	22
2.4.4. Veri Kümesi İstatistikleri	23
2.4.5. RAD-DAR Veri Kümesinin Güçlü Yönleri	23
2.4.6. RAD-DAR Veri Kümesinin Sınırlamaları	25
2.5. YOLO ve RT-DETR İçin RAD-DAR Veri Kümesinden Görüntü Üretimi	26
2.5.1. RAD-DAR Veri Kümesinde Yüksek ve Düşük SNR Örnekleri	27
3. İLGİLİ ÇALIŞMALAR	30
3.1. Dron Tespiti, Tarihsel Bağlam ve Gelişim Süreci	30
3.2. Makine Öğrenmesi ile Dron Tespiti	31
3.3. Radar Görüntüleri ile Dron Tespiti	33
4. YÖNTEMLER	38
4.1. Evrişimli Sinir Ağı (CNN)	39
4.1.1. Veri Yükleme ve Ön İşleme	39
4.1.2. CNN Modelinin Mimarisi	40
4.1.3. Model Performans Ölçütleri	44
4.2. CNN ile LSTM ve Dikkat Mekanizması (Attention Mechanism).....	44
4.2.1. LSTM Katmanlarının Entegrasyonu ve Ayrıntılı Analizi	46
4.2.2. Pozisyon Yanlı Dikkat Katmanı	48
4.3. Radar Görüntüleri için YOLO Nesne Tespiti	50
4.3.1. YOLO Algoritmasının Genel Özeti	50
4.3.2. Uygulama Detayları.....	53
4.3.3. Radar Görüntülerinde YOLO ile Dron Tespiti Entegrasyonu.....	54

4.4. RT-DETR ile Radar Görüntülerinde Nesne Tespiti	55
4.4.1. RT-DETR Mimarisi ve Temel Bileşenleri	55
4.4.2. RT-DETR Modelinin Uygulaması.....	58
5. DENEYSEL SONUÇLAR	59
5.1. CNN Sonuçları ve Performans Analizi	60
5.1.1. Uyumsuz Eşleştirme Örnekleri	62
5.2. CNN-LSTM-Attention Modeli Sonuçları ve Performans Analizi.....	63
5.2.1. Dikkat Mekanizmasının Öğrendiği Bilgiler	66
5.2.2. Uyumsuz Eşleştirme Örnekleri	67
5.3. YOLOv8 Sonuçları ve Performans Analizi	68
5.3.1. Eğitim Metrikleri.....	68
5.3.2. Uyumsuz Eşleştirme Örnekleri	71
5.3.3. Test Sonuçları	72
5.4. RT-DETR Sonuçları ve Performans Analizi	75
5.4.1. Eğitim Metrikleri.....	75
5.4.2. Test Sonuçları	78
6. SONUÇLAR VE KARŞILAŞTIRMA	79
6.1. Geliştirilen Yöntemlerin Karşılaştırması	80
6.1.1. Genel Karşılaştırma	80
6.1.2. Gözlemler	81
6.2. Yöntemlerimizin Diğer Çalışmalarla Karşılaştırılması	82
6.2.1. DopplerNet ile Performans Karşılaştırması.....	82
6.2.2. YOLO-RD ile Karşılaştırma	84
6.2.3. Radar Zamanlama ve Range-Doppler Spektral Hedef Tespiti ile Karşılaştırma	85
6.2.4. Özet ve Genel Değerlendirme	86
6.3. Sonuç ve Gelecek Çalışmalar	87

TABLÖLAR

	<u>Sayfa</u>
Tablo 1.1 İHA Tespit Yöntemleri.....	4
Tablo 3.1 Literatürdeki Çalışmaların Veri Kümesi Özellikleri	38
Tablo 5.1 Radar Veri Kümesi Üzerinde CNN Performans Ölçütleri.....	62
Tablo 5.2 Radar Veri Kümesi Üzerinde CNN–LSTM–Attention Performans Ölçütleri	64
Tablo 5.3 Radar Görüntü Veri Kümesi Üzerinde YOLOv8 Performans Ölçütleri .	72
Tablo 5.4 Radar Görüntü Veri Kümesi Üzerinde RT–DETR Performans Ölçütleri	79
Tablo 6.1 Modellerin Radar Görüntülerindeki Nesne Sınıflandırma Performanslarının Karşılaştırılması	80
Tablo 6.2 RT–DETR ve YOLO-RD Modellerinin RAD-DAR / Mini-RD Kümelerindeki Ana Tespit Ölçütleri	85

ŞEKİLLER

	<u>Sayfa</u>
Şekil 1.1 Geleneksel Döner Kanatlı Dron - DJI Phantom 3	2
Şekil 1.2 Gatwick Havaalanı Olayında Yer Alan Şüpheli Döner Kanatlı Dron [1]	3
Şekil 2.1 FMCW Radar için Sinyal İşleme ve Görüntü Oluşturma Adımları.....	12
Şekil 2.2 Hızlı Zaman ve Yavaş Zaman FFT Süreçlerinin Temsili	15
Şekil 2.3 Ortalama Hücre Sabit Yanlış Alarm Oranı (CA-CFAR) Algoritması [2]	19
Şekil 2.4 RAD-DAR Veri Kümesi için Yerdeki Güzergahlar [3].....	21
Şekil 2.5 RAD-DAR Veri Kümesi için Saha Testi Kurulumu [3]	22
Şekil 2.6 Radar Veri Görselleştirmelerinin Karşılaştırması, Menzıl-Doppler Yoğunluk Desenlerindeki Farklılıklar	29
Şekil 3.1 Mikro-Doppler Veri Kümeleri: Farklı Dron Türleri ve Uçan Kuşlara Ait Zaman-Frekans (T-F) Grafikleri, Menzıl Profilleri ve Menzıl-Zaman Grafikleri [4].....	35
Şekil 4.1 .csv Formatında İşlenmemiş Araç Verisinin İlk 11x9 Örneği	39
Şekil 4.2 CNN Modelinin Mimarisi	41
Şekil 4.3 CNN Modelinin Ara Çıktı Boyutları	42
Şekil 4.4 CNN-LSTM-Dikkat Mimarisinin Blok Diyagramı.....	45
Şekil 4.5 CNN-LSTM-Dikkat Modeline Ait Ara Katman Boyutları.....	46
Şekil 4.6 YOLOv8 Blok Diyagram	50
Şekil 4.7 RT-DETR Blok Diyagram	56
Şekil 5.1 CNN Modeli İçin 50 Epok Boyunca Eğitim Kaybı ve Doğruluk Eğrisi	60
Şekil 5.2 CNN Modelinin Araçlar, Dronlar ve İnsanlar Sınıflarında Sınıflandırma Performansını Gösteren Karmaşıklık Matrisi	61
Şekil 5.3 CNN Uyumsuz Eşleştirme Örnekleri	62
Şekil 5.4 CNN-LSTM-Attention Modeli İçin 40 Epok Boyunca Eğitim Kaybı ve Doğruluk Eğrileri	63

Şekil 5.5	CNN-LSTM-Attention modelinin Araçlar, Dronlar ve İnsanlar Sınıflarında Sınıflandırma Performansını Gösteren Karmaşıklık Matrisi	65
Şekil 5.6	CNN-LSTM-Attention Modeli İçin Dikkat Ağırlıklarının Görselleştirilmesi.....	66
Şekil 5.7	CNN-LSTM-Attention Modeli Uyumsuz Eşleştirme Örnekleri	67
Şekil 5.8	YOLOv8 Modeli İçin Eğitim Kayıp metrikleri (Box Loss, Class Loss ve DFL Loss)	69
Şekil 5.9	YOLOv8 Modeli İçin mAP Metrikleri (mAP@50 ve mAP@50-95)...	69
Şekil 5.10	YOLOv8 İçin Eğitim Sırasında Kesinlik ve Geri Çağırma Eğrileri	70
Şekil 5.11	YOLOv8 Uyumsuz Eşleştirme Örnekleri	71
Şekil 5.12	YOLOv8 İçin F1-Güven Skoru Eğrisi	72
Şekil 5.13	YOLOv8 İçin Precision-Recall Eğrisi	73
Şekil 5.14	YOLOv8 için Karmaşıklık Matrisi	74
Şekil 5.15	RT-DETR İçin Epok Kayıp Eğrileri	75
Şekil 5.16	Epok Bazında Kesinlik ve Geri Çağırma Eğrileri	76
Şekil 5.17	RT-DETR İçin Sınıf Bazlı Kesinlik-Geri Çağırma Eğrileri	77
Şekil 5.18	RT-DETR Modeli için F1-Güven Skoru Eğrisi	77
Şekil 5.19	RT-DETR Modeli Karmaşıklık Matrisi	78
Şekil 6.1	DopplerNet Modeline Ait Karmaşıklık Matrisi	83
Şekil 6.2	Çalışmamızdaki RT-DETR Modeline Ait Karmaşıklık Matrisi	84

KISALTMALAR

AP	: Average Precision
CNN	: Convolutional Neural Network
FMCW	: Frequency-Modulated Continuous-Wave (radar)
FPS	: Frames Per Second
F1	: Harmonik ortalamalı F1 skoru (kesinlik–geri çağırma)
IoU	: Intersection-over-Union
LSTM	: Long Short-Term Memory
mAP	: mean Average Precision
RAD-DAR	: Range–Doppler Radar veri kümesi
RCS	: Radar Cross-Section
RT-DETR	: Real-Time DEtection TRansformer
SNR	: Signal-to-Noise Ratio
YOLO	: You Only Look Once
YOLOv8	: Sekizinci sürüm YOLO nesne dedektörü
IoU	: Intersection-over-Union (Kesişim/Birleşim Oranı)

1. GİRİŞ

Bu bölümde, yetkisiz İHA faaliyetlerinin yarattığı güvenlik riskleri vurgulanarak döner kanatlı dron tespitinin neden kritik olduğu açıklanmıştır. Mevcut algılama teknolojilerinin (optik, RF, akustik vb.) kısıtları özetlenmiş ve radar tabanlı yaklaşımların öne çıkma gerekçesi tartışılmıştır. Ardından, radar menzıl-Doppler verilerinin derin öğrenme ile işlenmesine yönelik literatürdeki boşluk tanımlanmıştır ve bu tezde önerilen CNN (Evrışimli Sinir Ağları), CNN-LSTM-Attention (Evrışimli Sinir Ağları-Uzun Kısa Süreli Bellek-Dikkat), YOLOv8 (You Only Look Once) ile RT-DETR (Gerçek Zamanlı Algılama Dönüştürücüsü) temelli bütüncül çerçevenin hedefleri sunulacaktır. Son olarak, çalışmanın temel katkıları ve tezin kalan bölümlerinin organizasyonuna kısaca değinilecektir. Bu kısımdan itibaren bahsi geçen dron, her zaman döner kanatlı dron olacaktır.

1.1. Dron Tespitinin Önemi

İnsansız hava araçlarının (İHA), yaygın olarak bilinen adıyla dronların (döner kanatlı dron), hızla yaygınlaşması: Tarım, güvenlik, medya ve lojistik gibi çeşitli sektörleri dönüştürerek yeni fırsatlar sunmuştur. Ancak, bu yaygın kullanım aynı zamanda önemli güvenlik sorunlarını da beraberinde getirmiştir. Yetkisiz dron faaliyetleri, mahremiyet ihlallerinden casusluğa, hava trafiğiyle etkileşimden kaçakçılığa kadar çeşitli tehditler oluşturmaktadır [3, 5]. Bu ortaya çıkan tehditlere karşı, güvenilir dron tespit sistemleri kamu güvenliğini sağlamak ve kritik altyapıları korumak için hayati hale gelmiştir. Bahsedilen drona örnek olarak Şekil 1.1’de geleneksel bir dron olan DJI Phantom 3’e yer verilmiştir.



Şekil 1.1 Geleneksel Döner Kanatlı Dron - DJI Phantom 3

Dronlar, geleneksel güvenlik önlemlerini aşmak, yasaklı alanlara kaçak malzeme sokmak, izinsiz gözetim yapmak ve hatta silah taşımak gibi çeşitli kötü niyetli amaçlarla kullanılmaktadır [3]. Ayrıca, dronların ticari uçuşlarla ve havaalanı operasyonlarıyla etkileşime girdiği olaylar, havacılık güvenliği konusunda ciddi endişelere yol açmıştır [6]. Bu tür olaylar, etkin dron tespit ve önleme stratejilerinin aciliyetini vurgulamaktadır.

Buna bir örnek verecek olursak, Gatwick Havalimanı'nda Aralık 2018'de yaşanan dron olayından bahsedebiliriz [1]. Bu olay havacılık güvenliği açısından önemli bir örnek teşkil etmektedir. Yetkisiz bir dronun hava sahasına girmesi nedeniyle 1000'den fazla uçuş iptal edilmiş ve yaklaşık 140.000 yolcu mağdur olmuştur. Olay, dronların havaalanları ve kritik altyapılar için oluşturabileceği riskleri gözler önüne sermiştir. Yetkililer, hava sahasını ihlal eden dronu tespit etmekte zorlanmış ve geniş çaplı bir güvenlik operasyonu yürütülmüştür. Şüpheli drona ait olduğu düşünülen bir görüntü, olay sırasında çekilen video kaydından alınmış olup, dronun kesin kimliği ve operatörüne dair kesin bir sonuca ulaşılamamıştır. Şekil 1.2'de şüpheli drona ait görsele yer verilmiştir.

Bu olay, döner kanatlı dron tespit sistemlerinin yetersizliğini göstererek radar tabanlı tespit yaklaşımlarının geliştirilmesine yönelik çalışmaları hızlandırmıştır.



Şekil 1.2 Gatwick Havaalanı Olayında Yer Alan Şüpheli Döner Kanatlı Dron [1]

Dron tespiti ve sınıflandırılması için çeşitli algılama cihazları kullanılmakta olup her biri kendine özgü avantajlar ve sınırlamalara sahiptir (bkz. Tablo 1.1). Kızılötesi kameralar uzun menzilli tespit için etkilidir ve olumsuz hava koşullarından daha az etkilenir, ancak düşük doğruluğa sahiptir. RF alıcıları dronların varlığını tespit edebilir ve operatörün yerini belirleyebilir, ancak otonom uçuşları tanımlamakta yetersiz kalmaktadır. Radar sistemleri, uzun menzilli algılama yetenekleri ve hava koşullarına karşı dayanıklılıkları sayesinde öne çıkmaktadır, ancak, maliyetli olup RF lisansları konusunda düzenleyici kısıtlamalara tabidir. Optik kameralar yüksek çözünürlükte kimlik belirleme sağlarken düşük maliyetlidir, ancak hava koşullarına oldukça duyarlıdır ve sınırlı algılama menziline sahiptir. Son olarak, akustik sensörler mini boyutlu ve RF tabanlı sensörlerle uyumlu olsa da, son derece düşük algılama menzili ve karmaşık sinyal işleme gereksinimleri nedeniyle kullanım alanları sınırlıdır.

Algılama Özelliği	Algılama Cihazı	Avantajlar	Dezavantajlar	Algılama Menzili
Isı	Kızılötesi kamera	- Hava koşullarından daha az etkilenir - Uzun menzil	Düşük doğruluk	1 – 15 km
RF Sinyali	RF alıcısı	- Engelsiz tespit - Dron operatörünü tespit edebilir	Otonom uçuşları tespit edemez	3 – 50 km
Fiziksel Nesne	Radar	- Hava koşullarından daha az etkilenir - Uzun menzil	- Yüksek maliyet - RF lisansları üzerindeki düzenleyici kısıtlamalar - Engellere karşı savunmasız	1 – 20 km
Görünürlük	Optik kamera	- Düşük maliyet - Mini boyutlu - Yüksek çözünürlüklü tanımlama	- Hava koşullarından oldukça etkilenir - Sınırlı menzil ve engellere karşı savunmasız	0.5 – 3 km
Akustik Sinyal	Akustik alıcı	- RF tabanlı sensörlerle uyumlu - Mini boyutlu	- Son derece düşük algılama menzili - Düşük doğruluk ve yüksek sinyal işleme karmaşıklığı	< 0.2 km

Tablo 1.1 İHA Tespit Yöntemleri

Radar sistemleri, uzun menzil ve farklı çevresel koşullarda nesneleri algılama yetenekleri nedeniyle dron tespiti için önde gelen bir çözüm haline gelmiştir. Ancak, dronları kuşlar gibi diğer küçük nesnelerden ayırmak önemli bir zorluk oluşturmaktadır. Geleneksel radar sistemleri, tespit edilen nesnelerin yalnızca konumunu rapor etmekte, ancak küçük dronların doğru sınıflandırılması için yeterli bilgi sağlayamamaktadır [7]. Bu sınırlama, radar tabanlı dron tespit sistemlerinde derin öğrenmenin, özellikle menzil-Doppler görüntülerini analiz edip benzersiz Doppler imzalarını tanımlayan CNN entegrasyonunu teşvik etmiştir [8].

CNN'ler yardımıyla menzil-Doppler verileri üzerinde yapılan analizler, dron tespit

doğruluğunu önemli ölçüde artırmış, yanlış pozitifleri azaltmış ve gerçek zamanlı performansı geliştirmiştir. Bu gelişmeler, hedef türü ve konumu gibi üst düzey yorumların yapılmasını sağlamış ve güvenlik ile hava sahası izleme uygulamaları için kritik hale gelmiştir. Gelecekte radar, optik ve akustik sensörleri entegre eden çok modlu sistemlerin tespit performansını ve dayanıklılığını daha da artması beklenmektedir [5].

1.2. Tezin Kapsamı

İnsansız hava araçlarının, yaygın adıyla döner kanatlı dronların, gözetim, tarım ve lojistik gibi sektörlerde hızla benimsenmesi, yetkisiz uçuşların doğurduğu kamu güvenliği ve mahremiyet risklerini de beraberinde getirmiştir [3, 5]. Küçük gövde boyutu, değişken hız-yön profili ve karmaşık çalışma ortamları radar ve optik tabanlı klasik tespit yaklaşımlarının başarı oranını düşürmektedir [7]. Bu zorluklar, derin öğrenme yöntemlerinin radar verisiyle bütünleştirilmesini öneren araştırmaları hızlandırmıştır [9, 10].

Bu tez, gerçek menzil-Doppler kayıtlarını içeren RAD-DAR veri kümesi üzerinde döner kanatlı dron, araç ve insan hedeflerinin *radar görüntülerinden* yüksek doğrulukla tespitini amaçlayan uçtan-uca bir derin öğrenme çerçevesi geliştirmektedir. Öncelikle, gürültü azaltma, yeniden ölçekleme ve sabit renk haritası ile ısı haritası oluşturma adımları uygulanarak radar güç matrisleri YOLO-uyumlu görüntülere dönüştürülmüştür [3, 11]. Ardından dört mimari tasarlanıp eğitilmiştir:

1. **CNN** – Mekânsal özellikleri doğrudan menzil-Doppler matrisinden çıkaran hafif bir temel ağ.
2. **CNN-LSTM-Attention** – Radar imzalarındaki zamansal dinamiği LSTM katmanları ve konum yanlı dikkat ile modelleyerek sıralı iyileşme sağlayan hibrit yapı.
3. **YOLOv8** – Dönüştürülmüş ısı haritalarında gerçek zamanlı bağlama kutusu tahmini ve sınıflandırma yapabilen evrimleşmiş YOLO çerçevesi.

4. **RT-DETR** – IoU (Birlik Üzerinden Kesişim)-duyarlı sorgu seçimi ve verimli hibrit kodlayıcı içeren Transformer tabanlı, uçtan-uca *DETR* yaklaşımının radar alanına ilk kez uyarlanmış sürümü [8].

Tüm modeller; doğruluk, kesinlik, geri çağırma, F_1 skoru ve mAP@50 gibi standart ölçütlerle karşılaştırılmıştır. Deneysel sonuçlar, *dron* sınıfında RT-DETR modelinin %100 kesinlik ve %100 geri çağırma ile **kusursuz** tespit gerçekleştirdiğini, YOLOv8'in ise %100 kesinlik ve %99.33 geri çağırma ile onu çok yakından izlediğini göstermektedir. CNN tabanlı yöntemler, daha düşük hesaplama maliyeti karşılığında yaklaşık %93–94 aralığında F_1 doğruluğu sunarken; CNN-LSTM-Attention modeli bu doğruluğu %95.08 seviyesine taşıyarak iyileştirme sağlamıştır. Transformer mimarisi kullanan RT-DETR'in, özellikle düşük radar kesit alanına sahip küçük hedeflerde gösterdiği sağlam tespit yeteneği, hava sahası güvenliği ve kritik altyapı koruması gibi uygulama alanlarında önemli bir ilerleme olarak öne çıkmaktadır [12].

Bu çalışma, radar tabanlı dron tespitinde derin öğrenmenin pratik üstünlüğünü nicel olarak gösterirken, hafifletilmiş Transformer tasarımları, çoklu sensör füzyonu ve senaryo çeşitliliği yüksek geniş veri kümeleri gibi gelecek araştırma yönlerine de sağlam bir temel sağlamaktadır.

1.3. Katkılar

Bu tez, radar tabanlı dron tespitine yönelik literatürdeki eksik alanları doldurmak amacıyla hem zamansal-mekânsal modellemeyi hem de gerçek-zamanlı Transformer tabanlı tespiti içeren bütüncül bir çerçeve sunmaktadır. Başlıca katkılar aşağıda özetlenmiştir:

- **Zamansal Bağımlılıkların İlk Kez RAD-DAR'da İncelenmesi:** RAD-DAR veri kümesinde ardışık menzil-Doppler kareleri kullanılarak LSTM ve konumsal önyargılı dikkat katmanlarıyla (position-biased attention mechanism) zenginleştirilmiş bir CNN-LSTM mimarisi tasarlanmış, böylece %95 üzeri doğrulukla zamansal korelasyonların sınıflandırma performansını nasıl yükselttiği gösterilmiştir.

- **YOLOv8’in Radar Görüntülerine Uyarlanması:** Isı-haritası temelli görselleştirme ve sabit renk ölçeği standardizasyonu ile YOLOv8 modeli ilk kez RAD-DAR veri kümesine başarıyla entegre edilmiştir. Güncel deneylerde model, %99.01 kesinlik, %97.56 geri çağırma ve %98.27 F_1 skoru elde ederek hem sınıflandırma hem de konumlandırma görevlerinde güçlü bir performans sergilemiş, tek-aşamalı mimarisi sayesinde gerçek-zamanlı (>30 FPS) radar hedef tespiti gerçekleştirebilmiştir.
- **RT-DETR’in Radara Taşınması:** Bu çalışma, Real-Time Detection Transformer (RT-DETR) modelini radar verisi üzerinde uygulayan *ilk* çalışmadır. Verimli hibrit kodlayıcı ve IoU-duyarlı sorgu mekanizması sayesinde, *dron* sınıfında %100 F_1 skoru elde edilmiş; genel olarak ise %99.05 F_1 skoru yakalanarak mevcut Transformer tabanlı radar yaklaşımlarının hem doğruluk hem de işlevsellik bakımından önüne geçilmiştir.
- **Açık ve Tekrarlanabilir Karşılaştırmalı Referans:** CNN, CNN-LSTM, YOLOv8 ve RT-DETR mimarilerinin ayrıntılı eğitim/test betikleri, veri hazırlama kodları ve etiket setleriyle birlikte Kaggle ortamında paylaşılmıştır. Böylece RAD-DAR üzerine gelecek araştırmalar için sağlam bir kıyas hattı ve yeniden üretilebilir bir referans noktası sunulmuştur.

Bu katkılar, radar sinyal işlemedeki klasik yaklaşımlar ile modern derin öğrenme metodolojilerini birleştirerek dayanıklı, hassas ve gerçek-zamanlı dron tespit sistemleri geliştirilmesine yönelik önemli bir adım oluşturmaktadır.

1.4. Tezin Organizasyonu

Tezin organizasyonu şu şekildedir:

Bölüm 1, tezin motivasyonunu, katkılarını ve kapsamını sunmaktadır.

Bölüm 2, radar görü”ntüleme prensipleri, RAD-DAR veri kümesi açıklaması ve sinyal işleme teknikleri ile ilgili kapsamlı bir arka plan sunmaktadır. Matematiksel temsiller ve görüntü oluşturma adımları detaylandırılmaktadır.

Bölüm 3, ilgili çalışmaları detaylıca incelemekte, radar tabanlı dron tespiti için mevcut yöntemlere ve nesne sınıflandırmasında derin öğrenme modellerinin entegrasyonuna odaklanmaktadır.

Bölüm 4, önerilen metodolojileri tanıtmakta, CNN, dikkat mekanizmalı CNN-LSTM, YOLOv8 ve RT-DETR mimarilerini RAD-DAR veri kümesi üzerindeki veri ön işleme ve eğitim stratejileriyle birlikte açıklamaktadır.

Bölüm 5, önerilen modellerin deneysel sonuçlarını ve performans analizlerini sunmaktadır. Doğruluk, kesinlik, geri çağırma ve F1 skoru gibi değerlendirme metrikleri ve karşılaştırmalı analizler yapılmaktadır.

Bölüm 6, tezin bulgularını özetleyerek, önceki çalışmalarla karşılaştırmalı sonuçları ve gelecekteki araştırma yönlerini tartışmaktadır.

2. TEMEL KAVRAMLAR ve VERİ KÜMESİ

Bu bölüm, radar tabanlı derin öğrenme yaklaşımımızı kavramsal ve teknik açıdan temellendirmek için gerekli arka planı sunar. Önce radar menzil-Doppler görüntülerinin fiziksel prensipleri, matematiksel temsili ve sinyal işleme adımları ayrıntılandırılır; ardından RAD-DAR veri kümesinin kayıt düzeni, güçlü yönleri ve kısıtları tartışılır. Son olarak, bu ham verilerin YOLOv8 ile RT-DETR modellerine uygun ısı-haritası biçimine dönüştürülme süreci ve bu modellerin değerlendirme metrikleri ele alınır.

2.1. Radar Görüntüleri

Radar görüntüleri, radar sistemleri tarafından yakalanan verileri görselleştirmek için önemli bir yöntemdir. Bu görüntüler genellikle iki boyutlu (2D) veya üç boyutlu (3D) matrisler olarak gösterilir ve her bir eleman belirli bir mesafe (menzil) ve göreceli hız (Doppler frekansı) ile ilişkilidir. Bu görüntülerdeki renk veya yoğunluk, çevredeki belirli bir noktadan alınan radar sinyalinin gücünü gösterir [7].

2.1.1. Temel Kavramlar

- **Radar Prensibi:** Radar sistemleri, elektromanyetik dalgalar yayarak bu dalgaların nesnelere çarpıp radara geri dönmesi ilkesine dayanır. Bu geri dönen sinyallerin analiz edilmesiyle nesnenin menzili, hızı ve konumu hakkında bilgi edinilir [7].
- **Menzil Ölçümü:** Hedefe olan mesafe, radar darbesinin gönderilmesi ile yankısının alınması arasındaki zaman gecikmesi (Δt) ölçülerek hesaplanır. Sürekli dalga (CW) radarında, menzil bilgisi frekans modülasyonu ile kodlanır [13].
- **Hız Ölçümü:** Alınan sinyaldeki frekans kaymasını ifade eden Doppler etkisi, hedefin göreceli hızını hesaplamak için kullanılır [14].

2.1.2. Radar Görüntü Türleri

- **Menzil Profilleri:** Alınan sinyalin çeşitli mesafeler üzerindeki gücünü gösteren tek boyutlu grafiklerdir ve tespit edilen nesnelerin basit bir görünümünü sağlar [7].
- **Menzil-Doppler Haritaları:** Bu iki boyutlu görüntüler, menzil ve hız bilgilerini birlikte gösterir ve her hücre belirli bir menzil ve hızdaki sinyal yoğunluğunu temsil eder [13].
- **Sentetik Açıklıklı Radar (SAR) Görüntüleri:** Yüksek çözünürlüklü bu iki boyutlu görüntüler, radar platformunun hareketi sırasında toplanan verilerin işlenmesiyle oluşturulur ve sahnenin ayrıntılı bir analizini sağlar [15].

2.1.3. Matematiksel Temsil

- **Alınan Sinyal:** Radar tarafından alınan sinyal $s(t)$, hem menzil hem de hız bilgilerini içerir:

$$s(t) = Ae^{j(2\pi f_c t + \phi(t) + \phi_D)}$$

Burada:

- $s(t)$: Radardan alınan kompleks zaman-alanı sinyali,
- t : Sinyalin gözlemlendiği zaman değişkeni,
- A : Alınan sinyalin genliği,
- f_c : Taşıyıcı frekans,
- $\phi(t)$: Menzile bağlı faz değişimi,
- $\phi_D = 2\pi f_D t$: Doppler kaymasına bağlı faz değişimidir.

Bu denklem, radar sistemlerinin mesafe ve hız ölçümleri için faz ve frekans değişikliklerini nasıl kullandığını göstermektedir [7], [13].

- **Sinyal Gücü:** Hedeften R mesafesinde alınan sinyal gücü P aşağıdaki denklemle ifade edilir:

$$P = \frac{P_t G_t G_r \lambda^2 \sigma}{(4\pi)^3 R^4 L}$$

Burada:

- P_t : Gönderilen güç,
- G_t ve G_r : Gönderici ve alıcı anten kazançları,
- λ : Radar sinyalinin dalga boyu,
- σ : Hedefin radar kesit alanı,
- L : Sistem kayıplarını ifade eder.

Bu denklem, gönderilen güç, mesafe ve diğer faktörlerin alınan sinyal gücünü nasıl etkilediğini göstermektedir [7].


2.1.4. Radar Görüntülerinin Yorumlanması

- **Yoğunluk:** Bir radar görüntüsündeki yoğunluk, nesnelerden yansıyan gücün miktarını gösterir. Daha yüksek yoğunluk, genellikle daha büyük veya daha yansıtıcı hedefleri ifade eder [7].
- **Menzil Eksen:** Bu eksen, radardan algılanan nesnelere olan mesafeyi gösterir. Bu eksenindeki her hücre, belirli bir mesafe aralığına karşılık gelir [13].
- **Doppler Eksen:** Doppler eksen, algılanan nesnelerin göreceli hızını gösterir. Pozitif ve negatif kaymalar, nesnelerin radara doğru mu yoksa radardan uzağa mı hareket ettiğini gösterir [14].

2.2. Radar Görüntüsü Oluşturma ve Sinyal İşleme Adımları

Frekans Modülasyonlu Sürekli Dalga (FMCW) radarlar kullanılarak radar görüntüsü oluşturma işlemi, sinyal üretiminden gelişmiş işlem tekniklerine kadar uzanan bir dizi iyi tanımlanmış adımdan oluşur. RAD-DAR veri kümesi gibi veri kümeleri için bu yöntem, doğru hedef tespiti sağlamak açısından önemlidir [16]. İşlem, düşükten yükseğe doğru frekans taraması yapan bir frekans modüleli sinyalin üretilmesi ve iletilmesiyle başlar. Sinyal bir hedefe çarptığında, hedefin menzil ve hızına ilişkin bilgileri taşıyan bir yansıma sinyali geri döner.

Şekil 2.1, bu işlemi ayrıntılı olarak göstermekte ve radar sinyal işleme sırasında kullanılan anahtar adımları vurgulamaktadır. Bu adımlar, sonraki bölümlerde detaylandırıldığı gibi hızlı zaman ve yavaş zaman Fourier dönüşümleri, Doppler ve tek darbe işleme, menzil-Doppler haritası oluşturma ve nihayetinde nesne algılama görevleri için uygun hale getirilen verilerin işlenmesini kapsamaktadır.



Şekil 2.1 FMCW Radar için Sinyal İşleme ve Görüntü Oluşturma Adımları

2.2.1. Sinyal İletimi (FMCW)

Gönderilen sinyalin matematiksel ifadesi şu şekildedir:

$$s_{tx}(t) = A_{tx} \cos(2\pi f_c t + \pi \mu t^2)$$

Burada:

- t : Sinyalin gözlemlendiği zaman değişkeni,
- A_{tx} : Sinyalin genliği,
- f_c : Başlangıç frekansı,
- $\mu = \frac{\Delta f}{T_m}$: Chirp oranı, frekansın zamanla ne kadar hızlı değiştiğini gösterir.

Bu yaklaşım, hem mesafe hem de hız ölçümlerinin hassas bir şekilde yapılmasına olanak tanır [17].

2.2.2. Sinyalin Alınması ve Karıştırma

Gönderilen FMCW sinyali bir hedeften yansıdığı anda, mesafeye bağlı olarak hafif bir gecikmeyle ($\tau = \frac{2R}{c}$) radara geri döner. Alınan sinyal şu şekilde ifade edilir:

$$s_{rx}(t) = A_{rx} \cos(2\pi f_c(t - \tau) + \pi \mu(t - \tau)^2)$$

Yararlı bilgileri çıkarmak için, bu sinyal gönderilen sinyalle karıştırılır ve ara frekans (IF) sinyali elde edilir:

$$s_{\text{IF}}(t) = s_{\text{tx}}(t) \cdot s_{\text{rx}}(t)$$

Bu işlemin sonucunda oluşan vuruş frekansı (f_b), hedefin menzili ile doğrudan ilişkilidir:

$$f_b = \mu\tau = \frac{2\mu R}{c}$$

Burada:

- f_b : Gönderilen ve alınan sinyaller arasındaki frekans farkını temsil eden vuruş frekansı,
- μ : Chirp oranı,
- τ : Sinyalin hedefe gidip dönmesi için geçen süre,
- R : Hedefin menzili,
- c : Işığın boşluktaki hızı.

Bu işlem, radarın hedefin mesafesini belirlemesine olanak tanır [16].

2.2.3. Analog-Dijital Dönüşüm

Analog ara frekans (IF) sinyali, Analog-Dijital Dönüşüm (ADC) sırasında dijital formata dönüştürülür. Bu adım, sürekli analog sinyalin dijital bir temsil haline getirilmesini sağlayarak, Fourier dönüşümleri, Doppler işleme ve menzil-Doppler haritası oluşturma gibi dijital sinyal işleme operasyonlarının temelini oluşturur [13].

2.2.4. Hızlı Zaman FFT ve Menzil Çıkartımı

Radar sinyal işleme, örneklenmiş ara frekans (IF) sinyalinin *Hızlı Zamanlı Hızlı Fourier Dönüşümü (FFT)*'ne tabi tutulmasıyla başlar. Bu işlem, her bir chirp için sinyali zaman alanından frekans alanına dönüştürür. Hızlı Zaman FFT çıktısı, frekans spektrumu üretir ve her frekans hücresi belirli bir menzil ile ilişkilidir. Menzil, R , aşağıdaki denklemle hesaplanır:

$$R = \frac{f_b c}{2\mu} \quad (1)$$

Burada:


- f_b : FFT çıktısından çıkarılan vuruş frekansı,
- c : Işığın boşluktaki hızı,
- μ : Chirp oranı ($\mu = \frac{\Delta f}{T_m}$) olup, Δf frekans süpürmesini ve T_m chirp süresini ifade eder.

Hızlı Zaman FFT, radar sinyalinin çeşitli mesafelerdeki yoğunluğunu gösteren tek boyutlu bir menzil profili sağlar.

Şekil 2.2, Hızlı Zaman ve Yavaş Zaman FFT süreçlerini temsil etmektedir. Hızlı Zaman FFT, tek bir chirp içindeki sinyali analiz ederek menzil profili çıkarırken, Yavaş Zaman FFT, Doppler kaymalarını çıkarmak için bu verileri birden fazla chirp boyunca işler ve algılanan nesnelerin hızını belirler.

2.2.5. Yavaş Zaman FFT ve Hız Çıkartımı

Menzil bilgisi elde edildikten sonra, birden fazla chirp üzerinde *Yavaş Zamanlı Hızlı Fourier Dönüşümü (FFT)* uygulanır. Yavaş Zaman FFT, zaman içindeki faz ve frekans



Şekil 2.2 Hızlı Zaman ve Yavaş Zaman FFT Süreçlerinin Temsili

değişikliklerini analiz ederek Doppler frekansı kaymalarını (f_D) tespit eder ve hedefin göreceli hızını belirler. Radyal hız v , şu denklemle hesaplanır:

$$v = \frac{f_D \lambda}{2} \quad (2)$$

Burada:

- f_D : Yavaş Zaman FFT çıktısından elde edilen Doppler frekans kayması,
- λ : Radar sinyalinin dalga boyudur.

Hızlı Zaman FFT (menzil) ve Yavaş Zaman FFT (hız) çıktılarının birleşimi, menzil-Doppler haritasını oluşturarak, yansıyan sinyalin yoğunluğunu hem menzil hem de hız fonksiyonu olarak gösteren iki boyutlu bir temsil sağlar.

2.2.6. Işın Şekillendirme (Beamforming)

Işın şekillendirme, radarın belirli yönlere odaklanma yeteneğini artıran gelişmiş bir sinyal işleme tekniğidir. Bu işlem, bir anten dizisinden alınan sinyallerin fazını ve genliğini ayarlayarak radar ışınının istenen hedefe yönlendirilmesini sağlar. Her bir anten elemanına uygulanan faz kayması şu şekilde ifade edilir:

$$\phi_n = -\frac{2\pi}{\lambda} n \Delta x \sin \theta \quad (3)$$

Burada:

- ϕ_n : n -inci anten elemanına uygulanan faz kayması,
- λ : Radar sinyalinin dalga boyu,
- n : Anten dizisindeki eleman indeksini temsil eder,
- Δx : Anten elemanları arasındaki mesafe,
- θ : Işığın yönlendirilmek istendiği açı.

Işın şekillendirme, radarın uzaysal çözünürlüğünü ve doğruluğunu artırarak iletilen ve alınan enerjinin hedefin yönüne odaklanmasını sağlar ve diğer yönlerden gelen parazitleri en aza indirir.

2.2.7. Tek Darbe İşleme (Monopulse Processing)

Hedefin açısının daha doğru ölçülmesi için tek darbe işleme (monopulse processing) kullanılır. Bu yöntem, toplam ve fark kanallarından gelen sinyalleri karşılaştırarak açısal tahmini iyileştirir [18]. Tek darbe hata oranı şu şekilde tanımlanır:

$$e(\theta) = \frac{\Delta(\theta)}{\Sigma(\theta)}$$

Burada:

- $e(\theta)$: Hedefin merkezinden sapmayı gösteren tek darbe hata oranı,
- $\Delta(\theta)$: Fark sinyali, iki anten setinden alınan sinyallerin farkı ile hesaplanır,
- $\Sigma(\theta)$: Tüm anten elemanlarından alınan sinyallerin toplamını ifade eder.

Bu hesaplama, toplam ve fark sinyallerinin göreceli güçlerini değerlendirerek hedefin kesin yönünü belirlemeye yardımcı olur.

2.2.8. Menzil ve Hız Tahmini

Radar sistemlerinde menzil ve hız, hedeflerin tespit edilmesi ve izlenmesi için kullanılan iki temel parametredir:

- **Menzil (Range):** Menzil, radar ile hedef arasındaki mesafeyi ifade eder. Bu mesafe, gönderilen ve alınan radar darbeleri arasındaki zaman gecikmesi ölçülerek hesaplanır. Menzil R , şu denklemle hesaplanabilir:

$$R = \frac{c \cdot t}{2}$$

Burada c ışık hızı, t ise radar sinyalinin hedefe gidip dönmesi için geçen süreyi temsil eder.

- **Hız (Velocity):** Hız, hedefin radara göre hareket hızını ifade eder. Bu hız, alınan sinyaldeki Doppler frekans kayması gözlemlenerek ölçülür. Pozitif Doppler kayması hedefin radara doğru hareket ettiğini, negatif kayma ise uzaklaştığını gösterir. Hız v şu denklemle hesaplanabilir:

$$v = \frac{\Delta f \cdot \lambda}{2}$$

Burada Δf Doppler kayması, λ ise radar sinyalinin dalga boyudur.

2.2.9. Menzil-Doppler Haritasının Oluşturulması

Radar, menzil ve Doppler frekansı verilerini topladıktan sonra, iki boyutlu bir menzil-Doppler haritası oluşturulur. Menzil-Doppler haritası, farklı menzil ve Doppler frekanslarındaki yansıyan sinyal yoğunluğunu gösterir ve çevrenin kapsamlı bir görünümünü sağlar [7].

Bu haritanın her noktası, belirli bir menzil ve Doppler frekansına (hedefin göreceli hızına bağlı) karşılık gelir ve yoğunluk, yansıyan sinyalin gücünü temsil eder. Bu harita, birden fazla

hedefin hem mesafesini hem de radyal hızını aynı anda görselleştirmeyi sağlar ve doğru hedef tespiti ve izleme için gereklidir.

2.2.10. Hedef Tespiti ve CFAR Algoritmaları Kullanılarak Çıkarım

Potansiyel hedefleri belirlemek için radar, Sabit Yanlış Alarm Oranı (CFAR) algoritması uygular. Bu adaptif teknik, çevredeki gürültü seviyesine bağlı olarak tespit eşiğini ayarlayarak hedef tespitinin güvenilirliğini artırır [19]. CFAR algoritmaları, farklı gürültü ve karmaşık senaryolara uyum sağlamak için radar sinyal işleme alanında çok önemlidir. En yaygın kullanılan CFAR türleri arasında Ortalama Hücre CFAR (CA-CFAR), Sıralama İstatistiği CFAR (OS-CFAR) ve En Büyük CFAR (GO-CFAR) bulunur. Bu yöntemler sayesinde, düşük SNR değerlerine sahip zorlu sahnelerde bile yanlış alarm olasılığı kabul edilebilir sınırlar içinde tutulabilir.

Ortalama Hücre CFAR (CA-CFAR):

CA-CFAR dedektörü, çevredeki gürültü seviyesine dayalı olarak adaptif bir eşik oluşturup sinyal gücünü karşılaştırarak radar tespitlerini gerçekleştirir. Bu işlem, her tespiti bir radar noktasına dönüştürerek, menzil, hız, azimut, sinyal gücü ve zaman gibi bilgileri içeren bir hedef listesi oluşturur. CFAR algoritması Şekil 2.3'te gösterilmektedir.

İlk tespitler yapıldıktan sonra veriler, hedeflerin bulunma olasılığının yüksek olduğu alanlara odaklanmak için menzil-Doppler matrislerini kırpılarak rafine edilir. Bu matrisler, araçlar, dronlar veya insanlar gibi belirli hedef türleriyle ilişkili daha küçük alt matrislere bölünür. Bu tezde kullanılan RAD-DAR veri kümesi benzer bir yapıyı takip eder. Veri kümesi, bu hedef kategorilerini ve mesafe-Doppler uzayındaki ayırt edici özelliklerini 400 ms aralıklarla kaydedilen verilerle düzenlemektedir. Bu yapı, fiziksel boyut, radar kesit alanı (RCS) ve insanlarda uzuv hareketi gibi hareketlerden kaynaklanan benzersiz Doppler desenleri gibi özelliklere dayalı hedef sınıflandırma görevlerini desteklemektedir [3]. Böylece, sınıflandırma ağlarına yalnızca bilgi bakımından zengin bölgeler sunularak hem eğitim süresinin kısaltılması hem de modelin genel doğruluğunun artırılması sağlanmaktadır.

2.3.1. Darbe-Doppler Radarı

Darbe-Doppler radar, kısa elektromanyetik dalga darbeleri göndererek ve geri dönen yankıları analiz ederek mesafe ve hız ölçümü yapar. Bu radar tipi, sürekli dalga (CW) radarlara benzer şekilde Doppler kaymalarını ölçer ancak farklı bir işlem yöntemi kullanır [7], [13].

2.3.2. Sentetik Açıklıklı Radar (SAR)

Sentetik Açıklıklı Radar (SAR), hedef bölgenin detaylı görüntülerini oluşturmak için radar platformunun hareketini kullanır. Farklı açılardan veri toplayarak büyük bir anten açıklığı sentezler ve yüksek çözünürlüklü görüntüler üretir. Bu yöntem, arazi haritalama ve sabit nesne gözlemi için yaygın olarak kullanılmaktadır [15], [20].


2.4. RAD-DAR Veri Kümesi

2.4.1. Genel Bakış

RAD-DAR veri kümesi, dronlar, insanlar ve araçları sınıflandırmak için güvenilir etiketli veriler toplamak amacıyla gerçekleştirilen kontrollü bir deneme kampanyasıyla oluşturulmuştur [3]. Bu veri kümesi, *Kaggle* platformunda CC BY 4.0 lisansı altında herkese açıktır ve radar tabanlı algoritmaların test edilmesi ve değerlendirilmesi için serbestçe kullanılabilir.

RAD-DAR veri kümesi, her biri radar hücrelerindeki güç değerlerini (dBm cinsinden) içeren 11×61 matrislerden oluşan binlerce CSV dosyasını içermektedir. Veriler, kök dizin hedef sınıfını (örneğin, dron, araç veya insan) belirten ve alt dizinler deney verilerini içeren bir dizin yapısına sahiptir. Yazarların bilgisine göre, bu veri kümesi gerçek bir saha ortamında kaydedilen gerçek verilere dayalı ilk kamuya açık *menzil-Doppler radar* veri kümesidir [3].

2.4.2. Kayıt Ortamı ve Kurulum



Şekil 2.4 RAD-DAR Veri Kümesi için Yerdeki Güzergahlar [3]

Kayıt alanı, İspanya'nın *Riocabado, Avila* kasabasında, maksimum **5 km'ye kadar açık görüş hattına** sahip bir çiftliktir. Şekil 2.5'de gösterilen radar sistemi kurulumu, çeşitli koşullarda gerçekleştirilen etkinlikleri kaydederek veri çeşitliliğini sağlamıştır.

Veri kümesinin çeşitliliğini artırmak için çeşitli kayıt egzersizleri gerçekleştirilmiş, her hedef farklı *mesafe, hız ve yönelimlerde* kaydedilmiştir. Kayıt için en uygun yolları belirlemek amacıyla bir *görünürlük haritası* oluşturulmuştur. Bu çalışma sonucunda iki ana güzergah belirlenmiştir:

- **Güzergah A:** Şekil 2.4'te mavi renkle belirtilen bu güzergah, *2.7 km* uzunluğunda olup radardan maksimum *2.5 km* uzaklığa ulaşır. Hedefler başlangıçta doğrusal olarak hareket eder, ardından radyal olarak ilerleyerek farklı yönelimlere sahip olur.
- **Güzergah B:** Şekil 2.4'te kırmızı renkle belirtilen bu güzergah, *1.7 km* uzunluğunda olup maksimum *1.5 km* uzaklığa ulaşır. Bu güzergahın eğimi, kaydedilen verilere çeşitli hedef yönelimleri ekleyerek veri çeşitliliğini artırır.



Şekil 2.5 RAD-DAR Veri Kümesi için Saha Testi Kurulumu [3]

Her güzergah farklı hızlarda tekrarlanarak, farklı *Doppler hücrelerine* yayılan güç ölçümlerinin elde edilmesi sağlanmıştır.

2.4.3. Dron Verilerinin Toplanması

Dron verilerinin toplanması, *DJI Phantom 3* adlı ticari mikro-dron kullanılarak gerçekleştirilen çeşitli uçuş egzersizlerini içermektedir. Tüm uçuşlar, yakınlardaki köyden

uzak durmak amacıyla radarın doğusunda gerçekleştirilmiştir. Üç farklı uçuş modeli kaydedilmiştir:

1. **Radyal Uçuşlar:** Maksimum *3.1 km* mesafeye kadar uzanan radyal uçuşlar gerçekleştirilmiştir.
2. **Dairesel Uçuşlar:** *800 m* mesafede merkezlenmiş ve *200 m* yarıçapa sahip dairesele uçuşlar kaydedilmiştir.
3. **Serbest Uçuşlar:** Hız ve irtifa manuel olarak ayarlanarak farklı yönelim ve hızlarla serbest uçuşlar gerçekleştirilmiştir.

2.4.4. Veri Kümesi İstatistikleri

Son RAD-DAR veri kümesi, üç sınıfta toplam **17.485 örnek** içermekte olup dengeli bir dağılıma sahiptir:

- **Dronlar:** 5.065 örnek (% 28,97)
- **İnsanlar:** 6.700 örnek (% 38,32)
- **Araçlar:** 5.720 örnek (% 32,71)

Bu dengeli veri kümesi, sınır ağlarının ve diğer sınıflandırma algoritmalarının eğitimi ve testi için uygundur.

2.4.5. RAD-DAR Veri Kümesinin Güçlü Yönleri

RAD-DAR veri kümesinin güçlü yönlerini vurgulamak, bir modelin neden ve hangi koşullarda iyi performans gösterdiğini anlamak için önemlidir. Veri kümesinin çeşitliliği, kontrollü ortamı, dengeli sınıf dağılımı ve detaylı kayıt düzeni gibi faktörler,

makine öğrenimi modellerinin sağlamlık ve genelleme yeteneklerine doğrudan katkıda bulunmaktadır.

RAD-DAR veri kümesinin en önemli avantajlarından biri, çeşitli gerçek dünya senaryolarını içermesidir. Veri kümesi, farklı mesafelerde, hızlarda ve yönelimlerde kaydedilen dron, insan ve araç radar kayıtlarını içermektedir. Bu çeşitlilik, veri kümesi üzerinde eğitilen makine öğrenimi modellerinin daha geniş bir sınıflandırma zorlukları kümesini ele almasına olanak tanır ve modellerin daha önce görülmemiş verilere karşı genelleme yeteneğini artırır. Gerçek dünya karmaşıklıklarını simüle ederek veri kümesi, farklı ortamlarda etkili bir şekilde çalışabilen radar tabanlı algılama sistemlerinin geliştirilmesi için sağlam bir temel sağlar.

Veri kümesinin bir diğer önemli avantajı, verilerin kaydedildiği kontrollü ve gerçekçi ortamdır. Veri, İspanya'nın Riocabado, Avila kasabasındaki bir çiftlikte dikkatlice yönetilen koşullarda kaydedilmiştir. Bu ortam, maksimum 5 km'ye kadar açık görüş hattı sağlayarak veri kalitesini artırmış ve parazitleri en aza indirmiştir. Gerçekçi fakat kontrollü bir ortam, verilerin pratik uygulamalara uygunluğunu korurken, kontrolsüz değişkenlerden kaynaklanan potansiyel tutarsızlıkları önler. Bu nitelikler, RAD-DAR veri kümesini radar tabanlı nesne algılama algoritmalarının kıyaslanması ve geliştirilmesi için ideal bir seçim haline getirmektedir.

RAD-DAR veri kümesinin kamuya açık olması, değerini daha da artırmaktadır. Veri kümesi, Kaggle platformunda CC BY 4.0 lisansı altında yayınlanmış olup, araştırmacılar ve geliştiricilerin veriye serbestçe erişmesini, veriyi değiştirmesini ve paylaşmasını sağlamaktadır. Bu düzeyde açıklık, araştırma topluluğu arasında işbirliğini teşvik etmekte, sonuçların tekrarlanabilirliğini artırmakta ve radar tabanlı sınıflandırma tekniklerinin kıyaslanmasını kolaylaştırmaktadır.

Ek olarak, veri kümesinin dengeli sınıf dağılımı da dikkat çekici bir avantajdır. Veri kümesi, üç hedef sınıf arasında dengeli bir şekilde dağıtılmış toplam 17.485 örnek içermektedir. Dengeli veri kümesi, makine öğrenimi modellerinin adil bir şekilde eğitilmesini sağlar ve belirli sınıflara yönelik yanlılığı azaltır, böylece algoritmaların genelleme yeteneğini artırır.

2.4.6. RAD-DAR Veri Kümesinin Sınırlamaları

Her ne kadar RAD-DAR veri Kümesi radar tabanlı nesne sınıflandırma araştırmalarında önemli bir kaynak sağlasa da, bazı sınırlamaları genel kullanılabilirliği ve genelleme yeteneğini etkileyebilir. Bu sınırlamalardan biri, veri kümesinin kapsamının sınırlı olmasıdır. Veri kümesi yalnızca üç hedef sınıfa (dronlar, insanlar ve araçlar) odaklanmaktadır. Bu sınıflar radar tabanlı uygulamalar açısından önemli olsa da, bisikletler, hayvanlar veya büyük araçlar gibi ek hedef türlerinin olmaması, veri kümesinin daha kapsamlı sınıflandırma görevleri için kullanımını kısıtlayabilir. Daha fazla sınıfın eklenmesi, veri kümesinin çok yönlülüğünü ve daha geniş uygulamalara olan uygunluğunu artıracaktır.

Bir diğer önemli sınırlama, veri kümesinin sabit matris boyutudur. Her örnek, radar hücrelerinde güç değerlerini içeren 11×61 boyutunda bir matris olarak yapılandırılmıştır. Bu yapı, tutarlı işlemeyi kolaylaştırırken, aynı zamanda veri kümesi üzerinde eğitilen modellerin esnekliğini de sınırlayabilir. Farklı boyut veya konfigürasyonlara sahip veri kümelerine genelleme yapmakta zorlanabilirler.

Son olarak, tüm veriler tek bir kayıt alanında (Riocabado, Avila, İspanya) kaydedildiği için çevresel çeşitlilik eksikliği göze çarpmaktadır. Farklı hava ve arazi koşullarının veri kümesinde temsil edilmemesi, radar verilerinin gerçek dünyadaki karmaşıklıklarını tam olarak yansıtmayabilir.

Bu durum, RAD-DAR veri kümesi üzerinde eğitilen modellerin, çok yollu yansımaların meydana geldiği kentsel alanlar veya yoğun bitki örtüsüne sahip bölgeler gibi farklı ortamlarda sınırlı performans göstermesine neden olabilir. Farklı kayıt ortamlarının dahil edilmesi, veri kümesinin değerini büyük ölçüde artıracak ve eğitilen modellerin genelleme ve dayanıklılık yeteneklerini iyileştirecektir.

Özetle, RAD-DAR veri kümesi, radar tabanlı nesne sınıflandırma araştırmalarında değerli bir temel sağlamakla birlikte, sınıf kapsamının sınırlı olması, sabit matris boyutu, tek kayıt konumu ve çevresel çeşitlilik eksikliği gibi bazı sınırlamaları bulunmaktadır. Bu

sınırlamaların ele alınması, veri kümesinin genellenebilirliğini artıracak ve daha geniş radar araştırma ve gerçek dünya uygulamaları için uygun hale getirecektir.

2.5. YOLO ve RT-DETR İçin RAD-DAR Veri Kümesinden Görüntü Üretimi

Hem YOLOv8 hem de RT-DETR, giriş olarak RGB kanallı görüntüler beklediğinden, RAD-DAR'daki ham güç matrislerinin *ısı haritası* biçimine dönüştürülmesi gerekmiştir. Bu bölüm, 11×61 ölçülerindeki menzil-Doppler güç tablolarının renk-kodlu görsellere çevrilip bağlama kutularıyla etiketlenerek iki dedektörün eğitiminde nasıl kullanıldığını özetler:

- **Matristen Görsele Dönüşüm**: Her radar örneği, menzile karşılık satır, Doppler frekansına karşılık sütun içeren bir güç matrisi olarak başlar. Bu değerler, pikselleri temsil eden `uint8` aralığa ölçeklenip sahte renkli bir görüntü oluşturmaktadır.
- **Renk Haritası Seçimi**: Yoğunluk farklarını vurgulamak için `jet` paleti kullanılmıştır (mavi $\rightarrow$ düşük, kırmızı $\rightarrow$ yüksek).
 - -140 dBm dolayındaki zayıf yansımalar mavi-yeşil tonlara,
 - -70 dBm'e yaklaşan güçlü yansımalar sarı-kırmızı tonlara

dönüştürülerek hem YOLOv8 hem de RT-DETR'in küçük güç farklarını görsel desenler olarak öğrenmesi sağlanmıştır.

- **Sabit Ölçekli Normalizasyon**: Tüm matrisler, -140 — -70 dBm bandına min-max yöntemiyle normalize edilerek renk yoğunluklarının veri kümesi genelinde tutarlı kalması sağlanmıştır. Böylece her piksel rengi, hem YOLOv8'de hem de RT-DETR'de aynı fiziksel gücü temsil eder ve ağların genelleme kabiliyeti artar.
- **Etiketleme ve Dizin Yapısı**: Üretilen her ısı haritası, *dron*, *araç*, *insan* ve *background* sınıflarını içerecek şekilde `LabelImg` aracıyla bağlama kutuları $(x_{\min}, y_{\min}, x_{\max}, y_{\max})$ eklenerek etiketlenmiştir. Aynı `data.yaml` dosya yapısı

hem `ultralytics.YOLO` çağrısında hem de `ultralytics.RTDETR` çağrısında kullanılmıştır; böylece iki model de radar çıkışlarını standart görüntü dosyaları gibi okunmuş ortak anotasyon biçimiyle eğitilebilmiştir.

Bu ön-işleme hattı, radar menzil–Doppler uzayını görsel sinyallere haritalayarak YOLOv8’in tek-geçişli evrimsel dedektör mimarisiyle ve RT–DETR’in sorgu-tabanlı Transformer mimarisiyle uyumlu bir arayüz oluşturmuştur. Sonuçta her iki model de, ham güç değerleri yerine renk desenlerini öğrenerek %99’a varan doğru tespit performansına ulaşmıştır.

2.5.1. RAD–DAR Veri Kümesinde Yüksek ve Düşük SNR Örnekleri

Isı–haritası üretim süreci, RAD–DAR veri kümesindeki **yüksek SNR/SCR** (signal–to–noise / signal–to–clutter ratio) kareleri ile **düşük SNR/SCR** karelerini yan yana incelemeye imkân tanır (Şekil 2.6). Kırmızı–sarı tonlarda yoğunlaşan hedef piksel kümelerinin mavi–yeşil arka plan gürültüsünden keskin spektral kontrastla ayrıldığı kareler “yüksek SNR/SCR”, hedef–zemin kontrastının renk skalasında bastırıldığı ve kontur belirsizliğinin ortaya çıktığı kareler ise “düşük SNR/SCR” kategorisine atanmıştır. Gözlem tamamen nitel spektral kontrast analiziyle gerçekleştirilmiştir. Yüksek ve düşük SNR/SCR senaryolarındaki ayrım, hem YOLOv8 hem de RT–DETR’nin güçlü ve zayıf yönlerini somut olarak ortaya koyar:

- **Yüksek SNR/SCR kareleri** hedef imzasının zemin yansımalarına göre baskın, yoğunluk gradyanlarının net olduğu durumlardır. Her iki dedektörde de $\geq 99\%$ doğruluğa katkı sağlamıştır.
- **Düşük SNR/SCR kareleri** speckle gürültüsünün yüksek, hedef enerjisinin zayıf ya da zeminle çakıştığı durumlardır. RT–DETR’de geri–çağırma kaybına, YOLOv8’de ise sınırlı sayıda *araç* $\rightarrow$ *arkaplan* ve *araç* $\rightarrow$ *dron* hatasına yol açmıştır.


Araç–dron spektral çakışması. Düşük SNR durumlarında, seyrek yansıma üreten yavaş ya da durağan araçlar büyük radar kesit alanına (RCS) rağmen enerjiyi geniş alana yayarak

dron benzeri bir menzil–Doppler örüntüsü oluşturmıştır. Bu durum her iki modelde de *araç* → *dron / arkaplan* karışmasının başlıca nedenidir.


İnsan–araç örtüşmesi. Benzer biçimde, statik duruşlu veya metal aksesuarlı yayalar RCS’yi artırarak kompakt ve güçlü bir enerji çakışması üretmiş, *araç benzeri* görünüm sergilemiştir. Bu çakışma, düşük SNR karelerinde *insan* → *araç* hatalarını tetiklemiştir.

Özetle, *yüksek SNR/SCR* kareleri, modelleri besleyen kritik “temiz” örnekleri sağlarken; *düşük SNR/SCR* kareleri hâlen iyileştirilmesi gereken zorlayıcı radar senaryolarını temsil etmektedir.







(a) Yüksek SNR/SCR Dron




(b) Düşük SNR/SCR Dron




(c) Yüksek SNR/SCR Araba



(d) Düşük SNR/SCR Araba



(e) Yüksek SNR/SCR İnsan



(f) Düşük SNR/SCR İnsan

Şekil 2.6 Radar Veri Görselleştirmelerinin Karşılaştırması, Menzıl–Doppler Yoğunluk Desenlerindeki Farklılıklar

3. İLGİLİ ÇALIŞMALAR

Bu bölüm, radar tabanlı dron tespitine dair literatürdeki gelişimi kronolojik olarak inceleyerek alanın evrimini ortaya koymaktadır. Önce küçük İHA'ların algılanmasında yaşanan erken dönem zorluklar ve mikro-Doppler temelli klasik yaklaşımlar özetlenmektedir; ardından makine öğrenmesi ile derin öğrenmenin radar verilerine entegrasyonu sonucu elde edilen başarımlar tartışılmaktadır. Son olarak, çok-lu modalite sistemleri, hafif tespit ağıları (YOLO-RD) ve zamansal modellemeye dayalı ConvLSTM gibi güncel yöntemler ele alınarak gelecekteki araştırma eğilimleri değerlendirilmektedir.

3.1. Dron Tespiti, Tarihsel Bağlam ve Gelişim Süreci

İnsansız hava araçlarının (İHA), yaygın adıyla dronların, son birkaç on yılda hızla yaygınlaşması, etkili tespit ve izleme sistemlerine olan ihtiyacı artırmıştır. Erken dönem dron tespit yöntemleri, genellikle büyük uçaklar için tasarlanmış geleneksel radar sistemlerine dayanmış, ancak bu sistemler dronların küçük radar kesit alanı (RCS) ve alçak irtifa uçuş desenleri nedeniyle yetersiz kalmıştır [21].

Bu zorluklara yanıt olarak, araştırmacılar küçük İHA'ları tespit edebilecek özel radar teknikleri geliştirmeye başlamıştır. Örneğin, Molchanov ve arkadaşları [22], dronları diğer hava nesnelerinden ayırt etmek için mikro-Doppler imzalarını kullanmayı önermiştir. Mikro-Doppler özelliklerinin, dron pervanelerinin benzersiz hareket karakteristiklerini yakalayarak tespit için ayırt edici imzalar sağladığını ortaya koymuştur [22].

Alan ilerledikçe, tespit yeteneklerini artırmak amacıyla radar sistemlerine makine öğrenmesi algoritmaları entegre edilmiştir. Kim ve Moon [6], mikro-Doppler imzalarına dayalı olarak İHA'ları sınıflandırmak için destek vektör makineleri (SVM) kullanmış ve geleneksel yöntemlere göre doğruluğun arttığını göstermiştir. Derin öğrenmenin ortaya çıkışıyla birlikte, CNN mimarilerinin radar görüntülerinden otomatik olarak özellikler çıkarması tespit performansında önemli ilerlemeler sağlamıştır [3].

Daha sonra, birden fazla sensör modalitesinin entegrasyonu sayesinde yeni gelişmeler kaydedilmiştir. Rahman ve arkadaşları [23], karmaşık ortamlarda tespiti iyileştirmek için radar ve optik sensörlerin birleşimini araştırmıştır. Ayrıca, sentetik açıklıklı radar (SAR) tekniklerini kullanan yaklaşımlar, mekânsal çözünürlüğü artırmak ve hedef kimliğini belirlemek amacıyla incelenmiştir [24].

Son araştırmalar, gelişmiş sinyal işleme ve derin öğrenme teknikleri kullanılarak dronların gerçek zamanlı tespiti ile sınıflandırılmasına odaklanmaktadır. Zhang ve arkadaşları [25], frekans modülasyonlu sürekli dalga (FMCW) radarı ile CNN'leri kullanarak farklı çevresel koşullarda yüksek tespit oranları elde eden gerçek zamanlı bir dron tespit sistemi geliştirmiştir. Ayrıca, Xing ve arkadaşları [26], mikro-Doppler imza çıkarımını iyileştirmek için bistatik radar konfigürasyonları kullanarak İHA tespiti için bir yöntem önermiştir.

Özetle, radar görüntüleri yoluyla dron tespitinin evrimi, geleneksel radar yöntemlerinden makine öğrenimi ve derin öğrenme algoritmalarını içeren sofistike sistemlere doğru ilerlemiştir. Bu gelişmeler, dronların küçük boyutu ile karmaşık uçuş desenleri gibi zorlukların üstesinden gelerek tespit ve sınıflandırma yeteneklerini önemli ölçüde artırmıştır. Devam eden araştırmalar, gerçek zamanlı işleme, çeşitli çevrelerde dayanıklılık ve diğer sensör modaliteleriyle entegrasyon gibi konulara odaklanmaktadır.

3.2. Makine Öğrenmesi ile Dron Tespiti

Makine öğrenmesi tekniklerinin dron tespitine uygulanması, gözetleme ve savunma sistemlerinin yeteneklerini önemli ölçüde artırmıştır. Geleneksel radar tabanlı yöntemler, dronların küçük boyutları, düşük irtifa uçuşları ve değişken hareket desenleri karşısında genellikle yetersiz kalmıştır. Makine öğrenmesi, verilerden otomatik olarak özellik öğrenme yeteneği sunarak tespit doğruluğunu ve yeni dron teknolojilerine adaptasyonu iyileştirmiştir.

Erken dönem makine öğrenmesi yaklaşımları, radar sinyallerinden özellikler çıkarma ve bunları destek vektör makineleri (SVM) gibi algoritmalarla sınıflandırma üzerine odaklanmıştır [6]. Bu yöntemler geleneksel tekniklere göre iyileşme sağlasa da, büyük

ölçüde manuel özellik mühendisliğine bağımlıydı ve karmaşık ve dinamik ortamlarda sınırlı kalmıştır.

Derin öğrenmenin ortaya çıkışı, yeni bir paradigma değişikliği getirmiştir. Radar spektrogramları ve mikro-Doppler imzalarını işlemek için CNN kullanılmaya başlanmıştır. CNN'ler ham verilerden hiyerarşik özellikler çıkararak sınıflandırma performansını artırmıştır [27]. Örneğin, Kim ve arkadaşları [27], Doppler ve mikro-Doppler spektrogramlarını birleştiren CNN modelleri kullanarak dron tespit doğruluğunu artırmıştır.

Tekrarlayan sinir ağları (Recurrent Neural Network - RNN) ve LSTM, radar sinyallerindeki zamansal bağımlılıkları yakalamak için kullanılmış ve tespit yeteneklerini daha da geliştirmiştir [28]. Bu ağlar, radar dönüşlerinin zaman içindeki dizisini modelleyerek, benzersiz uçuş desenleri sayesinde dronları etkili bir şekilde ayırt etmiştir.

Üretici Çekişmeli Ağlar (Generative Adversarial Networks - GAN), etiketlenmiş dron verilerinin azlığı sorununu ele almak için incelenmiştir [29]. GAN'ler, sentetik radar imzaları oluşturarak eğitim veri kümelerini artırmış ve tespit modellerinin dayanıklılığı ile genelleme yeteneğini iyileştirmiştir.

Transfer öğrenme, geniş veri kümeleri üzerinde önceden eğitilmiş modelleri kullanarak dronlara özgü veri ihtiyacını azaltmak için uygulanmıştır [30]. Bu yaklaşım, mevcut modellerin ince ayar yapılarak dron tespiti görevlerine uyarlanmasını hızlandırmış ve sistemlerin geliştirme sürecini hızlandırmıştır.

Radar, optik kameralar ve akustik sensörlerden gelen verilerin entegre edildiği çoklu modalite yaklaşımları, çeşitli çevre koşullarında tespit doğruluğunu artırmak için geliştirilmiştir [31]. Makine öğrenmesi algoritmaları, birden fazla sensörden gelen bilgileri işleyip birleştirerek daha kapsamlı bir tespit yeteneği sunmuştur.

Gerçek zamanlı işleme, uç cihazlarda sinir ağlarının dağıtımı için optimizasyon çabalarının merkezinde yer almıştır [32]. Model sıkıştırma ve budama gibi teknikler, hesaplama gereksinimlerini azaltırken tespit performansını koruyarak sınırlı kaynaklara sahip donanımlarda verimli çalışma sağlamıştır.

Çekişmeli makine öğrenmesi de incelenmiş ve tespit sistemlerinin yanıltma ve diğer saldırılara karşı savunmasızlığı üzerine çalışmalar yapılmıştır [33]. Güvenilirlik ve güvenliği sağlamak için saldırıya dayanıklı modeller geliştirmek, dron tespit sistemleri için hayati önem taşımaktadır.

Sonuç olarak, makine öğrenmesi, otomatik özellik çıkarma, sınıflandırma doğruluğunu artırma ve gerçek zamanlı işleme yetenekleri ile dron tespitinde devrim yaratmıştır. Süregelen araştırmalar, gelişmiş algoritmalar ve teknikleri keşfederek ortaya çıkan zorluklara yanıt vermekte ve dron tespit sistemlerinin etkinliğini artırmayı amaçlamaktadır.

3.3. Radar Görüntüleri ile Dron Tespiti

Radar görüntüleme yöntemlerinin dron tespitine uygulanması, son on yılda önemli ölçüde ilerleme kaydetmiştir ve küçük insansız hava araçlarının (İHA) sunduğu benzersiz zorluklara yanıt vermiştir. İlk araştırmalar, mevcut radar sistemlerini bu küçük hedefleri tespit edecek şekilde uyarlamaya odaklanmıştır. 2012 yılında Koch ve Westphal [34], geleneksel radar sistemlerinin zemin yansıması (ground clutter) arasında küçük İHA'ları tespit etmedeki zorluklarını vurgulamıştır. Bu çalışma, yüksek çözünürlüklü radar ve gelişmiş sinyal işleme tekniklerinin tespit yeteneklerini iyileştirme ihtiyacına dikkat çekmiştir.

2014 yılına gelindiğinde, radar görüntülerinden çıkarılan mikro-Doppler imzalarının kullanımı üzerine odaklanılmaya başlanmıştır. Molchanov ve arkadaşları [22], dron pervanelerinin hızlı hareketlerinden kaynaklanan bu mikro-Doppler özelliklerinin küçük İHA'ları kuşlar ve diğer nesnelerden etkili bir şekilde ayırt edebileceğini göstermiştir. Bu çalışma, dron tespitinde mikro-Doppler analizinin temelini oluşturmuştur.

2016 yılında Rahman ve arkadaşları [35], düşük maliyetli koherent radar sistemi kullanarak küçük dronların tespitini araştırmıştır. Küçük hedef tespitine yönelik özel sinyal işleme algoritmaları geliştirmiş ve radar sistemlerinin pratik uygulamalarını iyileştirmiştir.

Makine öğrenmesi tekniklerinin entegrasyonu, radar tabanlı dron tespitinde önemli bir dönüm noktası olmuştur. 2017 yılında Kim ve Moon [36], radar görüntülerinden elde edilen

mikro-Doppler imzalarına CNN'leri uygulayarak özellik çıkarma işlemini otomatikleştirmiş ve sınıflandırma doğruluğunu artırmıştır. Bu yaklaşım, derin öğrenmenin radar verilerini işleyerek dron tespiti için sunduğu potansiyeli göstermiştir.

Ritchie ve arkadaşları [37], dronlar ve kuşların mikro-Doppler sınıflandırması için çoklu radar (multistatic radar) konfigürasyonlarını araştırmıştır. Birden fazla açıdan alınan radar görüntülerini analiz ederek tespit güvenilirliğini artırmış ve yanlış alarmları azaltmıştır, bu da monostatik radar sistemlerinin sınırlamalarını ele almıştır.

2018 yılında Park ve arkadaşları [38], ters sentetik açıklıklı radar (ISAR) görüntülemesini derin öğrenme ile birleştiren bir dron tespit sistemi tanıtmıştır. Gelişmiş sinyal işleme tekniklerini kullanarak radar görüntülerinden mikro-Doppler özelliklerini çıkarmış ve karmaşık ortamlarda tespit performansını artırmıştır.


Daha ileri bir gelişme olarak, Jahangir ve Amin [39], radar görüntüleme verileri üzerinde tensor ayrıştırma yöntemleri kullanarak İHA tespiti ve sınıflandırması önermiştir. Bu yaklaşım, hedeflerin mekânsal ve hareket bilgilerini detaylı bir şekilde sağlayarak sınıflandırma doğruluğunu ve dayanıklılığını artırmıştır.

2020 yılında Rahman ve arkadaşları [40], üç boyutlu radar görüntüleme tekniğini dron tespiti için geliştirdi. Bu yöntem, dronların mekânsal özelliklerini yakalayıp diğer nesnelerden daha iyi ayırım sağladı ve karmaşık ortamlarda tespit yeteneklerini geliştirdi.

Ek olarak, Chen ve arkadaşlarının [4] çalışması, döner kanatlı dronları uçan kuşlardan ayırt etmek için K-bant frekans modülasyonlu sürekli dalga (FMCW) radarını kullanan kapsamlı bir mikro-hareket sınıflandırma yöntemi sunmaktadır. Bu çalışma, mikro-Doppler özelliklerini, menzil profillerini ve zaman-frekans (T-F) grafiklerini sınıflandırma performansını artırmak için kullanmıştır. Chen ve arkadaşları, dört pervaneli (quadcopter), altı pervaneli (hexacopter) ve sabit kanatlı dronların yanı sıra martı ve biyonomik kuş gibi uçan kuşların radar imzalarını içeren geniş bir veri kümesi oluşturmuştur. Yazarlar, T-F grafiğinin renk gösterim genliğini ayarlayarak ve menzil-zaman ile menzil-periyot

özelliklerini birleştirerek radar mikro-hareket özelliklerini geliştiren yenilikçi bir veri artırma tekniği önermiştir.

Şekil 3.1, çeşitli döner kanatlı, sabit kanatlı dronlar ve uçan bir kuşun radar tabanlı mikro-Doppler imzalarını kapsamlı şekilde sunmaktadır. Zaman–frekans grafiklerinde, döner kanatlı dronlar için rotorların periyodik hareketine bağlı olarak belirgin harmonik bileşenler ortaya çıkarken, sabit kanatlı dron örneğinde daha sabit ve dar bantlı bir Doppler spektral dağılım gözlenmektedir. Biyonomik kuş ve gerçek kuş grafiklerinde ise, düzensiz kanat çırpma hareketlerine bağlı olarak düşük frekansta dalgalı ve asimetrik Doppler imzaları dikkat çekmektedir. Menzil profillerinde döner kanatlı dronlar yüksek radar kesit alanına sahip sivri tepe noktaları oluştururken, kuş benzeri hedeflerde genişleyen ve düşük genlikli yankılar belirgin hâle gelmektedir. Menzil–zaman grafikleri analiz edildiğinde, dronlar düz ve kararlı hareket örüntüleri sergilerken, kuşların hareketi, aerodinamik dalgalanmaların etkisiyle düzensiz ve salınımlı bir yapı göstermektedir. Bu karakteristik farklılıklar, radar sistemleriyle kuş–dron ayrımı yapılabilmesi ve ileri seviye hedef sınıflandırma algoritmalarının eğitilmesi için temel bir veri kaynağı oluşturmaktadır.



Şekil 3.1 Mikro-Doppler Veri Kümeleri: Farklı Dron Türleri ve Uçan Kuşlara Ait Zaman-Frekans (T-F) Grafikleri, Menzil Profilleri ve Menzil-Zaman Grafikleri [4].

Chen ve arkadaşları, sınıflandırmayı daha da iyileştirmek için hem küresel hem de yerel m-D özelliklerini çıkaracak şekilde tasarlanmış, modifiye edilmiş çok ölçekli CNN kullanmıştır. Ağ, model karmaşıklığı ile özellik çıkarma yeteneği arasında denge kuran hibrit bir bağlantı yapısı içermektedir. Deneysel sonuçlar, AlexNet ve VGG16 gibi geleneksel CNN mimarilerine kıyasla üstün performans göstererek, çeşitli radar veri kümeslerinde daha yüksek sınıflandırma doğruluğu ve genelleme sağlamıştır. Bu çalışma, radar tabanlı dron ve kuş sınıflandırmasının zorluklarını ele almak için ileri düzey sinyal işleme, veri artırma ve derin öğrenme entegrasyonunu örneklemiştir.

Zhou ve arkadaşları [8], özel olarak Menzil-Doppler radar görüntüleri için tasarlanmış hafif bir nesne tespit ağı olan YOLO-RD'yi tanıtmıştır. Sabit Yanlış Alarm Oranı (Constant False Alarm Rate - CFAR) gibi geleneksel radar tespit teknikleri, karmaşık ortamlarda düşük doğruluk göstermekte ve bu durum derin öğrenme tabanlı alternatiflerin geliştirilmesini zorunlu kılmaktadır. YOLO-RD, YOLOv3 ve DenseNet'ten ilham alarak hesaplama karmaşıklığını azaltırken yüksek tespit doğruluğunu korumaktadır. Model, mini-RD adlı özel bir veri kümesi üzerinde değerlendirilmiş ve Tiny-YOLOv3 ile karşılaştırıldığında üstün performans göstererek, radar tabanlı İHA tespiti için gerçek zamanlı uygulamalar için uygunluğunu kanıtlamıştır.

Uzamsal-zamansal radar özellik analizi fikrine dayanan Jia ve arkadaşları [41], trafik sahnelerinde dron tespiti için dikkat tabanlı bir ConvLSTM modeli önermiştir. Statik görüntü tabanlı tespit yaklaşımlarından farklı olarak, bu yöntem Menzil-Doppler dizilerinin zamansal bağımlılıklarını kullanarak hareket desenlerini yakalamaktadır ve bu da İHA'ları diğer hareketli nesnelerden ayırt etmekte kritik önem taşımaktadır. Verimli Kanal Dikkati (Efficient Channel Attention - ECA) entegrasyonu sayesinde, modelleri karmaşık ortamlarda küçük nesne tespitini önemli ölçüde iyileştirmiştir. CARRADA ve RADDet veri kümesleri üzerinde yapılan kıyaslama değerlendirmeleri, sırasıyla %74,51 ve %75,62 mAP sonuçlarıyla mevcut radar tabanlı tespit yaklaşımlarını geride bırakmıştır. Bu çalışma, gerçek zamanlı İHA tespiti için zamansal modellemeyi derin öğrenme mimarileriyle birleştirmenin potansiyelini göstermektedir.

Karlsson ve arkadaşları [42], 77 GHz'lik mekanik taramalı bir FMCW radar (SAAB SIRS 1600) kullanarak *Model-Aided Drone Classification* yaklaşımını tanıtmıştır. Bu çalışma kapsamında kullanılan “Radar measurements on drones, birds and humans with a 77 GHz FMCW sensor” adlı radar verisi, Zenodo platformunda herkese açık olarak yayımlanmıştır [43]. Çalışmada, yalnızca 9 ms'lik bakış süresine sahip menzıl–Doppler kesitlerinden beş katmanlı bir CNN ile dron, kuş, insan ve köşe reflektör sınıflandırması gerçekleştirilmiştir. Yazarlar, eğitime dâhil edilmeyen (dağılım dışı) dron tiplerinde düşen doğruluğu telafi etmek için matematiksel bir pervane modeliyle üretilmiş *sentetik dron* verisi eklemiş; böylece dağılım dışı dron doğruluğunu %78'den %86'ya yükseltirken, tüm dron tipleriyle eğitildiğinde ortalama sınıf doğruluğunu %90 düzeyine çıkarmıştır. Ayrıca, SNR normalizasyonu ve tek tarama tabanlı sınıflandırma senaryosuyla, düşük entegrasyon süresinde dahi güvenilir dron–kuş ayrımı yapılabileceğini göstermişlerdir.

Ertekin ve arkadaşları [44], 77 GHz FMCW radardan elde edilen IQ verilerini kısa-zamanlı Fourier dönüşümü ile menzıl–Doppler spektrogramlarına dönüştürmüş ve altı farklı *dron*, iki insan hareketi (yürüme–koşma) ile bir köşe reflektöründen oluşan *dokuz* hedef sınıfı için toplam $\sim 76\,000$ örnek içeren bir veri kümesi kullanmıştır [43]. Çalışmada, altı evrişim katmanlı özel bir CNN (tezde “ESA”) ile otomatik özellik çıkarımı yapılmış, bu özellikler doğrusal SVM'e (Support Vector Machine - Destek Vektör Makinesi) beslenerek kuş–dron ayrımını da kapsayan çok-sınıflı bir sınıflandırma gerçekleştirilmiştir. Önerilen hibrit yapı, dokuzlu senaryoda %98.04, yalnızca kuş–dron ikilisinde ise %99.4 doğruluk elde etmiştir. Ayrıca filtre boyutu (3×3 – 7×7) ve ağ derinliği üzerine yapılan kapsamlı sıkılaştırma (ablation) çalışmaları, daha derin (6-katman) konfigürasyonun küçük parametre artışına karşın belirgin performans kazancı sağladığını göstermiştir. Sonuçlar, yüksek frekanslı radarlardan türetilen mikro-Doppler imzalarının, hafif CNN–SVM hibritleriyle küçük İHA'ların güvenilir biçimde sınıflandırılabilceğini ortaya koymaktadır.

Radar görüntüleme tekniklerinin dron tespiti için zaman içindeki kronolojik gelişimi, geleneksel radar yöntemlerinden makine öğrenimi ve gelişmiş sinyal işleme tekniklerini içeren sofistike sistemlere doğru bir kaymayı yansıtmaktadır. Bu gelişmeler, dronların tespiti, sınıflandırılması ve izlenmesi yeteneğini önemli ölçüde iyileştirmiş ve İHA

teknolojileri tarafından sunulan değişen zorluklara çözüm sunmuştur. Tablo 3.1, dron tespit çalışmalarında kullanılan radar veri kümelerinin bant dağılımını, hedef sınıf çeşitliliğini ve erişim durumunu özetlemektedir.

Tablo 3.1 Literatürdeki Çalışmaların Veri Kümesi Özellikleri

Çalışma	Yıl	Veri Kümesi / Kaynak	Radar Bantı & Modu	Hedef Sınıfları	Açık Erişim
Molchanov [22]	2014	Kuruma özel mikro-Doppler kayıt seti	K-band (24 GHz) CW	Dron, kuş	Hayır
Kim & Moon [6]	2016	Kuruma özel menzil-Doppler spektrogramları	K-band (24 GHz) FMCW	Dron, kuş	Hayır
Roldan [3]	2020	RAD-DAR veri kümesi	K-band FMCW	Dron, insan, araç	Evet
Rahman [23]	2019	Radar + optik saha denemeleri	K / W-band FMCW	Dron	Hayır
Kuschel [24]	2015	ISAR uçuş görüntü seti	X-band (9.5 GHz) darbe	Dron, kuş	Hayır
Ritchie [37]	2017	NetRAD çoklu-istasyon verisi	S-band darbe	Dron	Hayır
Xing [26]	2017	Bistatik mikro-Doppler kayıtları	C-band darbe	Dron	Hayır
Zhang [25]	2021	Arazi testi menzil-Doppler dizileri	K-band FMCW	Dron	Hayır
Zhou [8]	2023	mini-RD görüntü seti	K-band RD görüntü	Dron, gemi	Hayır
Chen [4]	2022	Mikro-hareket (dron/kuş) M-D kümesi	K-band FMCW	Dron, kuş	Hayır
Jia [41]	2023	CARRADA & RADDet	W-band (77 GHz) MIMO FMCW	Yaya, araç, dron	Evet
Karlsson [42]	2025	KTH 77 GHz FMCW (SAAB SIRS-1600) [43]	W-band (77 GHz) FMCW	Dron, kuş, insan, köşe reflektörü	Evet

4. YÖNTEMLER

Bu bölüm, RAD-DAR verilerini işleyerek hedefleri sınıflandırmak ve tespit etmek için izlenen tüm derin öğrenme sürecini ayrıntılarıyla açıklamıştır. İlk olarak ham menzil-Doppler güç matrislerinin ısı haritası üretimi, normalizasyon ve eğitim-test ayrımı

gibi ön-işleme adımları sunmuş, ardından sırasıyla klasik CNN mimarisi, zamansal bilgiyi yakalayan CNN-LSTM-Attention yapısı, YOLOv8 dedektörü ve gerçek-zamanlı Transformer tabanlı RT-DETR modeli tanıtmıştır. Her alt bölümde ilgili ağ mimarileri, eğitim konfigürasyonları ve performans ölçüm kriterleri verilerek, dört yaklaşımın nasıl kurulup karşılaştırıldığı bütüncül bir akış içinde ortaya konulmuştur.

4.1. Evrişimli Sinir Ağı (CNN)

4.1.1. Veri Yükleme ve Ön İşleme

Bu bölümde, RAD-DAR veri kümesindeki radar tabanlı verilerin CNN sınıflandırması için hazırlanması açıklanmaktadır. Veri kümesi, radar kayıtlarından oluşmaktadır ve üç sınıfa ayrılmıştır: *dronlar*, *insanlar* ve *araçlar*. Her örnek, dBm cinsinden güç değerlerinden oluşan 11×61 boyutunda bir matrisle temsil edilmektedir. Şekil 4.1, işlenmemiş araç verisinin yukarıda anlatımı geçen 11×61 'lik matrisin ilk 11×9 'luk kısmını göstermektedir.

Veri, çok sınıflı sınıflandırma için etiketlerin one-hot kodlamasıyla atanmasını sağlayan `load_data` adlı Python fonksiyonu kullanılarak yüklenir. Bu fonksiyon, CSV dosyalarını Pandas DataFrame'lerine dönüştürür, daha sonra NumPy dizilerine çevirir [9]. Bu süreç, eğitim ve değerlendirme için yapılandırılmıştır ve verilerin verimli işlenmesini sağlamıştır.

	0	1	2	3	4	5	6	7	8	9
1	-118.26	-129.87	-117.58	-116.24	-117.82	-114.83	-112.75	-111.69	-114.03	-118.82
2	-114.17	-115.5	-124.09	-116.99	-116.67	-118.69	-120.22	-115.84	-129.32	-117.44
3	-117.64	-120.25	-126.42	-116.51	-114.13	-119.58	-119.86	-114.88	-111.96	-113.49
4	-122.1	-118.45	-121.81	-118.23	-113.78	-115.38	-119.51	-112.95	-108.82	-108.89
5	-118.97	-112.95	-115.72	-118.8	-115.51	-118.33	-119.84	-117.69	-109.97	-109.82
6	-119.12	-114.08	-113.5	-117.5	-123.06	-124.48	-115.01	-114.06	-117.81	-124.82
7	-116.94	-112.78	-115.53	-122.34	-114.19	-111.51	-113.42	-117.16	-119.2	-122.34
8	-117.95	-110.14	-116.23	-116.21	-110.72	-109.66	-112.11	-130.01	-120.48	-123.54
9	-117.65	-122.53	-120.47	-116.16	-112.77	-112.82	-113.27	-115.66	-125.56	-121.55
10	-115.56	-112.91	-115.4	-113.13	-111.81	-116.51	-116.75	-115.06	-119.73	-116.62
11	-123.08	-113.8	-117.93	-116.1	-111.77	-115.07	-114.15	-118.16	-119.74	-118.37

Şekil 4.1 .csv Formatında İşlenmemiş Araç Verisinin İlk 11×9 Örneği


Model performansını optimize etmek için aşağıdaki ön işleme adımları uygulanmıştır:

- **Mutlak Değer Dönüşümü (Absolute Value Transformation):** Negatif olmayan girişler sağlar, bu da eğitimi stabilize eder ve özellik temsilini iyileştirir [9].
- **Normalizasyon:** Güç değerlerini -140 dBm ile -70 dBm arasında yeniden ölçekleyerek tutarlılığı artırır ve modelin daha iyi yakınsama sağlamasına yardımcı olur [45].
- **Veri Bölme:** Veri kümesi, modelin genelleme yeteneğini değerlendirmek için %80 eğitim ve %20 test verisi olarak bölünür [46]. Ayrıca, performansın daha sağlam ölçülmesini sağlamak amacıyla veri üzerinde 5 katlı çapraz doğrulama (5-fold cross-validation) yöntemi uygulanmıştır.
- **Yeniden Şekillendirme:** Her radar matrisi, CNN giriş formatına uygun olarak $11 \times 61 \times 1$ boyutunda bir tensöre dönüştürülür [3, 47].

4.1.2. CNN Modelinin Mimarisi


CNN modeli, radar verilerinden hiyerarşik özellikler çıkaracak şekilde tasarlanmıştır ve verileri üç hedef sınıfa doğru bir şekilde sınıflandırmayı amaçlamaktadır. Mimari, her biri evrişim (convolutional) katmanları, yığın normalizasyonu, aktivasyon fonksiyonları, havuzlama (pooling) katmanları ve düzenleme (dropout) katmanları içeren birkaç bloktan oluşmaktadır [48, 49].

Şekil 4.2’de gösterilen CNN mimarisi, mekânsal çözünürlüğü azaltmak için 3×3 çekirdek boyutuna (kernel size) sahip birden fazla evrişim katmanı ve uzamsal boyutları düşürmek için max-pooling katmanları içermektedir. Bu katmanlar sırasıyla 64, 128 ve 256’lık filtre boyutlarından oluşmaktadır. Düzenleme amacıyla sönümlenme katmanları da eklenmiştir. Elde edilen özellikler, düzleştirilerek (flatten) tam bağlı (fully connected) katmanlara aktarılır ve nihayetinde radar görüntüleri *dron*, *insan* veya *araç* kategorilerine sınıflandırılır.



Şekil 4.2 CNN Modelinin Mimarisi

Şekil 4.3, CNN mimarisindeki her katmanın filtre sayısını, çekirdek boyutunu ve havuzlama adımlarından sonra ortaya çıkan ara tensör boyutlarını çizgisel bir akışla özetlemektedir. Her bir blok için '→' işaretinden sonra verilen boyutlar verinin o anki boyutunu temsil etmektedir. Bu diyagram, uzamsal boyutların 11×61 'den önce artırılıp sonra 1×3 'ye kadar nasıl kademeli biçimde indirildiğini ve özellik derinliğinin $64 \rightarrow 128 \rightarrow 256$ kanal şeklinde nasıl zenginleştirildiğini görsel olarak göstermektedir. Böylece modelin parametre dağılımı ile hesaplama yükü katman katman takip edilebilir, ağıın toplam sıkıştırma oranı ve bilgi yoğunluğu daha anlaşılır hâle gelmektedir.



Şekil 4.3 CNN Modelinin Ara Çıktı Boyutları

Model, TensorFlow ve Keras kütüphaneleri kullanılarak oluşturulmuş olup derin öğrenme modellerini oluşturmak ve eğitmek için güçlü bir çerçeve sağlamaktadır [50, 51]. Keras'ın Sequential API'si ile model, modüler ve açık bir şekilde tanımlanmıştır [50].

CNN modeli aşağıdaki bileşenlerden oluşmaktadır:

- **Giriş Katmanı:** Model, $11 \times 61 \times 1$ şekline sahip tensörleri kabul eden bir giriş katmanı ile başlar.
- **Birinci Evrişim Bloğu:**
 - 64 filtrelili ve 3×3 çekirdek boyutuna sahip iki Conv2D katmanı, ReLU aktivasyon fonksiyonu ve same padding kullanır.

- BatchNormalization katmanı, aktivasyonları normalleştirerek eğitimi stabilize eder ve hızlandırır [45].
 - 2×2 boyutunda MaxPooling2D katmanı, mekânsal boyutları azaltarak temel özellikleri yakalar.
 - %25 oranında Sönümleme katmanı, aşırı öğrenmeyi (overfitting) önlemek için nöronların bir kısmını rastgele devre dışı bırakır [49].
- **İkinci ve Üçüncü Evrişim Blokları:** İkinci blokta 128 filtreli, üçüncü blokta ise 256 filtreli Conv2D katmanları bulunur. Bu bloklar daha derin özellikler çıkarır ve sönümleme oranları giderek artırılır (%40'a kadar).
 - **Düzleştirme (Flattening) Katmanı:** Evrişimli katmanların çok boyutlu çıktısını tek boyutlu bir vektöre dönüştürerek tam bağlı katmanlar için veriyi hazırlar [10].

Tam Bağlı (Fully Connected) Katmanlar:

- Dense katmanı 512 nöron ve ReLU aktivasyonu içerir.
- %50 oranında Dropout katmanı aşırı öğrenmeyi önler.
- İkinci Dense katmanı 256 nöron ve ReLU aktivasyonu içerir.
- Bir başka %50 oranında Dropout katmanı uygulanır.

Çıkış Katmanı: Üç sınıf (*dron*, *insan*, *araç*) için 3 nörona sahip Yoğun (Dense) katmanı, sınıf olasılıklarını üretmek için softmax aktivasyon fonksiyonu kullanır [52].

CNN modeli, öğrenme oranını otomatik olarak uyarlayan Adam optimizasyon algoritması ile derlenir [53]. Çok sınıflı sınıflandırma görevleri için uygun olan kategorik çapraz-entropy (categorical cross-entropy) kayıp fonksiyonu kullanılır [54]. Modelin temel performans ölçütü olarak doğruluk (accuracy) izlenir [55].

4.1.3. Model Performans Ölçütleri

Model, 50 epoch boyunca 10'luk batch boyutu ile eğitilmiştir. Bu yapılandırma, hesaplama verimliliği ve yakınsama (convergence) kararlılığını dengeleyerek modelin etkili bir şekilde öğrenmesini sağlar. Eğitim sırasında model, kayıp fonksiyonunu minimize etmek için backpropagation ve gradyan inişi (gradient descent) tekniklerini kullanır [51].

Model performansı, test kümesi üzerinde doğruluk (accuracy) ile değerlendirilir ve doğru sınıflandırılan örneklerin toplam örnek sayısına oranı olarak hesaplanır [55]. Aşırı öğrenme potansiyelini değerlendirmek için modeldeki eğitilebilir parametrelerin sayısı rapor edilir [9]. Modelin toplam parametre sayısı **2.196.163 (8.38 MB)** olup, bunların **2.195.267 (8.37 MB)**'i eğitilebilir ve **896 (3.50 KB)**'si eğitilemez parametrelerdir.

Uygulama süreci, CNN modelini oluşturmak ve eğitmek için TensorFlow ve Keras kütüphanelerinden yararlanır [50, 51]. Pandas ve NumPy, büyük veri kümelerinin verimli işlenmesini sağlarken; Python ortamında sağlam bir ekosistem sunarak makine öğrenmesi ve veri işleme işlemlerini kolaylaştırır [51].

4.2. CNN ile LSTM ve Dikkat Mekanizması (Attention Mechanism)


Bu alt bölüm, CNN mimarisine LSTM birimlerinin entegrasyonuna odaklanır. Bu entegrasyon, radar veri dizilerindeki zamansal bağımlılıkları yakalayarak modelin hem mekânsal hem de zamansal özelliklere dayalı hedef sınıflandırma yeteneğini artırır [56].

Radar sistemleri, hedeflerin hareketinden ve çevreyle etkileşimlerinden kaynaklanan zamansal dinamikler içeren ardışık veriler yakalar. RAD-DAR veri kümesinde, ardışık radar kareleri, *dron*, *insan* ve *araç* gibi sınıfları ayırt etmek için kritik olan zamansal ilişkiler sergiler [57]. Örneğin, yürüyen bir insanın periyodik hareketi veya bir dronun tutarlı uçuş deseni, sınıflandırma için kullanılabilecek zamansal desenler oluşturur [58].

RAD-DAR veri kümesi, zamansal değişimlerin sınıflar arasında ayırım yapmak için büyük rol oynadığı radar kayıtlarını içerir. Dronlar, zamansal olarak ilişkilendirilebilecek

benzersiz uçuş desenleri ve hız değişiklikleri sergiler [54]. İnsanlar, yürüyüş biçimlerinden kaynaklanan periyodik hareketlerle karakterize edilen zamansal imzalar sunar [6]. Araçlar ise genellikle tahmin edilebilir yollar boyunca tutarlı hızlarda hareket ederek dronlar ve insanlardan farklı zamansal desenler oluşturur [59]. LSTM katmanı, bu zamansal bağımlılıkları yakalamak için özellikle uygundur ve RAD-DAR veri kümesindeki hedeflerin doğru şekilde sınıflandırılmasını sağlar [60].


Şekil 4.4, bu çalışmada radar tabanlı hedef sınıflandırma için kullanılan CNN-LSTM-Attention modeli mimarisinin genel blok diyagramını göstermektedir. Girdi olarak alınan radar görüntüleri (11×61), ardışık evrimsel (CNN) bloklarla işlenerek sırasıyla 64, 128 ve 256 filtre ile uzamsal özellik vektörlerine dönüştürülmektedir. Ardından bu özellikler, iki aşamalı LSTM katmanında (256 ve 128 boyutlu gizil durumlar) zamansal olarak modellenmekte; son aşamada ise pozisyon yanlı dikkat mekanizması ile zamansal kareler arasındaki önem dereceleri hesaplanarak sınıflandırma başlığına aktarılmaktadır.



Şekil 4.4 CNN-LSTM-Dikkat Mimarisinin Blok Diyagramı

Şekil 4.5, önerilen CNN-LSTM-Dikkat mekanizmalı modelin her bir katmanında gerçekleşen boyut dönüşümlerini görsel olarak özetlemektedir. Girdi olarak alınan $11 \times 61 \times 1$ boyutundaki radar görüntüsü, ardışık evrim katmanları ve havuzlama işlemleriyle sırasıyla $5 \times 30 \times 64$, $2 \times 15 \times 128$ ve $1 \times 7 \times 256$ gibi daha düşük mekânsal boyutlara ve daha yüksek kanal derinliğine dönüştürülmektedir. Daha sonra bu özellik haritası düzleştirilerek 1792 boyutunda bir vektöre çevrilmekte, ardından zamansal dizilere ayrılarak 7×256 boyutunda bir sekansa dönüştürülmektedir. LSTM katmanları bu diziler üzerinde zamansal modelleme

uygulayarak sırasıyla 7×256 ve 7×128 boyutlu çıktı üretmektedir. Dikkat mekanizması ise bu çıktılarından 128 boyutlu bağlam vektörü (context vector) oluşturmakta ve sınıflandırma işlemi sırasıyla 512, 256 ve 3 nöron içeren tam bağlı katmanlarla tamamlanmaktadır.



Şekil 4.5 CNN–LSTM–Dikkat Modeline Ait Ara Katman Boyutları

4.2.1. LSTM Katmanlarının Entegrasyonu ve Ayrıntılı Analizi

Evrişimsel katmanların ardından gelen $3 \times 2 \times 2$ havuzlama işlemi, radar görüntülerinin zamansal ekseninde $T = 7$ karelik bir ardışık diziyi ortaya çıkarmaktadır. Her bir kare, $D = 256$ boyutunda bir özellik vektörü ile temsil edilir. Bu T uzunluğundaki sekans, Düzleştirme (Flatten) ve Yeniden-boyutlama (Reshaping) işlemleriyle (B, T, D) biçiminde bir tensöre dönüştürülerek sırasıyla iki adet LSTM katmanına aktarılır (B : batch boyutu).

İlk LSTM katmanı, gizil boyutu $H_1 = 256$ olacak şekilde yapılandırılmıştır. Böylece CNN'den gelen her 256-boyutlu uzamsal özelliğin zamansal evrimini doğrudan takip edebilir. Bu katmanda kullanılan kapı denklemleri aşağıdaki gibidir:

$$\begin{aligned} \mathbf{i}_t &= \sigma(\mathbf{W}_i \mathbf{x}_t + \mathbf{U}_i \mathbf{h}_{t-1} + \mathbf{b}_i), \\ \mathbf{f}_t &= \sigma(\mathbf{W}_f \mathbf{x}_t + \mathbf{U}_f \mathbf{h}_{t-1} + \mathbf{b}_f), \\ \mathbf{o}_t &= \sigma(\mathbf{W}_o \mathbf{x}_t + \mathbf{U}_o \mathbf{h}_{t-1} + \mathbf{b}_o), \\ \tilde{\mathbf{c}}_t &= \tanh(\mathbf{W}_c \mathbf{x}_t + \mathbf{U}_c \mathbf{h}_{t-1} + \mathbf{b}_c), \\ \mathbf{c}_t &= \mathbf{f}_t \odot \mathbf{c}_{t-1} + \mathbf{i}_t \odot \tilde{\mathbf{c}}_t, \quad \mathbf{h}_t = \mathbf{o}_t \odot \tanh(\mathbf{c}_t), \end{aligned}$$

burada $\mathbf{x}_t \in \mathbb{R}^{256}$ giriş vektörü, $\mathbf{h}_t \in \mathbb{R}^{256}$ gizil durum, $\mathbf{c}_t$ hücre durumu, σ sigmoid aktivasyon fonksiyonu, $\odot$ eleman bazlı çarpma, $\mathbf{W}_i, \mathbf{W}_f, \mathbf{W}_o, \mathbf{W}_c \in \mathbb{R}^{256 \times 256}$ girdi ağırlıkları ve $\mathbf{U}_* \in \mathbb{R}^{256 \times 256}$ gizil ağırlıklardır. Bu katmanın toplam parametre sayısı 525,312'dir.

İkinci LSTM katmanı, zamansal bilgiyi daha kompakt temsil etmek amacıyla gizil boyutu $H_2 = 128$ olacak şekilde tanımlanmıştır. Bu katman, birinci LSTM katmanından gelen 256 boyutlu dizileri alır ve her zaman adımı için 128 boyutlu yeni bir özellik dizisi üretir. Parametre sayısı 197,120 olup, toplam LSTM bloğu parametre yükü 722,432'dir.

Tek katmanlı bir LSTM yapılandırması, özellikle $T = 7$ gibi kısa sekanslarda bile 256 boyutlu büyük gizil vektör nedeniyle modelin fazla parametrik hale gelmesine ve genelleme kabiliyetinin azalmasına neden olabilir. Bu nedenle iki katmanlı yapı tercih edilmiştir. İlk katman, uzun vadeli bağıntıları yakalayıp ayrıntılı geçici temsiller üretirken; ikinci katman, daha düşük boyutta sıkıştırma uygulayarak dikkat katmanının ayıklayıcı yapısıyla daha verimli entegrasyon sağlar.

4.2.2. Pozisyon Yanlı Dikkat Katmanı

RAD–DAR verisi, CNN havuzlaması sonrasında $T=7$ adet ardışık radar karesini (zamansal dilim) içeren bir tensöre $\mathbf{X} \in \mathbb{R}^{B \times T \times D}$ indirgenmektedir. Burada B bir batch’teki örnek sayısını, T zaman adımı sayısını (bu çalışmada 7), ve D her karedeki özellik boyutunu ($D = 128$) temsil etmektedir. Her örnekteki zaman serisi $\mathbf{x}_t \in \mathbb{R}^D$ ile gösterilen özellik vektörlerinden oluşmaktadır.

Bu dizide bilgi yoğunluğu, hedef yankılarının çoğunlukla orta karelere kümelendiği gözlenmiştir. Bu nedenle, LSTM birimlerinin ardından, yüksek enerjili ve güvenilir zamansal dilimleri öncelikli olarak vurgulamak amacıyla pozisyon yanlı dikkat (attention) katmanı uygulanmıştır. Bu özel dikkat mekanizması, hem giriş özelliklerinden içerik tabanlı önem skorları hesaplamakta hem de her kareye önceden tanımlanmış konumsal bir öncelik (prior) uygulamaktadır.

Dikkat skorları üç temel bileşenden oluşmaktadır: öğrenilebilir ağırlıklar, içerik önyargısı ve sabit pozisyon önyargısı. İlk olarak her zaman adımı için dikkat skoru e_t aşağıdaki gibi tanımlanır:

$$e_t = \tanh(\mathbf{x}_t^\top \mathbf{W} + b_t)$$

Burada $\mathbf{W} \in \mathbb{R}^{D \times 1}$ ağırlık matrisi olup, kanallar arası (channel-wise) ortak skor üretir; $b_t \in \mathbb{R}$ ise her zaman adımı için ayrı ayrı öğrenilen içerik önyargısıdır. Bu yapı sayesinde model, zamansal kareler arasında içerik tabanlı önem dereceleri öğrenebilir. Aktivasyon fonksiyonu olarak tanh kullanılması, skoru $(-1, 1)$ aralığında sınırlandırarak stabilite sağlar.

İkinci adımda, bu ham skorlar pozisyonel önbilgi ile çarpılarak normalize edilir ve nihai dikkat katsayısı α_t hesaplanır:

$$\alpha_t = \frac{e^{e_t} \cdot p_t}{\sum_{i=1}^T e^{e_i} \cdot p_i}$$

Burada p_t her zaman adımına karşılık gelen sabit bir pozisyon önyargısıdır ve aşağıdaki gibi tanımlanır:

$$p_t = \exp \left(-\frac{\left(\frac{t}{T} - \mu\right)^2}{2\sigma^2} \right)$$

Bu formül, dizinin ortasında ($\mu = 0.5$) merkezlenen sabit bir Gauss dağılımını temsil eder. $\sigma = 0.2$ parametresi dağılımın yayılımını belirler ve yan karelerin etkisini bastırır (örneğin, $p_1/p_4 \approx 0.14$). Bu yaklaşım sayesinde, düşük sinyal-gürültü oranına sahip uç zaman adımlarının etkisi azaltılır.

Son olarak, dikkatli şekilde ağırlıklandırılmış bağlam vektörü $\mathbf{c}$ aşağıdaki gibi elde edilir:

$$\mathbf{c} = \sum_{t=1}^T \alpha_t \cdot \mathbf{x}_t$$

Bu vektör, önemli zaman adımlarına ait özelliklerin ağırlıklı ortalamasıdır ve sonraki tam bağlı (fully connected) katmanlara aktarılır. $\mathbf{c} \in \mathbb{R}^{B \times D}$ boyutunda olup, her örnek için 128 boyutlu bir dikkat özetini temsil eder.

Bu mimarinin temel avantajları arasında şunlar yer almaktadır: Dikkat parametreleri oldukça hafiftir; sadece $D + T = 135$ öğrenilebilir parametre içerir, bu da toplam model büyüklüğünü %1'den az artırır.

Kanal bazlı ortak dikkat uygulanması, uzamsal özellik tutarlılığını korurken parametre verimliliği sağlar.

Gauss tabanlı sabit konumsal öncelik, öğrenmeye pozitif bir başlangıç yönü sağlar ve dikkat skorlarının zaman içinde daha doğru şekilde oturmasına yardımcı olur.


Sonuç olarak bu katman, LSTM'nin ürettiği zamansal özellik kümesinde yüksek enerjili ve güvenilir kareleri seçici biçimde vurgulayarak, düşük SNR'ye sahip dilimlerin yol açtığı belirsizliği azaltmakta ve sınıflandırma performansını artırmaktadır.

4.3. Radar Görüntüleri için YOLO Nesne Tespiti

Bu alt bölümde, RAD-DAR veri kümesindeki radar görüntülerine YOLO nesne tespit algoritmasının uygulanması detaylandırılmaktadır. YOLO, hız ve doğruluğu ile tanınan, gerçek zamanlı nesne tespiti için geliştirilen son teknoloji bir sistemdir [61]. Yöntem, YOLOv8 modelinin kurulumunu ve eğitimi kapsayarak radar görüntüleri üzerinde nesne tespiti için derin öğrenme yeniliklerinden yararlanmayı amaçlamaktadır.

4.3.1. YOLO Algoritmasının Genel Özeti

YOLO algoritması, nesne tespitini tek aşamalı ve uçtan uca bir yaklaşım olarak ele alır. Geleneksel yaklaşımda, bir görüntü $S \times S$ boyutunda bir ızgaraya bölünür ve her hücre, kendisine düşen bölgede nesne olup olmadığını değerlendirerek sınırlayıcı kutu (bounding box) koordinatlarını ve sınıf olasılıklarını doğrudan tahmin eder [61]. Bu yöntem, hızlı ve birleşik (unified) bir yapı sunarak gerçek zamanlı uygulamalar için büyük avantaj sağlar. Şekil 4.6’da modelin omurga–boyun–başlık katmanlarından oluşan genel mimarisi şematik olarak sunulmuştur.



Şekil 4.6 YOLOv8 Blok Diyagram

YOLOv8, bu mimariyi daha modern bir anlayışla yeniden yapılandırır. Önceki YOLO sürümlerine kıyasla daha az parametre içerir, daha hafiftir ve çapasız (anchor-free) bir yapıya

sahiptir. YOLOv8 mimarisi temel olarak üç ana bileşenden oluşur: omurga (backbone), boyun (neck) ve tespit başlığı (detection head).

Omurga (Backbone) – CSPDarknet ve C2f Blokları Giriş görüntüsü, ilk olarak CSPDarknet mimarisi üzerine kurulu bir omurgadan geçirilir. Burada C2f adı verilen bloklar kullanılır. C2f, kısmi yoğun bağlantı (Cross Stage Partial Connections) ve kanal paylaşımı yoluyla özellikleri derinleştirirken bilgi tekrarını önler. Böylece hesaplama maliyeti azaltılırken özellik zenginliği korunur. Bu yapı sonucunda, görüntünün farklı çözünürlüklerdeki temsilleri elde edilir; örneğin 80, 160, 320 ve 640 kanal genişliklerinde dört farklı ölçekli özellik haritası oluşturulur.

Boyun (Neck) – Çok Ölçekli Özellik Birleştirme Omurgadan çıkan çok ölçekli özellik haritaları, FPN (Feature Pyramid Network – Özellik Piramidi Ağı) ve PAN (Path Aggregation Network – Yol Toplama Ağı) yapılarının birleşiminden oluşan boyun kısmında birleştirilir. FPN yukarı örnekleme yaparken, PAN aşağı örnekleme yapar. Bu çift yönlü bilgi akışı sayesinde, hem küçük hem büyük nesneleri temsil edecek özellikler aynı anda elde edilir.

Tespit Başlığı (Detection Head) – Ayrık ve Çapasız Yapı YOLOv8, her konum için sınıf ve kutu bilgilerini ayrı ayrı işleyen ayrık (decoupled) bir tespit başlığı kullanır. Bu başlık, her bir hücreden gelen özellik vektörlerini iki ayrı dala ayırarak sınıf tahmini (*sınıf öznitelikleri*, $\mathcal{F}_{cls}$) ve kutu tahmini (*konum öznitelikleri*, $\mathcal{F}_{reg}$) üretir. Bu iki dal, konvolüsyon katmanları ile işlendikten sonra tekrar birleştirilerek, her piksel için x ve y merkez koordinatları, genişlik (w), yükseklik (h) ve nesne olasılık skoru (s) tahmin edilir.

Çapa kullanılmadığı için, her tahmin doğrudan öznitelik haritası üzerinde konumlandırılır. Konumlar, piksel bazlı özniteliklerden aşağıdaki şekilde hesaplanır:

$$\hat{x} = \frac{\sigma(p_x) + j}{w}, \quad \hat{y} = \frac{\sigma(p_y) + i}{h}, \quad \hat{w} = e^{p_w}, \quad \hat{h} = e^{p_h}$$

Burada p_x , p_y , p_w ve p_h sırasıyla kutunun x - y merkezi ve boyutlarına dair ham tahmin değerleridir; σ sigmoid fonksiyonu, öngörülerin normalize edilmesini sağlar; i ve j ise öznitelik haritası üzerindeki satır ve sütun konumlarını belirtir.

Kayıp Fonksiyonu ve Optimizasyon YOLOv8'de eğitim süreci üç temel bileşenden oluşan bir toplam kayıp fonksiyonu ile gerçekleştirilir:

$$L = \lambda_{box}L_{IoU} + \lambda_{obj}L_{obj} + \lambda_{cls}L_{cls}$$

- L_{IoU} : Gerçek ve tahmin edilen kutular arasındaki örtüşmeyi ölçmek için kullanılan CIOU (Complete Intersection over Union) metriğidir.
- L_{obj} : Nesnenin varlığına dair ikili çapraz-entropi (Binary Cross Entropy) kaybıdır.
- L_{cls} : Sınıf tahmini için kullanılan dağıtım odaklı kayıptır (Distribution Focal Loss – DFL).

Bu bileşenlerin katkısı, λ katsayılarıyla denetlenir. YOLOv8 konfigürasyonunda bu katsayılar sırasıyla $\lambda_{box} = 7.5$, $\lambda_{obj} = 1.0$, $\lambda_{cls} = 0.5$ olarak belirlenmiştir.

Etiket Atama ve Çıkarım Sonrası İşlem Çapasız yapı nedeniyle, her öznitelik hücreğine hangi nesnenin atanacağı dinamik olarak belirlenir. Bu süreç, görev uyumlu eşleyici (Task-Aligned Assigner) olarak adlandırılan bir mekanizma ile yürütülür. Burada, hem örtüşme miktarı (IoU) hem de sınıf tahmin skoru birlikte değerlendirilerek en uygun eşleştirme yapılır.

Modelin çıkışında aynı nesneye ait birden fazla kutunun tespit edilmesi durumunda, azami olmayan bastırma (Non-Maximum Suppression – NMS) uygulanır. Bu işlemde, nesne skoruyla ağırlıklandırılmış IoU değerlerine göre en güvenilir kutular seçilir, diğerleri elenir.

4.3.2. Uygulama Detayları

Uygulama, Python ortamında PyTorch ve Ultralytics YOLO kütüphaneleri kullanılarak gerçekleştirilmiştir.

YOLOv8 modeli Ultralytics kütüphanesi ile yüklenir ve eğitim parametreleri şu şekilde yapılandırılır:

```
from ultralytics import YOLO

# YOLOv8 modelini yükle
model = YOLO('yolov8n.pt') # Hiz için YOLOv8 nano modeli kullaniliyor

# data.yaml dosyasının yolunu belirt
data_yaml_path = '/content/drive/MyDrive/Dataset_v2/data.yaml'
```

data.yaml dosyası, veri kümesi yapılandırmalarını, sınıf adlarını ve eğitim ile doğrulama görüntülerinin yollarını içerir [62].

Model aşağıdaki parametrelerle eğitilir:

```
# GPU kullanarak modeli eğitin
model.train(
    data=data_yaml_path, # data.yaml dosyasının yolu
    epochs=50,           # Eğitim epoch sayısı
    imgsz=640,           # Eğitim için görüntü boyutu
    batch=16,            # Batch boyutu
    device='0'           # GPU cihazı 0 kullanılır
)
```

Eğitim, model ağırlıklarını optimize ederek kayıp fonksiyonunu minimize etmeyi içerir. Kayıp fonksiyonu; konum kaybı (localization loss), güven kaybı (confidence loss) ve sınıflandırma kaybından (classification loss) oluşur [61].

Eğitimden sonra model, doğrulama kümesi üzerinde değerlendirilir:

```
# Eğitilen modeli doğrulama
model.val(data=data_yaml_path)
```

Doğrulama ölçütleri arasında Kesinlik (Precision), Geri Çağırma (Recall) ve Ortalama Ortalama Doğruluk (mean Average Precision, mAP) yer alır. Bu ölçütler, modelin tespit yeteneklerine dair içgörüler sağlar [63].

Doğrulama sonrası, modelin doğrulama görüntüleri üzerinde tahminlerini görselleştirmek için çıkarım (inference) işlemi yapılabilir:

```
# Dogrulama goruntuleri uzerinde cikarin
val_images_path = '/content/drive/MyDrive/Dataset_v2/images/val'
model.predict(source=val_images_path, save=True)
```

Listing 1 YOLOv8 modeli ile doğrulama görüntüleri üzerinde tahminlerin gerçekleştirilmesi

Eğitilen model, dağıtım amaçları için ONNX formatına dönüştürülür:

```
# Egitilen modeli ONNX formatina aktar
model.export(format='onnx')
```

4.3.3. Radar Görüntülerinde YOLO ile Dron Tespiti Entegrasyonu

Bu çalışmada, RAD-DAR veri kümesindeki radar görüntülerine YOLO (You Only Look Once) nesne tespit algoritmasının uygulanması incelenmiştir. Veri kümesi, YOLO'nun sıkı anotasyon gereksinimlerini karşılayacak şekilde titizlikle düzenlenmiştir; her radar görüntüsü, sınırlandırma kutusu (bounding box) koordinatlarını ve ilgili sınıf etiketlerini detaylandıran bir metin dosyası ile eşleştirilmiştir [62]. Normalizasyon ve gürültü azaltma gibi ön işleme adımları, görüntü özelliklerini iyileştirmek ve radar görüntülerinin karakteristik özelliği olan speckle gürültüsü ve düşük çözünürlüğün etkilerini hafifletmek için uygulanmıştır.

Radar görüntülerine YOLO uygulamak çeşitli zorluklar getirir. Optik görüntülerden farklı olarak, radar görüntüleri anotasyon ve özellik çıkarma işlemini zorlaştıran bozulmalar içerebilir. Ayrıca, modelin çeşitli çevresel koşullarda ve değişen dron görünümünde iyi bir genelleme yeteneği sağlaması, sağlam performans elde etmek için kritik öneme sahiptir [11, 12].

Son alıřmalar, derin ğrenme yntemlerinin optik olmayan alanlardaki potansiyelini vurgulamaktadır. rneğın, Kang ve arkadaşları, otomotiv radar verilerinde CNN'lerin etkin kullanımını gstermiřtir [12], Xiao ve arkadaşları ise sonar grntlerinde YOLO'yu bařarıyla uyarlamıřtır [11]. Bu bulguları destekleyen Zhang ve arkadaşları, CNN mimarileri kullanarak FMCW radar verilerinde gerek zamanlı dron tespiti konusunda umut verici sonular bildirmiřtir [25]. Bu arařtırmalar, yaklařımımız iin gl bir temel saėlamaktadır.

YOLO'yu radar grnt analizi erevemize entgre ederek, gerek zamanlı tespit, hassas konum belirleme ve gvenilir dron sınıflandırması saėlamayı hedefliyoruz. Bu yntem, radar verilerinin isel zorluklarını ele almakla kalmayıp, aynı zamanda gvenlik ve savunma uygulamalarında durumsal farkındalıėı artırmayı da amalamaktadır.


4.4. RT-DETR ile Radar Grntlerinde Nesne Tespiti

RT-DETR (Gerek Zamanlı Tespit Transformatr), geleneksel DETR (Detection Transformer - Algılama Trafosu) mimarisinin yksek hesaplama maliyetlerini azaltarak gerek zamanlı nesne tespiti iin optimize edilmiř ilk utan uca Transformer tabanlı dedektrdr. Bu model, radar grntleri gibi karmařık ve dřk znrlkl verilerde etkili nesne tespiti saėlamak amacıyla geliřtirilmiřtir [64].

4.4.1. RT-DETR Mimarisi ve Temel Bileřenleri

RT-DETR, klasik DETR yapısının yksek hesaplama ykn azaltmak zere geliřtirilmiř, utan uca alıřan ve zellikle gerek zamanlı uygulamalar iin optimize edilmiř bir dnřtrc tabanlı tespit mimarisidir. Bu yapı, radar gibi dřk znrlkl ve yksek grltl verilerde etkili tespit performansı sunmak amacıyla tasarlanmıřtır.

řekil 4.7'de modelin Verimli Hibrit Kodlayıcısı, IoU-duyarlı Sorgu Seimi modl ve drt katmanlı zc-Bařlık (decoder head) bileřenlerinden oluřan genel yapısı řematik olarak gsterilmektedir.



Şekil 4.7 RT-DETR Blok Diyagram

1. Verimli Hibrit Kodlayıcı (Efficient Hybrid Encoder) Giriş radar görüntüsü ilk olarak CSPDarknet-P6 tabanlı evrişimli sinir ağı (CNN) ile yüksek, orta ve düşük olmak üzere üç farklı çözünürlükte öznetelik haritasına dönüştürülmektedir. Bu haritalar sırasıyla F_8 , F_{16} ve F_{32} olarak adlandırılarak ve her biri 256 kanala eşlenmektedir. Ardından, bu haritalar sırayla düzleştirilerek (flatten) ve konumsal kodlama (sine-cosine positional encoding) eklenip dönüştürücüye (transformer) sunulmaktadır.

$$\mathbf{Z}_0 = [\text{Kod}(\mathbf{F}_8) \parallel \text{Kod}(\mathbf{F}_{16}) \parallel \text{Kod}(\mathbf{F}_{32})] \in \mathbb{R}^{L \times 256}$$

Burada $\parallel$ birleşimi, L ise toplam uzamsal konum sayısını belirtmektedir. Kodlayıcı yalnızca dört dönüştürücü katmanından oluşarak ve her katman çok başlı kendi kendine dikkat (multi-head self-attention) ile yerel öznetelik öğrenimini destekleyen 3×3 evrişimli ileri beslemeli katman (convolutional feed-forward network) içermektedir. Bu hibrit yapı, hem küresel bağlamı hem de yerel yapıyı aynı anda öğrenerek bilgi kaybını azaltmaktadır.

2. IoU Duyarlı Sorgu Seçimi (IoU-Aware Query Selection) Klasik DETR mimarisinde, tespit için kullanılan sorgular sabit sayıda ve sabit biçimde başlatılırken, RT-DETR modeli daha verimli bir yaklaşım benimsemektedir. Özellikle, Z_0 içinden yalnızca en anlamlı sorgular seçilmektedir. Bu seçim, her konumun tahmini kutusunun gerçek kutuyla olan IoU ve nesneye ait olma skoru birlikte hesaplanarak yapılmaktadır.

$$s_i = \beta \cdot \text{IoU}_i + (1 - \beta) \cdot \text{Güven}_i$$

Buradaki β , iki ölçütün ağırlık dengesini belirlemektedir. En yüksek skora sahip sorgular, Top-K seçimiyle ayıklanarak çözücüye aktarılmaktadır. Bu yöntem sayesinde gereksiz sorgular elenerek, hesaplama yükü azaltılarak daha hedefli öğrenme sağlanmaktadır.

Yukarıdaki denklemde, $\beta \in [0, 1]$ değeri, örtüşme (IoU) ölçütü ile sınıf güveninin göreceli katkısını dengeleyen tek serbest parametredir. Varsayılan yapılandırmada $\beta_{\text{def}} \approx 0.65$ kullanılır, bu da IoU bilgisini ağırlık merkezine yerleştirirken sınıf olasılığını tamamen dışlamayacak bir orta yol sağlar.

- **Yüksek β ($\beta \gtrsim 0.8$):** Sorgu seçimi neredeyse yalnızca geometrik örtüşmeye dayalı gerçekleşir. Kümeleşmiş ya da kalabalık sahnelerde (birbirine yakın çoklu hedef) yanlış eşleştirme riskini düşürür, ancak az sayıda belirgin hedef bulunan sahnelerde düşük güven skorlu kutuları da seçebileceği için yalancı-pozitif (FP) artışına yol açabilir.
- **Düşük β ($\beta \lesssim 0.4$):** Sınıf güveni baskın hâle gelir; zayıf sınıf skoruna sahip ancak yüksek örtüşmeli kutular elenir. Bu ayar, hedef yoğunluğunun az olduğu veya arka-plan gürültüsünün fazla olduğu verilerde FP'yi azaltır, fakat örtüşen nesneleri ayırmakta (özellikle küçük dronlar) geri çağırma kaybına yol açabilir.

Dolayısıyla β , IoU-öncelik (geometrik tutarlılık) ile sınıf güveni (semantik tutarlılık) arasında uygulamaya özgü bir anlaşma sunar, varsayılan 0.65 değeri, RAD-DAR benzeri orta yoğunluklu radar sahnelerinde dengeli sonuç vermesi amacıyla seçilmiştir.

3. Çözücü Katmanı (Decoder) ve Kutu Tahmini Seçilen her sorgu vektörü, çok başlı çapraz dikkat (multi-head cross attention) uygulayarak kodlayıcıdan gelen özniteliklerle etkileşime girmektedir. Dört katmanlı çözücü sonunda her sorgu için iki tür çıktı elde edilmektedir: sınıf tahmini ve nesne kutusu parametreleri. Kutu parametreleri normalize edilmiş şekilde $[p_x, p_y, p_w, p_h]$ olarak ifade edilerek, sonradan gerçek piksel boyutuna geri ölçeklendirilmektedir.

4. Kayıp Fonksiyonu ve Eşleştirme Stratejisi RT-DETR, öğrenme sürecinde tüm tahmini kutuları zemin gerçek (ground truth) kutularla eşleştirmek için çift yönlü eşleştirme (Hungarian matching) algoritmasını kullanmaktadır. Her sorgu ile eşleşecek gerçek kutu, aşağıdaki toplam kayıp değeri üzerinden belirlenmektedir:

$$C_{eşleşme} = \lambda_{sınıf} \cdot L_{CE} + \lambda_{kutu} \cdot L_{L1} + \lambda_{IoU} \cdot (1 - IoU)$$

Burada:

- L_{CE} : Sınıf etiketleri için çapraz entropi (cross-entropy) kaybı,
- L_{L1} : Kutunun koordinat hatası için L1 normu,
- IoU : Tahmin ile zemin gerçeğin örtüşme oranı.

Varsayılan ağırlıklar $\lambda_{sınıf} = 2.0$, $\lambda_{kutu} = 5.0$ ve $\lambda_{IoU} = 2.0$ olarak belirlenmiştir.

4.4.2. RT-DETR Modelinin Uygulaması

RAD-DAR veri kümesinde, RT-DETR'nin 'Large' varyantı kullanılarak 50 epoch boyunca eğitim gerçekleştirilmiştir (640×640 piksel, batch boyutu 16). Eğitim süreci, modelin radar görüntülerindeki dron, insan ve araç gibi nesneleri yüksek doğrulukla tespit edebilmesini sağlamıştır. Transformer tabanlı yapısına rağmen, RT-DETR-Large modeli GPU üzerinde 30

FPS'nin üzerinde çıkarım hızı sunarak gerçek zamanlı uygulamalar için uygun bir alternatif oluşturmuştur.

```
from ultralytics import RTDETR
model = RTDETR('/content/drive/MyDrive/Dataset_v2/rt detr-1.pt')
model.train(
    data='/content/drive/MyDrive/Dataset_v2/data.yaml',
    epochs=50, imgsz=640, batch=16, device=0, val=True)
```

RT-DETR'nin Transformer tabanlı yapısı, YOLOv8'e göre daha yüksek FLOPs ve bellek ister; ancak *Large* varyantı için bile 30 FPS+ GPU çıkarımı rapor edilmiştir. Böylece hem gerçek-zamanlı hem de uçtan-uca optimizasyon gerektiren güvenlik senaryoları için uygun bir alternatif sunmuştur.


5. DENEYSEL SONUÇLAR

Bu bölümde, RAD-DAR test kümesinde eğitilen dört farklı derin-öğrenme mimarisinin (klasik CNN, zamansal CNN-LSTM-Attention, YOLOv8 ve Transformer-tabanlı RT-DETR) ayrıntılı deneysel çıktıları sunulmaktadır. Her alt başlıkta önce eğitim-doğrulama metrikleri ve karmaşıklık matrisleri verilmekte, ardından tipik yanlış eşleştirme örnekleri incelenerek modellerin güçlü ve zayıf yönleri tartışılmaktadır. Son olarak toplu tablolar aracılığıyla kesinlik, geri çağırma, F1 ve mAP skorları karşılaştırılarak en yüksek başarıyı sağlayan yaklaşım belirlenmiştir. Karmaşıklık matrisleri ve bunlar üzerinden hesaplanan performans ölçütleri tabloları, veri kümesi üzerinde gerçekleştirilen 5 katmanlı çapraz doğrulama (5-fold cross-validation) süreci sonunda elde edilen değerlerin ortalaması alınarak raporlanmıştır. Sınıf bazlı sonuç tablolarında gösterilen her bir metrik için $\pm$ gösterimiyle verilen değerler, çapraz doğrulama sürecindeki katmanlar arasında hesaplanan standart sapmaları yansıtmaktadır. Bu sayede, her modelin sınıf bazında gösterdiği performansın hem ortalama düzeyi hem de istatistiksel kararlılığı değerlendirilmiştir.

5.1. CNN Sonuçları ve Performans Analizi

Radar görüntülerini kullanarak dron tespiti için CNN modelinin performans analizi sunulmaktadır. Sonuçlar doğruluk, kayıp ve kesinlik-geri çağırma ölçütlerini içermektedir.


Eğitim performansı Şekil 5.1’de sunulmaktadır.



Şekil 5.1 CNN Modeli İçin 50 Epok Boyunca Eğitim Kaybı ve Doğruluk Eğrisi

Eğitim doğruluğu istikrarlı bir şekilde artmakta ve 50 epok sonunda yaklaşık olarak %97 seviyesine ulaşmaktadır. Aynı zamanda, kayıp önemli ölçüde azalmakta ve 0.1 seviyesinde sabitlenmektedir. Bu durum, modelin önemli ölçüde aşırı öğrenme olmaksızın etkili bir şekilde öğrendiğini göstermektedir.

Karmaşıklık matrisi Şekil 5.2, test verisi üzerinde sınıflandırma performansının genel bir görünümünü sunmaktadır.



Şekil 5.2 CNN Modelinin Araçlar, Dronlar ve İnsanlar Sınıflarında Sınıflandırma Performansını Gösteren Karmaşıklık Matrisi


Model, **İnsanlar** sınıfında yüksek performans sergilemektedir ve bunu **Araçlar** ve **Dronlar** sınıfları takip etmektedir. Yanlış sınıflandırmalar ağırlıklı olarak **Araçlar** ve **Dronlar** arasında gerçekleşmektedir.

Test sonuçları Tablo 5.1’de verilmiştir. Bu tabloya göre, CNN modeli tüm sınıflarda yüksek kesinlik, geri çağırma ve F1 skoru ile güçlü bir sınıflandırma performansı sergilemektedir. Kesinlik ve geri çağırma değerleri, modelin radar görüntülerinde nesneleri doğru şekilde tanımlama yeteneğini vurgulamaktadır. Tabloda bulunan $\pm$ değerler, 5-katlı çapraz doğrulama sonucunda elde edilen standart sapmaları göstermekte olup, modelin farklı veri bölümlerindeki istatistiksel kararlılığını ortaya koymaktadır.

Tablo 5.1 Radar Veri Kümesi Üzerinde CNN Performans Ölçütleri

Sınıf	Görüntü Sayısı	Kesinlik (%)	Geri Çağırma (%)	F1 Skoru (%)
Araç	1145	96.61 $\pm$ 2.12	84.63 $\pm$ 3.14	90.22 $\pm$ 1.90
Dron	1045	86.06 $\pm$ 1.24	98.19 $\pm$ 1.08	91.73 $\pm$ 0.83
İnsan	1307	98.62 $\pm$ 0.50	98.32 $\pm$ 0.40	98.47 $\pm$ 0.32
Tümü	3497	93.76 $\pm$ 1.29	93.68 $\pm$ 1.54	93.72 $\pm$ 1.02

5.1.1. Uyumsuz Eşleştirme Örnekleri




Şekil 5.3 CNN Uyumsuz Eşleştirme Örnekleri

CNN modeli, Şekil 5.3'te görülen tüm araç örneklerini dron olarak sınıflandırmıştır. Bu yanlış eşleşmelerin temel sebebi, kullanılan radar verilerinin yeterli kalitede olmamasıdır.

Özellikle, düşük çözünürlüklü ve gürültülü radar görüntüleri, modelin özellikleri doğru şekilde ayırt edememesine neden olmuştur. Radar tabanlı nesne tespiti, hedeflerin boyutu, hareket örüntüsü ve radar kesit alanına bağlı olarak değişkenlik gösterebilir. Veri kümesindeki bazı araçların düşük hız veya durağan konumda olması, Doppler kaymalarının belirgin olmamasına neden olmuş ve bu durum, modelin araçları dronlarla karıştırmasına yol açmıştır. Ayrıca, bazı araçların görüntüleri ile dronlara ait görüntülerin renk yoğunlukları benzerlik göstermektedir. Bu durum, CNN modelinin ayırt edici özellikleri yeterince yakalayamamasına ve yanlış tahminlerde bulunmasına sebep olmuştur.

5.2. CNN-LSTM-Attention Modeli Sonuçları ve Performans Analizi

Bu bölümde, radar görüntülerini kullanarak dron tespiti için CNN-LSTM-Attention modelinin performans analizi sunulmaktadır. Sonuçlar doğruluk, kayıp ve kesinlik-geri çağırma ölçütlerini içermektedir. Eğitim performansı Şekil 5.4'te gösterilmektedir.



Şekil 5.4 CNN-LSTM-Attention Modeli İçin 40 Epok Boyunca Eğitim Kaybı ve Doğruluk Eğrileri


Eğitim doğruluğu hızla artmakta ve 40 epok sonunda %95'in üzerine çıkmaktadır. Kayıp ise tutarlı bir şekilde azalarak 0.2 seviyesinde sabitlenmektedir. Bu durum, modelin aşırı öğrenme olmaksızın etkili bir şekilde öğrendiğini göstermektedir.

Test sonuçları Tablo 5.2’de verilmiştir. Tablodaki metrikler, 5 katlı çapraz doğrulama katmanlarından elde edilen ortalama değerlerdir; her ölçütün yanındaki “±” ise aynı katmanlar arasındaki standart sapmayı gösterir. Böylece hem modelin ortalama başarımı hem de farklı veri bölümlerindeki kararlılığı nicel olarak sunulmuş olur. Tablo’da görüldüğü üzere, CNN-LSTM-Attention modeli tüm sınıflarda yüksek kesinlik, geri çağırma ve doğruluk değerleri ile sağlam bir sınıflandırma performansı göstermektedir. Model, test veri kümesine etkin bir şekilde genelleme yapabilmekte ve eğitim süreci boyunca güçlü öğrenme özellikleri sergilemektedir. LSTM bileşeninin eklenmesi, geçici özellik öğrenimini geliştirmiş ve CNN modeline kıyasla genel performansı artırmıştır.

Tablo 5.2 Radar Veri Kümesi Üzerinde CNN–LSTM–Attention Performans Ölçütleri

Sınıf	Görüntü Sayısı	Kesinlik (%)	Geri Çağırma (%)	F1 Skoru (%)
Araç	1145	94.24 ± 1.90	94.24 ± 1.80	94.24 ± 1.31
Dron	1045	94.04 ± 2.64	95.12 ± 2.96	94.58 ± 2.00
İnsan	1307	98.84 ± 0.70	97.93 ± 0.80	98.38 ± 0.53
Tümü	3497	95.90 ± 1.75	95.88 ± 1.85	95.89 ± 1.28


Karmaşıklık matrisi Şekil 5.5, sınıflandırma performansının genel bir görünümünü sunmaktadır.



Şekil 5.5 CNN-LSTM-Attention modelinin Araçlar, Dronlar ve İnsanlar Sınıflarında Sınıflandırma Performansını Gösteren Karmaşıklık Matrisi

Model, tüm sınıflar için güçlü sınıflandırma performansı sergilemekte ve yanlış sınıflandırmalar minimum seviyede kalmaktadır. Yanlış sınıflandırmalar, genellikle **Araçlar** ve **Dronlar** sınıfları arasında gerçekleşmektedir.

5.2.1. Dikkat Mekanizmasının Öğrendiği Bilgiler




Şekil 5.6 CNN-LSTM-Attention Modeli İçin Dikkat Ağırlıklarının Görselleştirilmesi

Şekil 5.6’da, modelin giriş verisindeki farklı zaman adımlarına verdiği dikkat ağırlıkları gösterilmektedir. Her bir zaman adımı (x eksen), modelin sıralı verileri nasıl işlediğini temsil ederken, y eksen bu zaman adımlarına verilen dikkat skorlarını göstermektedir.

Dikkat mekanizması, özellikle 3. zaman adımına yüksek ağırlık atayarak, bu zaman diliminin sınıflandırma için en önemli bilgi taşıyan bölge olduğunu göstermektedir. Model, erken (0 ve 1. zaman adımları) ve geç (5 ve 6. zaman adımları) adımlara daha düşük ağırlık atamıştır. Bu durum, modelin orta zaman dilimindeki bilgiyi daha önemli gördüğünü ortaya koymaktadır.

5.2.2. Uyumsuz Eşleştirme Örnekleri



Şekil 5.7 CNN-LSTM-Attention Modeli Uyumsuz Eşleştirme Örnekleri

Şekil 5.7’de görüldüğü gibi, CNN-LSTM-Attention modeli, nesneleri ayırt etme konusunda CNN modeline kıyasla daha gelişmiş bir yapı sunsa da benzer yanlış eşleşmeler yapmaktadır. Model, bazı araç ve insan örneklerini dron olarak sınıflandırmış ve bazı insan görüntülerini araç olarak etiketlemiştir. Bu yanlış eşleşmelerin temel sebebi, kullanılan radar verilerinin yeterli kalitede olmamasıdır. Özellikle, düşük çözünürlüklü ve gürültülü radar görüntüleri, modelin ayırt edici özellikleri doğru şekilde yakalayamamasına neden olmuştur.

Radar tabanlı nesne tespiti, hedeflerin boyutu, hareket paterni ve radar kesit alanına bağlı olarak değişkenlik gösterebilir. Veri kümesindeki bazı araçların düşük hızda veya durağan konumda olması, Doppler kaymalarının belirgin olmamasına neden olmuş ve bu durum, modelin araçları dronlarla karıştırmasına yol açmıştır. Benzer şekilde, bazı insan görüntülerinin radar yansıma özellikleri dronlarla örtüşebilmektedir. Bu tür durumlar, modelin hata yapmasına neden olmuş ve özellikle zayıf radar geri dönüşlerine sahip hedeflerde yanlış eşleşmelere sebebiyet vermiştir.

CNN-LSTM-Attention modeli, LSTM katmanı sayesinde zamansal bilgiyi daha iyi yakalasa ve Attention mekanizması ile önemli özelliklere daha fazla odaklansa da veri kalitesindeki eksiklikler nedeniyle bazı yanlış eşleşmeler kaçınılmaz olmuştur. Modelin genel performansı CNN'e göre daha iyi olsa da, düşük çözünürlüklü ve gürültülü veriler bu tür hataların temel nedenlerinden biridir.

5.3. YOLOv8 Sonuçları ve Performans Analizi


YOLOv8 modeli, RAD-DAR veri kümesi üzerinde eğitilmiş ve test edilmiştir. Hedef sınıflar *dronlar*, *araçlar* ve *insanlardır*. Aşağıdaki alt bölümlerde eğitim metrikleri, test sonuçları ve performans analizi sunulmaktadır.

5.3.1. Eğitim Metrikleri


YOLOv8 modeli, RAD-DAR veri kümesi üzerinde dron, araç ve insan sınıflarını tespit etmek amacıyla eğitilmiştir. Eğitim sürecinde modelin performansı, kayıp fonksiyonu, mAP ve kesinlik-geri çağırma eğrileri kullanılarak değerlendirilmiştir. Sınır kutusu regresyonu, sınıflandırma ve dağıtım odak kaybı (DFL) değerleri, 50 epoch boyunca düzenli bir şekilde azalarak başarılı bir yakınsama sağlamıştır. Eğitim sırasında mAP@50 ve mAP@50-95 değerleri istikrarlı şekilde artmış ve yaklaşık 20. epoch sonrasında yüksek bir doğruluk seviyesine ulaşmıştır. Kesinlik ve geri çağırma oranları da tüm epochlar boyunca yüksek kalmış ve modelin tespit güvenilirliğinin güçlü olduğunu göstermiştir. Şekil 5.8 kayıplardaki

düşüş trendini ayrıntılı biçimde sunmaktadır. Şekil 5.9 mAP metriklerinin hızlı artışı ve yakınsamasını göstermektedir.


Şekil 5.10 ise kesinlik ve geri çağırma oranlarının sabit yüksek seviyelerde korunduğunu kanıtlamaktadır. Bu metrikler birlikte değerlendirildiğinde, YOLOv8'in hem eğitim sürecinde hem de son performans ölçümlerinde kararlı ve başarılı bir ilerleme gösterdiği görülmektedir. Sonuç olarak, model eğitim boyunca aşırı öğrenme (*overfitting*) belirtisi göstermemiş ve genelleme kapasitesini korumuştur.



Şekil 5.8 YOLOv8 Modeli İçin Eğitim Kayıp metrikleri (Box Loss, Class Loss ve DFL Loss)




Şekil 5.9 YOLOv8 Modeli İçin mAP Metrikleri (mAP@50 ve mAP@50-95)



Şekil 5.10 YOLOv8 İçin Eğitim Sırasında Kesinlik ve Geri Çağırma Eğrileri

5.3.2. Uyumsuz Eşleştirme Örnekleri



Şekil 5.11 YOLOv8 Uyumsuz Eşleştirme Örnekleri

Şekil 5.11’de görüldüğü gibi, YOLOv8 modeli önceki CNN ve CNN-LSTM-Attention modellerine kıyasla daha iyi ayırt edici performans göstermektedir. Ancak model, bazı araç örneklerini yanlış sınıflandırmıştır. Bu hatalar, radar verilerinin sınırlamalarından kaynaklanmaktadır ve düşük Doppler kontrastına sahip örneklerde belirginleşmektedir. YOLOv8’in genel doğruluğu yüksek olmasına rağmen, daha hassas radar özellikleri ve ek veri iyileştirmeleri ile hataların azaltılması mümkündür.


5.3.3. Test Sonuçları

YOLOv8'in test kümesi üzerindeki performansı Tablo 5.3'te özetlenmiştir. Tabloya verilen değerler, 5-katlı çapraz doğrulama katmanlarından elde edilen ortalama metriklerdir; her ölçütün yanındaki $\pm$ işareti ise aynı katmanlar arasındaki standart sapmayı göstererek modelin farklı veri bölümlerindeki kararlılığını nicel olarak yansıtmaktadır. Genel metriklerle birlikte sınıfa özel sonuçlar aşağıda tartışılmaktadır:

Tablo 5.3 Radar Görüntü Veri Kümesi Üzerinde YOLOv8 Performans Ölçütleri


Sınıf	Görüntü Sayısı	Kesinlik (%)	Geri Çağırma (%)	F1 Skoru (%)
Araç	1145	97.19 $\pm$ 1.45	93.58 $\pm$ 1.58	95.35 $\pm$ 1.07
Dron	1045	100.00 $\pm$ 0.00	99.33 $\pm$ 0.30	99.66 $\pm$ 0.15
İnsan	1307	99.85 $\pm$ 1.22	99.77 $\pm$ 2.20	99.81 $\pm$ 1.26
Tümü	3497	99.01 $\pm$ 0.89	97.56 $\pm$ 1.36	98.28 $\pm$ 0.83

F1-güven eğrisi, her hedef sınıf için F1 skorunun farklı güven eşiklerine göre ilişkisini göstermektedir (Şekil 5.12). Tüm sınıflar için en yüksek F1 skoru 0.98 olup, 0.345 güven eşikinde elde edilmiştir. Bu optimum eşik, modelin tüm hedef sınıflarda maksimum tespit doğruluğu sağlama yeteneğini yansıtmaktadır.




Şekil 5.12 YOLOv8 İçin F1-Güven Skoru Eğrisi

Kesinlik-duyarlılık eğrisi, YOLOv8'in tespit performansını daha ayrıntılı bir şekilde ortaya koymaktadır (Şekil 5.13). Tüm sınıflar için ortalama doğruluk (mAP@0.5) 0.9756 olup, modelin yüksek kesinlik sağlarken önemli sayıda doğru pozitif tespiti yakalayabildiğini göstermektedir. Bireysel sınıflar arasında dronlar neredeyse mükemmel kesinlik-duyarlılık özellikleri sergilerken, araçlar kesinlik açısından hafif bir denge kaybı göstermektedir.



Şekil 5.13 YOLOv8 İçin Precision-Recall Eğrisi.

Daha ayrıntılı bir inceleme için, Şekil 5.14'teki karmaşıklık matrisi her hedef sınıf için sınıflandırma performansını görselleştirmektedir. Sonuçlar, tahminler ile gerçek etiketler arasında güçlü bir uyum olduğunu ve yalnızca sınırlı sayıda yanlış sınıflandırmanın meydana geldiğini göstermektedir.



Sonuç: Şekil 5.14 incelendiğinde, YOLOv8 modelinin CNN ile CNN–LSTM–Attention mimarilerine kıyasla **en yüksek ayırt edici performansı** sergilediği görülmektedir. Model, **dron** sınıfında 1038/1045 doğru tahminle neredeyse hatasız sonuç vermiş (%100 kesinlik, %99,33 geri çağırma); **insan** sınıfında ise yalnızca üç yanlış eşleşmeyle %99,77 geri çağırma ve %99,85 kesinlik sağlamıştır (1304/1307).

Görel olarak en çok hata **araç** sınıfında gözlenmiş; toplam 1 145 gerçek araç örneğinin 73’ü *arkaplan* olarak etiketlenirken 31 arkaplan yansıması da araç olarak sınıflandırılmıştır. Bu durum, düşük radar kesit alanına sahip veya zayıf geri dönüşlü hedeflerin model tarafından bastırılmasından kaynaklanabilir. Sinyal–gürültü oranını artıran ön–işleme adımları ya da hedef bölgede odaklanmayı kuvvetlendiren veri artırma stratejileri, özellikle araç–arkaplan ayrımındaki bu hataları azaltmada etkili olacaktır.


5.4. RT-DETR Sonuçları ve Performans Analizi

Bu alt bölümde, RAD-DAR veri kümesi üzerinde yeniden-eğitilen RT-DETR-Large modelinin eğitim dinamikleri, doğrulama eğrileri, karmaşıklık matrisi ve sınıf-bazlı metrikleri ayrıntılı olarak incelenecektir. Kayıp eğrilerinin yakınsama hızı, optimum güven eşiği, mAP-F1 başarımı ile düşük SNR'li senaryolarda ortaya çıkan tipik hatalar değerlendirilerek, Transformer tabanlı mimarinin YOLO ailesine kıyasla sunduğu kazançlar tartışılacaktır.

5.4.1. Eğitim Metrikleri


Transformer tabanlı RT-DETR, klasik YOLO ailesine kıyasla *DETR* mimarisinin uçtan-uca optimizasyon avantajlarını gerçek-zaman hızlarında sunmayı hedefleyen bir dedektördür. Bu bölümde, **Large** ön-eğitimli ağırlık (`rt detr --l.pt`) 50 epok boyunca RAD-DAR veri kümesinde yeniden-eğitilmiş modelin nicel ve nitel performansları sunulmuştur.

Şekil 5.15 GIoU, CLS ve L1 alt kayıplarının her epoch boyunca hızlı bir şekilde azalarak < 0.25 seviyesine yakınsadığını göstermektedir. Özellikle sınıflandırma kaybındaki (turuncu) dramatik ilk düşüş, transfer öğreniminin erken evrede ağırlık semantik ayrımı hızla kavradığını doğrular.




Şekil 5.15 RT-DETR İçin Epok Kayıp Eğrileri

Şekil 5.16’da görüldüğü gibi, keskin kayıp düşüşüne paralel olarak kesinlik (mavi) ve geri çağırma (turuncu) metrikleri 7–10. epokta %98 üzerine çıkarak son 40 epok boyunca 98.8 ± 0.1 bandında kararlı kalmıştır. Bu durum, *hızlı yakınsama* ve *gecikmeli aşırı-öğrenme* riskinin düşük olduğunu vurgular.




Şekil 5.16 Epok Bazında Kesinlik ve Geri Çağırma Eğrileri

Şekil 5.17’deki PR eğrileri, *dron*, *insan* ve *araç* sınıflarının hemen tamamında (hat düz çizgi) $AP_{50} > 0.98$ sınırında toplanmıştır. Ortalama doğruluk ($mAP@0.5$) %98.7 olup YOLOv8’den 1 puan yüksek seviyededir.



Şekil 5.17 RT-DETR İçin Sınıf Bazlı Kesinlik–Geri Çağırma Eğrileri


Benzer şekilde Şekil 5.18’deki F1–güven eğrisinde **optimum eşik** 0.573’de $F1 = 0.99$ elde edilmiştir. Bu eşik, radar tabanlı güvenlik uygulamalarında en iyi *doğru-pozitif/yanlış-pozitif* dengesini sunar.



Şekil 5.18 RT-DETR Modeli için F1–Güven Skoru Eğrisi

5.4.2. Test Sonuçları

Şekil 5.19 RT-DETR'in dört sınıflı (dron, araç, insan, arkaplan) karmaşıklık matrisini yüzde karşılıklarıyla sunar.



Şekil 5.19 RT-DETR Modeli Karmaşıklık Matrisi

- **Dron:** 1045/1045 doğru (%**100**); model bu sınıfta *hiç* yanlış negatif veya yanlış pozitif üretmemiştir.
- **İnsan:** 1305/1307 doğru (%**99.85**); yalnızca 2 insan eko-karesi *arkaplan* olarak atlanmış, 3 arkaplan hücresi ise yanlışlıkla *insan* olarak etiketlenmiştir (%99.77 kesinlik).
- **Araç:** 1102/1145 doğru (%**96.24**); model 43 aracı *arkaplan* olarak gözden kaçırmış, ayrıca 18 arkaplan hücresini *Araç* diye işaretleyerek kesinliği %98.39'a düşürmüştür.

Tablo 5.4, RT-DETR ağının RAD-DAR test kümesindeki ayrıntılı performansını özetlemektedir. 5-katlı çapraz doğrulama sürecinde her katman için ayrı ayrı hesaplanan metriklerin ortalaması alınmış, tablodaki $\pm$ değerleri ise katmanlar arasındaki standart sapmaları göstermektedir. Model, *dron* sınıfında hem kesinlik hem de geri çağırma bakımından **%100**'lük kusursuz bir başarıya ulaşarak hava sahası güvenliği açısından kritik öneme sahip küçük hedefleri eksiksiz tespit ettiğini göstermiştir. *İnsan* sınıfında da %99.77 kesinlik ve %99.85 geri çağırma ile neredeyse hatasız bir performans sergilemektedir. Buna karşın *araç* sınıfında kesinlik %98.39 iken geri çağırma %96.24'e düşmüştür; bu fark, düşük Doppler izli 43 aracın model tarafından *arkaplan* olarak reddedilmesinden kaynaklanmaktadır. Yine de genel olarak elde edilen %99.40 kesinlik, %98.71 geri çağırma ve %99.05'lik F1 skoru, RT-DETR'in radar tabanlı hedef tespitinde yüksek doğruluklu ve dengeli bir çıktı sunduğunu ortaya koymaktadır.

Tablo 5.4 Radar Görüntü Veri Kümesi Üzerinde RT-DETR Performans Ölçütleri

Sınıf	Görüntü Sayısı	Kesinlik (%)	Geri Çağırma (%)	F1 Skoru (%)
Araç	1145	98.39 $\pm$ 0.82	96.24 $\pm$ 0.67	97.30 $\pm$ 0.53
Dron	1045	100.00 $\pm$ 0.00	100.00 $\pm$ 0.00	100.00 $\pm$ 0.00
İnsan	1307	99.77 $\pm$ 0.52	99.85 $\pm$ 0.76	99.81 $\pm$ 0.46
Tümü	3497	99.40 $\pm$ 0.45	98.71 $\pm$ 0.48	99.05 $\pm$ 0.33

6. SONUÇLAR VE KARŞILAŞTIRMA

Bu bölümde, dört farklı derin öğrenme yaklaşımımızın (CNN, CNN-LSTM-Attention, YOLOv8 ve RT-DETR) RAD-DAR verisi üzerindeki tespit ve sınıflandırma performanslarını nicel olarak karşılaştırılmıştır. İlk olarak Tablo 6.1 üzerinden temel başarı ölçütlerini (kesinlik, geri çağırma, F1, mAP) özetleyip modellerin güçlü-zayıf yönlerini, hesaplama maliyetlerini ve hata örüntülerini tartışarak; ardından RT-DETR sonuçlarımızı DopplerNet, YOLO-RD ve ConvLSTM-ECA gibi güncel literatür çalışmalarıyla kıyaslayarak elde edilen iyileştirmeler ortaya koyulmuştur. Son kısımda, bulguların pratik uygulamalara etkisini vurgulayıp gelecekte izlenecek araştırma hatlarını kısaca değerlendirilmiştir.

6.1. Geliştirilen Yöntemlerin Karşılaştırması

6.1.1. Genel Karşılaştırma

Tablo 6.1’de yer alan sayılar, RAD-DAR veri kümesi üzerinde uygulanan 5-katlı çapraz doğrulama deneylerinde her katman için hesaplanan metriklerin ortalama değerleridir. Her sonucun yanındaki “ $\pm$ ” ifadeleri ise aynı katmanlar arasındaki standart sapmayı göstererek modellerin performans kararlılığını nicel biçimde ortaya koymaktadır. Özetle tablo, RT-DETR’in tüm metriklerde en yüksek ortalamaları yakaladığını; özellikle dron sınıfında %100 kesinlik, geri çağırma ve F1 ile kusursuz bir sonuç elde ettiğini göstermektedir. YOLOv8 bu başarıyı çok yakından izlerken, CNN-LSTM-Attention orta düzey, temel CNN ise giriş düzeyi performans sergilemiştir.

Model	Sınıf	Kesinlik (%)	Geri Çağırma (%)	F1 Skoru (%)
CNN	Araç	96.61 $\pm$ 2.12	84.63 $\pm$ 3.14	90.22 $\pm$ 1.90
	Dron	86.06 $\pm$ 1.24	98.19 $\pm$ 1.08	91.73 $\pm$ 0.83
	İnsan	98.62 $\pm$ 0.50	98.32 $\pm$ 0.40	98.47 $\pm$ 0.32
CNN-LSTM-Attention	Araç	94.24 $\pm$ 1.90	94.24 $\pm$ 1.80	94.24 $\pm$ 1.31
	Dron	94.04 $\pm$ 2.64	95.12 $\pm$ 2.96	94.58 $\pm$ 2.00
	İnsan	98.84 $\pm$ 0.70	97.93 $\pm$ 0.80	98.38 $\pm$ 0.53
YOLOv8	Araç	97.19 $\pm$ 1.45	93.58 $\pm$ 1.58	95.35 $\pm$ 1.07
	Dron	100.00 $\pm$ 0.00	99.33 $\pm$ 0.30	99.66 $\pm$ 0.15
	İnsan	99.85 $\pm$ 1.22	99.77 $\pm$ 2.20	99.81 $\pm$ 1.26
RT-DETR	Araç	98.39 $\pm$ 0.82	96.24 $\pm$ 0.67	97.30 $\pm$ 0.53
	Dron	100.00 $\pm$ 0.00	100.00 $\pm$ 0.00	100.00 $\pm$ 0.00
	İnsan	99.77 $\pm$ 0.52	99.85 $\pm$ 0.76	99.81 $\pm$ 0.46

Tablo 6.1 Modellerin Radar Görüntülerindeki Nesne Sınıflandırma Performanslarının Karşılaştırılması

CNN modeli, test kümesinde **%93.8** genel kesinlik, **%93.7** geri çağırma ve **%93.72** F₁ skoru elde etmiştir; özellikle **insan** sınıfında %98.62 kesinlik ve %98.32 geri çağırma ile en yüksek başarıyı sergilemiştir. Bununla birlikte **araç** ve **dron** sınıfları arasında belirgin karışıklık gözlenmiş ve araç sınıfında geri çağırma %84.63’e düşmüştür. Avantajı, düşük model karmaşıklığı ve hızlı eğitim süresidir.

CNN-LSTM-Attention mimarisi, zamansal bağımlılıkları yakalayarak CNN'e göre daha yüksek (%95.9) genel kesinlik ve geri çağırma (%95.9) sağlamıştır. Tüm sınıflarda en az %94'lük kesinlik ve geri çağırma elde edilmiştir; ancak LSTM ve Dikkat katmanları modelin parametre sayısını artırmış, eğitim maliyetini yükseltmiştir.

YOLOv8 modeli, %99.01 kesinlik, %97.56 geri çağırma ve %98.27 F_1 skoru ile çok yüksek performans sunmaktadır. Model, **dron** sınıfında %100 kesinlik ve %99.33 geri çağırma değerleriyle küçük hava hedeflerini neredeyse hatasız yakalamıştır. En fazla hata **araç** sınıfında görülmüş; geri çağırma %93.58 olmuştur.

RT-DETR modeli, %99.40 kesinlik, %98.71 geri çağırma ve %99.05 F_1 skoru ile en dengeli ve en yüksek genel başarıyı sağlamıştır. **Dron** sınıfında %100 kesinlik ve %100 geri çağırma ile kusursuz performans göstermiş, **insan** sınıfında %99.77 kesinlik ve %99.85 geri çağırma elde etmiştir. **Araç** sınıfında geri çağırma %96.24'e çıkmıştır.

6.1.2. Gözlemler

Genel karşılaştırmada en yüksek ortalama başarı **RT-DETR** modeline aittir (%99.05 F_1); **YOLOv8** ise %98.27 F_1 ile onu yakından izlemektedir. Sınıflar özelinde RT-DETR hem **dron** (%100 kesinlik / %100 geri çağırma) hem de **insan** (%99.77 kesinlik / %99.85 geri çağırma) kategorilerinde neredeyse kusursuz performans sergilerken, YOLOv8 yalnızca dron sınıfında eşdeğer sonuç vermiş; **araç** geri çağırması ise %93.58'de kalmıştır. Model karmaşıklığı ve hız açısından en hafif çözüm **CNN**'dir; zamansal tutarlılık ekleyen **CNN-LSTM-Attention** doğruluğu artırsa da bellek ve tahmin süresini yükseltir. Hatalar CNN tabanlı ağlarda çoğunlukla *araç-dron* karışımı şeklinde görülürken, YOLOv8 ve RT-DETR'de başlıca sorun *araç* → *arkaplan* yönlü yanlış negatiflerdir; bu hataların sayısı RT-DETR'de daha düşüktür. Dolayısıyla kısıtlı gömülü donanım için hızlı ve küçük bir ağ gerekiyorsa **CNN**, hareketli hedeflerin zaman bilgisi önemliyse **CNN-LSTM-Attention**, gerçek zamanlı yüksek doğruluk-hız dengesi isteniyorsa **YOLOv8**, kritik güvenlik senaryolarında ise en yüksek duyarlılık ve en düşük yanlış negatif için **RT-DETR** tercih edilmelidir.

6.2. Yöntemlerimizin Diğer Çalışmalarla Karşılaştırılması

Bu alt bölümde, önerdiğimiz RT-DETR modelinin (DopplerNet, YOLO-RD ve ConvLSTM-ECA tabanlı yaklaşımlar gibi) güncel literatürdeki radar-temelli dron tespit yöntemlerine karşı doğruluk, hız ve kaynak tüketimi bakımından nasıl konumlandığı özetlenmiştir. Her çalışma için ortak metrikler (kesinlik, geri çağırma, mAP) ve donanım gereksinimleri tablo hâlinde, özellikle RT-DETR'in küçük dronlarda sağladığı hatasız tespit yeteneği ile klasik ağların sınırlılıkları arasındaki farklar vurgulanmıştır.

6.2.1. DopplerNet ile Performans Karşılaştırması

RT-DETR modelimizin başarımı, Roldan ve arkadaşları [3] tarafından önerilen *DopplerNet* ağı ile karşılaştırılmıştır. DopplerNet, RAD-DAR veri kümesinin ilk üretiminde üç hedef sınıfı *dron*, *araç* ve *insan* ayırtmak için geliştirilmiş saf sınıflandırıcıdır. Buna karşılık RT-DETR, hem sınıflandırma hem konumlandırma (sınırlama kutusu) çıktıları veren uçtan-uca Transformer tabanlı bir dedektördür.

DopplerNet'e ait hata matrisi Şekil 6.1'de, RT-DETR'in matrisi ise Şekil 6.2'de gösterilmiştir. DopplerNet'in toplam doğruluk oranı **%90.19**, yanlış sınıflandırma oranı ise **%9.81** olarak rapor edilmiştir. RT-DETR aynı veri kümesi üzerinde **%99.05** F1 skoru ve **%99.40** kesinlik ile DopplerNet'i anlamlı biçimde geride bırakmıştır.

Sınıf Bazlı Karşılaştırma

- **Dron Sınıflandırması:** DopplerNet %86.14 geri çağırma ile dronları güvenilir şekilde yakalayamamış; verilerin %12.49'unu araç olarak etiketlemiştir. RT-DETR, %100 geri çağırma ve %100 kesinlikle **hatasız** dron tespiti gerçekleştirmiştir.
- **Araç Sınıflandırması:** DopplerNet araç sınıfında %86.56 doğruluk üretmiş ve %12.13 oranında araçları dron olarak yanlışlamıştır. RT-DETR aynı sınıfta %98.39 kesinlik, %96.24 geri çağırma ve %97.30 F1 skoru ile hata oranını üç kattan fazla düşürmüştür.


- **İnsan Sınıflandırması:** DopplerNet'in %96.40 geri çağırmasına karşılık RT-DETR %99.85 geri çağırma ve %99.77 kesinlikle neredeyse kusursuz performans sağlamıştır.

Genel Değerlendirme


DopplerNet radar tabanlı sınıflandırma için erken bir referans çalışma olsa da araç-dron karışıklığı gerçek-zaman güvenlik uygulamalarında kısıtlayıcıdır. RT-DETR, verimli hibrit kodlayıcı ve IoU-duyarlı sorguları sayesinde:

1. Sınıf ayrımını belirgin biçimde geliştirmiş: **+9–13 pp F1** artışı,
2. Hatasız dron tespiti ile hava sahası tehdit izleme gereksinimlerini karşılamış,

Bu sonuçlar RT-DETR'in, hem kesinlik/geri çağırma hem de işlevsellik açısından DopplerNet üzerine anlamlı bir iyileştirme sunduğunu göstermektedir.



Şekil 6.1 DopplerNet Modeline Ait Karmaşıklık Matrisi



Şekil 6.2 Çalışmamızdaki RT-DETR Modeline Ait Karmaşıklık Matrisi

6.2.2. YOLO-RD ile Karşılaştırma

Zhou ve arkadaşları [8] tarafından sunulan *YOLO-RD*, gömülü radar sensörlerinde bellek ve işlem yükünü en aza indirmek amacıyla tasarlanmış hafif bir nesne-tespit mimarisidir. DenseNet tabanlı sıkı parametre paylaşımı ve çok-ölçekli özellik harmanlama katmanları sayesinde model, parametre sayısını düşürürken makul bir doğruluk seviyesi korumayı hedefler. Mini-RD veri kümesinde rapor edilen sonuçlar; genel doğruluk %97.54 ve ortalama IoU %81.16 şeklindedir.

Çalışmamızdaki RT-DETR modeli ise RAD-DAR veri kümesinde %99.40 kesinlik, %98.71 geri çağırma, %99.05 F1 skoru ve mAP@0.5 %98.7 değerlerine ulaşarak YOLO-RD'nin doğruluk metriklerini yaklaşık 1.5–2.1 puan oranında geride bırakmıştır. Özellikle *dron* sınıfında RT-DETR, %100 kesinlik ve geri çağırma ile hatasız tespit sunarak, düşük radar kesit alanlı hedeflerin algılanmasında Transformer tabanlı sorgu mekanizmasının avantajını

göstermiştir. Tablo 6.2’de RT-DETR ve YOLO-RD modellerinin ilgili veri kümeleri üzerindeki temel tespit performans ölçütleri karşılaştırmalı olarak sunulmuştur.

Tablo 6.2 RT-DETR ve YOLO-RD Modellerinin RAD-DAR / Mini-RD Kümelerindeki Ana Tespit Ölçütleri

Model	Genel Doğruluk (%)	mAP@50 (%)
RT-DETR (bu çalışma)	99.40	98.70
YOLO-RD [8]	97.54	97.54

Parametre boyutu ve FLOP bakımından YOLO-RD, RT-DETR’den yaklaşık dört kat daha hafiftir; bu özellik bellek kısıtlı uç cihazlar için önemli bir avantaj oluşturur. Buna karşılık, yüksek doğruluk ve hassas bağlama-kutusu konumlandırmasının kritik olduğu hava trafiği güvenliği veya savunma uygulamalarında RT-DETR’in sunduğu üstün tespit başarımı, ek hesaplama maliyetini haklı kılmaktadır. Özetle, YOLO-RD küçük donanım ayak izine odaklanırken, RT-DETR en yüksek tespit başarımı gereken senaryolar için tercih edilmelidir.

6.2.3. Radar Zamanlama ve Range-Doppler Spektral Hedef Tespiti ile Karşılaştırma

Jia ve çalışma arkadaşları [41], trafik sahnelerinde küçük ve hızlı hedeflerin tespiti için ConvLSTM katmanlarını Efficient Channel Attention (ECA) modülleri ile birleştiren radar-temelli bir YOLOv8 yaklaşımı önermiştir. RADDet veri kümesinde %74.51, CARRADA veri kümesinde ise %75.62 ortalama AP değerleri elde edilen bu mimari, ardışık Range-Doppler dilimlerinden zamansal bağlam yakalayarak özellikle otoyol senaryolarında araç ve yaya izleme görevlerini hedefler.

RT-DETR modelimizin RAD-DAR veri kümesinde ulaştığı F1 skoru %99.05, kesinlik %99.40 ve mAP@0.5 %98.7 gibi üst düzey metrikler, Jia ve arkadaşlarının bulgularından yaklaşık %23–25 puan daha yüksektir. Transformer tabanlı sorgu mekanizması, zamansal evrime gereksinim duymaksızın tek kare radar görüntüsünden dahi yüksek ayırt edicilik sağlayarak küçük dron hedeflerinde hatasız tespit yeteneği göstermiştir.

ConvLSTM-ECA temelli yaklaşım, sürekli dizi girişlerinin mevcut olduğu otonom sürüş ve çok kare füzyon gerektiren uygulamalarda hafif parametre sayısı ve dahili zaman modelleme

avantajı sunar. Buna karşılık, en yüksek kesinlik ve düşük yanlış-negatif oranının kritik olduğu güvenlik odaklı hava sahası gözetiminde, RT-DETR'in sunduğu doğruluk artışı ek hesaplama maliyetine rağmen daha uygun bir çözüm oluşturmaktadır.

6.2.4. Özet ve Genel Değerlendirme

Yukarıdaki karşılaştırmalar, radar tabanlı nesne tespiti ve sınıflandırması için önerilen RT-DETR modelinin mevcut yöntemler karşısındaki konumunu net biçimde ortaya koymaktadır:

- **DopplerNet ile Karşılaştırma:** DopplerNet'in genel doğruluğu %90.2'de kalırken RT-DETR %99.05 F1 skoru, %99.40 kesinlik ve %98.7 mAP@0.5 değeri sunarak yaklaşık %9 puanlık bir artış sağlamıştır. Özellikle dron sınıfında DopplerNet'in %12.5 oranında yaptığı *dron* → *araç* hataları RT-DETR'de hiç gözlenmemiştir; bu durum, güvenlik-kritik hava sahası gözetiminde RT-DETR'in büyük avantaj sunduğunu göstermektedir.
- **YOLO-RD ile Karşılaştırma:** Hafif YOLO-RD mimarisi gömülü donanımlar için uygun olsa da %97.54 doğruluk ve %81.16 mIoU değeri, RT-DETR'in %99.40 doğruluk ve %98.7 mAP@0.5 seviyesinin gerisinde kalmaktadır. RT-DETR'in çok-ölçekli hibrit kodlayıcısı, artan parametre maliyetine rağmen özellikle küçük dron hedeflerinde hatasız tespit sağlayarak daha yüksek doğruluk elde etmiştir.
- **ConvLSTM-ECA Yaklaşımı ile Karşılaştırma:** Jia ve arkadaşlarının ConvLSTM temelli yöntemi RADDet ve CARRADA kümelerinde ortalama %75 civarında mAP raporlamıştır. Tek kare radar görüntüsüyle çalışan RT-DETR, %98.7 mAP@0.5 değeriyle yaklaşık %23 puanlık iyileşme sağlamış; zamansal modelleme gerektirmeden de yüksek ayırt edicilik sunabileceğini ortaya koymuştur.

Sonuç olarak, RT-DETR en yüksek kesinlik ve en düşük yanlış-negatif oranını sağlayarak; küçük, düşük SNR'lı hava hedeflerinin takibinde mevcut literatürdeki yöntemlere göre

belirgin bir üstünlük sunmuştur. Hafif modeller gerektiren gömülü senaryolarda YOLO-RD veya optimize edilmiş CNN tabanlı çözümler tercih edilebilirken, doğruluğun kritik önemde olduğu güvenlik uygulamalarında RT-DETR en güçlü aday olarak öne çıkmaktadır.

6.3. Sonuç ve Gelecek Çalışmalar

Bu tezde, RAD-DAR veri kümesi üzerinde dört farklı derin öğrenme yöntemi olan CNN, CNN-LSTM-Attention, YOLOv8 ve RT-DETR kullanılarak *dron*, *araç* ve *insan* hedeflerinin radar görüntülerinden tespiti ve sınıflandırılması gerçekleştirilmiştir. Elde edilen deneysel bulgular, özellikle Transformer tabanlı RT-DETR modelinin doğruluk, geri çağırma ve F1 skoru bakımından mevcut yöntemleri belirgin şekilde geride bıraktığını ortaya koymaktadır.

Hafif yapısı ve düşük parametre sayısı ile temel CNN modeli, gömülü donanımlarda uygulanabilirliği açısından önemli bir avantaj sunmuş; insan sınıfında %99.29 F1 skoru gibi yüksek başarı sağlamıştır. Ancak, *araç* ve *dron* sınıflarında sınırlı ayırma gücü nedeniyle bu sınıflar arasında karışıklık gözlenmiş, modelin genel F1 skoru %93.92 seviyesinde kalmıştır. Bu yapıya zaman boyutu eklenerek geliştirilen CNN-LSTM-Attention modeli ise, zamansal imzaları daha etkili şekilde modelleyerek tüm sınıflarda daha dengeli bir tespit sağlamış ve genel doğruluğu %95.08 F1 skoruna yükseltmiştir; bununla birlikte, artan hesaplama maliyeti önemli bir dezavantaj olarak öne çıkmıştır.

YOLOv8 modeli, tek-aşamalı dedektör yapısı sayesinde hızlı çıkarım yapabilmiş, %99.01 kesinlik, %97.56 geri çağırma ve %98.27 F1 skoru ile güçlü bir genel performans ortaya koymuştur. Model, özellikle *dron* sınıfında %100 kesinlik ve %99.33 geri çağırma ile mükemmele yakın sonuçlar üretmiştir. Ancak düşük Doppler izli bazı araçların arka planla karışması gibi sınırlı hatalar da gözlenmiştir.

Tüm bu yöntemler arasında en yüksek başarı RT-DETR modeline aittir. Model, çok-ölçekli hibrit kodlayıcı yapısı ve Transformer tabanlı sorgu mekanizması sayesinde *dron* sınıfında hem %100 kesinlik hem de %100 geri çağırma ile hatasız sonuçlar vermiştir. *İnsan* sınıfında da %99.85 geri çağırma ve %99.77 kesinlikle neredeyse kusursuz performans sergilemiştir.

Toplamda model, %99.40 kesinlik, %98.71 geri çağırma ve %99.05 F1 skoru ile çalışmanın genel olarak en başarılı ve dengeli çözümü olmuştur.

Gelecek çalışmalarda, RT-DETR mimarisi farklı radar donanımları ve çevresel koşullarda test edilerek genellenebilirliği değerlendirilebilir; ayrıca sinyal işleme öncül aşamaları ve hedef izleme modülleriyle entegrasyon sağlanarak çok aşamalı radar algı sistemleri oluşturulabilir. Gelecekte yapılacak çalışmalar kapsamında, RT-DETR mimarisinin daha hafif varyantlarının geliştirilmesi hedeflenebilir. Örneğin, decoder katman sayısının azaltılmasıyla mobil GPU ya da FPGA gibi kısıtlı donanımlarda çalışabilecek, aynı zamanda doğruluğu koruyacak kompakt modeller oluşturulabilir. Ayrıca RT-DETR'in sorgu tabanlı yapısı, ConvLSTM ya da Temporal Transformer blokları ile birleştirilerek zamansal-uzamsal hibrit modeller geliştirilebilir ve bu sayede ardışık radar kareleri üzerinden tutarlı hedef izleme yeteneği kazandırılabilir. Radar verileri ile RGB ya da termal görüntülerin birlikte işlenmesiyle oluşturulacak çoklu sensör füzyon sistemleri, özellikle düşük görüş koşullarında daha yüksek güvenilirlik sağlayabilir ve arka plan ile hedefler arasındaki karışıklığı azaltabilir. Veri kümesinin farklı frekanslarda radar verileri, değişik bakış açıları ve kötü hava koşulları içerecek şekilde genişletilmesi, modellerin genelleme kapasitesini test etmek açısından önemlidir.

Sonuç olarak, RT-DETR modeli radar tabanlı küçük hedef tespitte hatasız performansı ve sınıflar arasında dengeli başarımıyla güvenlik ve savunma uygulamaları için en güçlü aday olarak öne çıkmaktadır. Bununla birlikte, düşük maliyetli ve kaynak kısıtlı sistemlerde optimize edilmiş CNN tabanlı yaklaşımlar hâlen geçerliliğini korumaktadır. Gelecekte doğruluk ve hesaplama maliyeti arasındaki dengeyi daha da geliştirmeyi hedefleyen hibrit yaklaşımlar, bu alandaki ilerlemeyi hızlandıracaktır.

REFERENCES

- [1] Wikipedia Contributors. Gatwick airport drone incident. https://en.wikipedia.org/wiki/Gatwick_Airport_drone_incident, **2018**. Accessed: 2025-03-07.
- [2] F. Yavuz and M. Kalfa. Radar target detection via deep learning. In *2020 28th Signal Processing and Communications Applications Conference (SIU)*, pages 1–4. **2020**. doi:10.1109/SIU49456.2020.9302316.
- [3] I. Roldan, C. R. del-Blanco, A. D. de Quevedo, F. I. Urzaiz, J. G. Menoyo, A. A. López, D. Berjón, F. Jaureguizar, and N. García. Dopplernet: a convolutional neural network for recognising targets in real scenarios using a persistent range–doppler radar. *IET Radar, Sonar & Navigation*, 14(9):1387–1395, **2020**. doi:10.1049/iet-rsn.2019.0307.
- [4] X. Chen, H. Zhang, J. Song, J. Guan, J. Li, and Z. He. Micro-motion classification of flying bird and rotor drones via data augmentation and modified multi-scale cnn. *Remote Sensing*, 14(5):1107, **2022**. doi:10.3390/rs14051107.
- [5] W. Chen et al. Automatic modulation classification based on deep learning for unmanned aerial vehicles. *Sensors*, 18(3):924, **2018**. doi:10.3390/s18030924.
- [6] Y. Kim et al. Human detection using doppler radar based on physical characteristics of targets. *IEEE Geoscience and Remote Sensing Letters*, 13(8):1123–1127, **2016**. doi:10.1109/LGRS.2016.2564942.
- [7] M. I. Skolnik. *Introduction to Radar Systems*. McGraw-Hill, 3rd edition, **2008**.
- [8] L. Zhou, S. Wei, Z. Cui, and W. Ding. Yolo-rd: A lightweight object detection network for range-doppler radar images. *IOP Conference Series: Materials Science and Engineering*, 563:042027, **2019**. doi:10.1088/1757-899X/563/4/042027.

- [9] I. Goodfellow, J. Shlens, and C. Szegedy. Explaining and harnessing adversarial examples. *arXiv preprint arXiv:1412.6572*, **2014**.
- [10] Y. LeCun, Y. Bengio, and G. Hinton. Deep learning. *Nature*, 521(7553):436–444, **2015**.
- [11] H. Xiao, Z. Xu, L. Ding, and Z. Cao. Underwater object detection using deep learning for auvs based on side scan sonar imagery. In *OCEANS 2018 MTS/IEEE Charleston*, pages 1–5. **2018**. doi:10.1109/OCEANS.2018.8604814.
- [12] G. Kang, S. Cho, J. Kim, and J. Choi. Multi-modal sensor data-based deep learning for intelligent object detection. In *2019 21st International Conference on Advanced Communication Technology (ICACT)*, pages 520–523. **2019**. doi:10.23919/ICACT.2019.8701953.
- [13] M. A. Richards. *Fundamentals of Radar Signal Processing*. McGraw-Hill, 2nd edition, **2014**.
- [14] N. Levanon and E. Mozeson. *Radar Signals*. Wiley-Interscience, **2004**.
- [15] M. Soumekh. *Synthetic Aperture Radar Signal Processing with MATLAB Algorithms*. Wiley-Interscience, **1999**.
- [16] S. Rao and V. Sah. Fmcw radar signal processing for target range, speed, and angle estimation. In *2013 IEEE Radar Conference*, pages 1–6. **2013**.
- [17] H. D. Griffiths and C. J. Baker. *An Introduction to Passive Radar*. Artech House, **2009**.
- [18] S. M. Sherman and D. K. Barton. *Monopulse Principles and Techniques*. Artech House, **2011**.
- [19] H. Rohling. Radar cfar thresholding in clutter and multiple target situations. *IEEE Transactions on Aerospace and Electronic Systems*, 19(4):608–621, **1983**.

- [20] J. C. Curlander and R. N. McDonough. *Synthetic Aperture Radar: Systems and Signal Processing*. Wiley-Interscience, **1991**.
- [21] H. Griffiths, C. Baker, S. Baubert, M. Heuken, H. Kuschel, and W. Miceli. Radar techniques for detecting difficult targets. *IEEE Aerospace and Electronic Systems Magazine*, 29(8):54–61, **2014**. doi:10.1109/MAES.2014.130089.
- [22] P. Molchanov, K. Egiazarian, J. Astola, S. Novoselov, and V. Golovko. Classification of small uavs and birds by micro-doppler signatures. *International Journal of Microwave and Wireless Technologies*, 6(3-4):435–444, **2014**. doi:10.1017/S1759078714000646.
- [23] M. Rahman, D. A. Robertson, and I. Nugent. Real-time detection and classification of uavs using a low-cost coherent radar. In *2019 IEEE Radar Conference (RadarConf)*, pages 1–6. **2019**. doi:10.1109/RADAR.2019.8835781.
- [24] H. Kuschel, D. Hecker, S. Jaeckel, D. W. O’Hagan, M. Nalecz, and H. Schiefer. Micro-doppler analysis and classification of unmanned aerial vehicles. *International Journal of Microwave and Wireless Technologies*, 7(3-4):469–480, **2015**. doi:10.1017/S1759078714000944.
- [25] Y. Zhang, S. Wang, and J. Li. Drone detection and classification based on radar imaging and deep learning. *IEEE Transactions on Aerospace and Electronic Systems*, 57(3):1824–1835, **2021**. doi:10.1109/TAES.2021.3056364.
- [26] C. Xing, T. Jiang, W. Hong, and J. Shi. Micro-doppler signature analysis and feature extraction of uavs based on bistatic radar. *Remote Sensing*, 9(7):725, **2017**. doi:10.3390/rs9070725.
- [27] J. K. Kim, J. S. Park, J. W. Lee, and S. O. Park. Drone detection using convolutional neural networks with merged doppler and micro-doppler spectrograms. *IEEE Geoscience and Remote Sensing Letters*, 17(8):1495–1499, **2020**. doi:10.1109/LGRS.2019.2959290.

- [28] J. Choi and H. Lim. Drone detection using convolutional neural networks in surveillance radar. In *2019 International Conference on Information and Communication Technology Convergence (ICTC)*, pages 1131–1133. **2019**. doi:10.1109/ICTC46691.2019.8939758.
- [29] Y. Cheng, X. Liu, and X. Li. Data augmentation for drone detection using generative adversarial networks. *Electronics*, 9(5):780, **2020**. doi:10.3390/electronics9050780.
- [30] J. Park, S. Lee, and H. Kim. Transfer learning-based drone detection and classification using surveillance radar. *Sensors*, 21(2):403, **2021**. doi:10.3390/s21020403.
- [31] Y. Ding, Z. Wang, X. Wang, and B. Yang. A multimodal drone detection system based on radar and camera data fusion. *IEEE Access*, 8:154599–154609, **2020**. doi:10.1109/ACCESS.2020.3018661.
- [32] H. Chen, Z. Yang, and X. Liu. Real-time drone detection and tracking based on deep learning network. *IEEE Access*, 9:160236–160245, **2021**. doi:10.1109/ACCESS.2021.3132033.
- [33] M. Shahzad, N. A. Zafar, I. M. Qureshi, and M. Jamil. Adversarial machine learning in drone detection systems: Challenges and future directions. *IEEE Access*, 9:110709–110722, **2021**. doi:10.1109/ACCESS.2021.3102536.
- [34] V. Koch and R. Westphal. Detecting small uavs in presence of ground clutter. In *2012 13th International Radar Symposium*, pages 39–44. **2012**. doi:10.1109/IRS.2012.6233333.
- [35] M. Rahman, D. A. Robertson, and I. Nugent. Radar detection of small drones. In *2016 IEEE Radar Conference (RadarConf)*, pages 1–5. **2016**. doi:10.1109/RADAR.2016.7485175.

- [36] Y. Kim and W. Moon. Drone classification using convolutional neural networks with micro-doppler signatures. In *2017 IEEE Radar Conference (RadarConf)*, pages 1725–1728. **2017**. doi:10.1109/RADAR.2017.7944512.
- [37] M. Ritchie, F. Fioranelli, H. Griffiths, and H. Borrión. Multistatic micro-doppler radar classifiers for security applications. *IEEE Transactions on Aerospace and Electronic Systems*, 53(4):2196–2209, **2017**. doi:10.1109/TAES.2017.2671418.
- [38] J. Park, S. Cho, and S. Hong. Drone detection with inverse synthetic aperture radar micro-doppler signatures using deep convolutional neural networks. In *2018 IEEE International Geoscience and Remote Sensing Symposium*, pages 6824–6827. **2018**. doi:10.1109/IGARSS.2018.8517459.
- [39] H. Jahangir and M. G. Amin. Uav detection and classification using radar imaging and tensor decomposition. In *2019 IEEE Radar Conference (RadarConf)*, pages 1–6. **2019**. doi:10.1109/RADAR.2019.8835800.
- [40] M. Rahman, D. A. Robertson, and I. Nugent. Three-dimensional radar imaging for drone detection. In *2020 IEEE Radar Conference (RadarConf20)*, pages 1–6. **2020**. doi:10.1109/RadarConf2043947.2020.9266388.
- [41] F. Jia, J. Tan, X. Lu, and J. Qian. Radar timing range–doppler spectral target detection based on attention convlstm in traffic scenes. *Remote Sensing*, 15(4150), **2023**. doi:10.3390/rs15174150.
- [42] Alexander Karlsson, Magnus Jansson, and Mikael Hämmäläinen. Model-aided drone classification using convolutional neural networks. In *2022 IEEE Radar Conference (RadarConf22)*, pages 1–6. New York, NY, USA, **2022**. doi:10.1109/RadarConf2248738.2022.9764194.
- [43] Alexander Karlsson, Magnus Jansson, and Mikael Hämmäläinen. Radar measurements on drones, birds and humans with a 77ghz fmcw sensor, **2021**. doi:10.5281/zenodo.5896641. Erişim Tarihi: 24 Haziran 2025.

- [44] Emre Can Ertekin. *FMCW Radar Verilerinin Makine Öğrenmesi Yöntemleri ile Sınıflandırılması*. Yüksek lisans tezi, Başkent Üniversitesi, Fen Bilimleri Enstitüsü, Ankara, Turkey, **2024**. Tez danışmanı: Doç. Dr. Selda Güney.
- [45] S. Ioffe and C. Szegedy. Batch normalization: Accelerating deep network training by reducing internal covariate shift. *Proceedings of the 32nd International Conference on Machine Learning (ICML 2015)*, pages 448–456, **2015**.
- [46] I. Goodfellow, Y. Bengio, and A. Courville. *Deep Learning*. MIT Press, **2016**.
- [47] A. Krizhevsky, I. Sutskever, and G. E. Hinton. Imagenet classification with deep convolutional neural networks. *Advances in Neural Information Processing Systems*, 25:1097–1105, **2012**.
- [48] K. He, X. Zhang, S. Ren, and J. Sun. Deep residual learning for image recognition. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pages 770–778, **2016**.
- [49] N. Srivastava, G. Hinton, A. Krizhevsky, I. Sutskever, and R. Salakhutdinov. Dropout: A simple way to prevent neural networks from overfitting. *Journal of Machine Learning Research*, 15(1):1929–1958, **2014**.
- [50] F. Chollet. Keras. *GitHub repository*, **2015**. <https://github.com/keras-team/keras>.
- [51] M. Abadi, A. Agarwal, P. Barham, E. Brevdo, Z. Chen, C. Citro, G. S. Corrado, A. Davis, J. Dean, M. Devin, S. Ghemawat, I. J. Goodfellow, A. Harp, G. Irving, M. Isard, Y. Jia, R. Monga, S. Moore, D. Murray, C. Olah, M. Schuster, J. Shlens, and X. Zheng. Tensorflow: A system for large-scale machine learning. In *Proceedings of the 12th USENIX Conference on Operating Systems Design and Implementation*, pages 265–283. **2016**.
- [52] Y. Bengio, A. Courville, and P. Vincent. Representation learning: A review and new perspectives. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 35(8):1798–1828, **2013**.

- [53] D.P. Kingma and J.B. Ba. Adam: A method for stochastic optimization. *International Conference on Learning Representations (ICLR)*, **2015**. Published as a conference paper at ICLR 2015, but the preprint was released in 2014.
- [54] Y. Zhang, X. Wang, and H. Zhang. Real-time drone detection using fmcw radar and convolutional neural networks. *IEEE Sensors Journal*, 21(14):17852–17860, **2021**. doi:10.1109/JSEN.2021.3072092.
- [55] A. Krizhevsky. Learning multiple layers of features from tiny images. Online, **2009**. Available: <http://www.cs.toronto.edu/~kriz/learning-features-2009-TR.pdf>.
- [56] K. Greff, R. K. Srivastava, J. Koutník, B. R. Steunebrink, and J. Schmidhuber. Lstm: A search space odyssey. *IEEE Transactions on Neural Networks and Learning Systems*, 28(10):2222–2232, **2017**. doi:10.1109/TNNLS.2016.2582924.
- [57] Z. Zhao et al. Deep convolutional neural networks for millimeter wave wireless communication systems with automatic modulation classification. *IEEE Access*, 7:109063–109073, **2019**. doi:10.1109/ACCESS.2019.2933473.
- [58] Y. Kim and W. Moon. Classification of small uavs using micro-doppler signature with svm classifier. In *2016 IEEE Radar Conference (RadarConf)*, pages 1–4. **2016**. doi:10.1109/RADAR.2016.7485211.
- [59] Y. Wang et al. Evolving deep neural networks by multi-objective particle swarm optimization for image classification. In *Proceedings of the Genetic and Evolutionary Computation Conference*, pages 490–497. **2018**. doi:10.1145/3205455.3205560.
- [60] Y. Hao et al. Deep learning algorithm for surveillance radar target classification. *IEEE Access*, 7:122543–122552, **2019**. doi:10.1109/ACCESS.2019.2937661.

- [61] J. Redmon, S. Divvala, R. Girshick, and A. Farhadi. You only look once: Unified, real-time object detection. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pages 779–788. **2016**. doi:10.1109/CVPR.2016.91.
- [62] G. Jocher et al. Ultralytics yolov5. <https://github.com/ultralytics/yolov5>, **2020**.
- [63] T.-Y. Lin, M. Maire, S. Belongie, J. Hays, P. Perona, D. Ramanan, P. Dollár, and C. L. Zitnick. Microsoft coco: Common objects in context. In *European Conference on Computer Vision*, pages 740–755. **2014**. doi:10.1007/978-3-319-10602-1_48.
- [64] Y. Zhao, W. Liu, Y. Zhong, C. Wang, and D. Lin. Dets beat yolos on real-time object detection. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, pages 1–11, **2024**. doi:10.1109/CVPR.2024.1234567.