

**BAŞKENT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
SAVUNMA TEKNOLOJİLERİ VE SİSTEMLERİ ANABİLİM DALI
SAVUNMA ELEKTRONİĞİ VE YAZILIMI TEZLİ YÜKSEK LİSANS
PROGRAMI**

**8.5 GHZ FMCW RADARI KULLANARAK ARAÇ, İNSAN VE DRON
ÜZERİNDEN OLUŞTURULAN MENZİL DOPPLER
HARİTALARININ UZAMSAL BOYUTLARDA
SINIFLANDIRILMASI**

HAZIRLAYAN

ALKIN ÖZKURTOĞLU

YÜKSEK LİSANS TEZİ

ANKARA-2025

**BAŞKENT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
SAVUNMA TEKNOLOJİLERİ VE SİSTEMLERİ ANABİLİM DALI
SAVUNMA ELEKTRONİĞİ VE YAZILIMI TEZLİ YÜKSEK LİSANS
PROGRAMI**

**8.5 GHZ FMCW RADARI KULLANARAK ARAÇ, İNSAN VE DRON
ÜZERİNDEN OLUŞTURULAN MENZİL DOPPLER
HARİTALARININ UZAMSAL BOYUTLARDA
SINIFLANDIRILMASI**

HAZIRLAYAN

ALKIN ÖZKURTOĞLU

YÜKSEK LİSANS TEZİ

TEZ DANIŞMANI

DR. ÖĞR. ÜYESİ MEHMET DİKMEN

ANKARA-2025

BAŞKENT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Savunma Teknolojileri ve Sistemleri Anabilim Dalı Savunma Elektronik ve Yazılım Tezli Yüksek Lisans çerçevesinde Alkın Özkurtoğlu tarafından hazırlanan bu çalışma, aşağıdaki jüri tarafından Yüksek Lisans Tezi olarak kabul edilmiştir.

Tez Savunma Tarihi: 08 / 07 / 2025

Tez Adı: 8.5 GHz FMCW Radarı Kullanarak Araç, İnsan ve Dron Üzerinden Oluşturulan Menzil Doppler Haritalarının Uzamsal Boyutlarda Sınıflandırılması

Tez Jüri Üyeleri (Unvanı, Adı - Soyadı, Kurumu)

İmza

Prof. Dr. Mehmet Serdar Güzel, Ankara Üniversitesi

.....

Dr. Öğr. Üyesi Mehmet Dikmen, Başkent Üniversitesi

.....

Doç. Dr. Selda Güney, Başkent Üniversitesi

.....

ONAY

Prof. Dr. Dilek ÇÖKELİLER SERDAROĞLU

Fen Bilimleri Enstitüsü Müdürü

Tarih: ... / ... /

BAŞKENT ÜNİVERSİTESİ
FEN BİLİMLER ENSTİTÜSÜ

YÜKSEK LİSANS / TEZ ÇALIŞMASI ORJİNALLİK RAPORU

Tarih: ... / ... / 20...

Öğrencinin Adı Soyadı: Alkın ÖZKURTOĞLU

Öğrencinin Numarası: 21720208

Anabilim Dalı: Savunma Teknolojileri ve Sistemleri

Danışmanın Unvanı/Adı, Soyadı: Dr. Öğr. Üyesi Mehmet Dikmen

Tez Başlığı: 8.5 GHz FMCW Radarı Kullanarak Araç, İnsan ve Dron Üzerinden

Oluşturulan Menzil Doppler Haritalarının Uzamsal Boyutlarda Sınıflandırılması

Yukarıda başlığı belirtilen Yüksek Lisans tez çalışmamın; Giriş, Ana Bölümler ve Sonuç Bölümünden oluşan, toplam 89 sayfalık kısmına ilişkin, 11/07/2025 tarihinde tez danışmanım tarafından Turnitin adlı intihal tespit programından aşağıda belirtilen filtrelemeler uygulanarak alınmış olan orijinallik raporuna göre, tezimin benzerlik oranı % 4'tür. Uygulanan filtrelemeler:

1. Kaynakça hariç
2. Alıntılar hariç
3. Beş (5) kelimeden daha az örtüşme içeren metin kısımları hariç

“Başkent Üniversitesi Enstitüleri Tez Çalışması Orijinallik Raporu Alınması ve Kullanılması Usul ve Esaslarını” inceledim ve bu uygulama esaslarında belirtilen azami benzerlik oranlarına tez çalışmamın herhangi bir intihal içermediğini; aksinin tespit edileceği muhtemel durumda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi ve yukarıda vermiş olduğum bilgilerin doğru olduğunu beyan ederim.

Öğrenci İmzası:

ONAY

Tarih: ... / ... / 20...

Öğrenci Danışmanı:

Dr. Öğr. Üyesi Mehmet Dikmen

ÖNSÖZ

Yüksek lisans eğitim hayatım boyunca, bana danışmanlık ederek, yolumu aydınlatan ve yardımlarını esirgemeyen danışman hocam Dr. Öğr. Üyesi Mehmet Dikmen'e sonsuz teşekkürlerimi sunarım. Tez sürecimin her aşamasında gösterdiği rehberlik ve bilimsel katkılar, bu çalışmanın ortaya çıkmasında belirleyici rol oynamıştır.

Tez süresi boyunca ihtiyaç duyduğum her noktada yardımlarını asla esirgemeyen Hacettepe Üniversitesi Yapay Zeka Topluluğu ve Orta Doğu Teknik Üniversitesi Yapay Zeka Topluluğu üyelerine teşekkür ederim.

Bu çalışma boyuncaengin bilgileriyle bana yol gösteren, tecrübe ve deneyimleri ile beni aydınlatan ve çalışmalarım sırasında yanımda olan Yüksek Elektrik/Elektronik Mühendisi Sayın Ozan YILMAZ'a teşekkür ederim.

Çalışmalar sırasında yardımlarını esirgemeyen tüm çalışma arkadaşlarıma teşekkür ederim.

Akademik sürecimin dışında her zaman yanımda olan değerli arkadaşlarıma Hakan ÖNCÜ'ye ve Cem ŞENOL'a içtenlikle teşekkür ederim.

Öğrenim hayatım boyunca maddi ve manevi desteklerini hiçbir zaman esirgemeyen, hep yanımda olan aileme yürekten sonsuz teşekkürlerimi sunarım.

ÖZET

ALKIN ÖZKURTOĞLU

**8.5 GHZ FMCW RADARI KULLANARAK ARAÇ, İNSAN VE DRONE
ÜZERİNDEN OLUŞTURULAN MENZİL DOPPLER HARİTALARININ
UZAMSAL BOYUTLARDA SINIFLANDIRILMASI**

Başkent Üniversitesi Fen Bilimleri Enstitüsü

Savunma Teknolojileri ve Sistemleri Anabilim Dalı

2025

Bu tezde, menzil doppler haritalarına bağlı olarak insan, dron ve araç özelinde nesne sınıflandırma teknikleri araştırılmıştır. Kullanılan makine öğrenmesi ve derin öğrenme modelleri mimarileri, ardışık menzil doppler görüntülerinin uzamsal ve zamansal özellikleri dikkate alınarak belirlenir.

Kamuya açık olan RDRD veri seti, önerilen model mimarisini eğitmek ve değerlendirmek için kullanılmıştır. Veri seti, bir 8.5 GHz frekans modüleli sürekli dalga radarı kullanılarak toplanmış; insan, araç ve dron gibi farklı hedef türlerine ait menzil doppler görüntülerini içermektedir. Belirli bir yol boyunca seyahat eden araç, dron ve insan için belirli sinyal işleme adımlarından geçirilerek elde edilen bu görüntüler, her sınıf için ardışık şekilde bir araya getirilerek bir görüntü yığını oluşturulmuştur.

Söz konusu veri seti içindeki görüntülerin işlenmesi için, makine öğrenme ve derin öğrenme yöntemlerini içeren birkaç görüntü sınıflandırma tekniği vardır. Bu kapsamda, makine öğrenmesi tabanlı Rastgele Orman (RF) ve Aşırı Gradyan Artırmalı Öğrenme (XGB) algoritmalarının yanı sıra, derin öğrenmeye dayalı 2 Boyutlu Evrişimli Sinir Ağı (2D CNN) ve Görsel Dönüştürücü (ViT) mimarileri de karşılaştırmalı olarak değerlendirilmiştir. Bu mimariler özelinde, bahsedilen üç ayrı hedef için RF mimarisi test veri setinde %91,45, XGB yöntemi %92,54, özelleştirilmiş 2D CNN modeli %94,34 ve ViT mimarisi test veri seti üzerinde %93,19 oranında sınıflandırma doğruluğu sağlamıştır.

ANAHTAR KELİMELEER: Menzil Doppler, Topluluk Öğrenmesi, FMCW Radar, Evrişimsel Yapay Sinir Ağları, Kimlik Tespiti.



ABSTRACT

ALKIN ÖZKURTOĞLU

**SPATIAL CLASSIFICATION OF RANGE DOPPLER MAPS GENERATED
FROM VEHICLES, HUMANS AND DRONES USING 8.5 GHZ FMCW RADAR**

Başkent University Institute of Science

Department of Defence Technologies and Systems

2025

In this thesis, object classification techniques for human, drone and vehicle based on range doppler maps are investigated. The machine learning and deep learning model architectures used were determined by considering the spatial and temporal characteristics of consecutive range doppler images.

The publicly available RDRD dataset is used to train and evaluate the proposed model architecture. The dataset contains range doppler images of different types of targets, such as humans, vehicles and drones, collected using an 8.5 GHz frequency modulated continuous wave radar. These images, which are obtained by performing certain signal processing steps for vehicles, drones and humans traveling along a given path, are stacked together consecutively for each class to form an image stack.

There are several image classification techniques for processing these images, including machine learning and deep learning methods. In this context, machine learning based Random Forest and XGBoost algorithms as well as deep learning based 2D Convolutional Neural Network and Visual Transformer architectures are comparatively evaluated. Specific to these architectures, Random Forest architecture provided 91,45%, XGBoost obtained 92,54%, custom developed 2D Convolutional Neural Network resulted 94,34% and Visual Transformer architecture achieved 93,19% classification accuracy on the test dataset.

KEYWORDS: Range Doppler, Ensemble Learning, Convolutional Neural Network, Frequency Modulated Continuous Wave Radar, Target Recognition.



İÇİNDEKİLER

ÖNSÖZ.....	i
ÖZET.....	ii
ABSTRACT.....	iv
İÇİNDEKİLER.....	vi
TABLolar LİSTESİ.....	ix
ŞEKİLLER LİSTESİ.....	x
SİMGELER VE KISALTMALAR LİSTESİ.....	xiii
1. GİRİŞ.....	1
2. TEORİK ALTYAPI.....	6
2.1. Radar Teknolojisi.....	6
2.1.1. Çalışma prensibi.....	6
2.1.2. Radar denklemleri.....	6
2.1.3. Radar ile uzaklık ölçümü.....	7
2.1.4. Yön Belirlenmesi.....	8
2.1.5. Darbe Tekrarlama Aralığı (PRI).....	9
2.1.6. Maksimum Belirsiz Menzil.....	9
2.1.7. Veri Matrisi (Data Matrix).....	10
2.1.8. Veri Küpü.....	10
2.1.9. Dalga Sinyali Spektrumu.....	11
2.2. FMCW Radar.....	12
2.2.1. Temel FMCW Radar Yapısı.....	13
2.2.2. FMCW Radar ile Menzil Ölçümü.....	14

2.2.3. Maksimum Menzil ve Menzil Çözünürlüğü.....	15
2.3. Menzil Doppler Haritalar.....	15
2.3.1 Menzil Doppler Analizi.....	15
2.4. Makine Öğrenimi.....	18
2.4.1. Rastgele Orman.....	18
2.4.2. Aşırı Gradyan Artırmalı Öğrenme (XGB - Extreme Gradient Boosting).....	20
2.5. Sinir Ağları.....	21
2.5.1. Yapay Sinir Ağları (ANN).....	21
2.5.2. Algılayıcılar ve Aktivasyon Fonksiyonları.....	23
2.5.3. Regülerizasyon.....	24
2.5.4. Evrişimsel Sinir Ağları (CNN).....	25
2.5.5. 2 Boyutlu Evrişimsel Sinir Ağları.....	25
2.5.6. Görüntü Dönüştürücüsü (ViT).....	26
2.6. Görüntü İşleme.....	30
2.6.1. Wavelet Tabanlı Gürültü Bastırma.....	32
2.6.2. Görüntü Ön İşleme Yöntemleri.....	35
3. KULLANILAN METOTLAR.....	38
3.1. Kullanılan Veri Ön İşleme Adımları.....	44
3.1.1. Wavelet Tabanlı Gürültü Bastırma.....	44
3.1.2. Ara Değerleme (Interpolation).....	45
3.1.3. Medyan Filtreleme (Median Filtering).....	45
3.1.4. Min – Max Normalizasyonu.....	46
3.2. Kullanılan Makine Öğrenmesi Yöntemleri.....	48

3.2.1. Eğitim Süreçleri.....	48
3.2.2. Rastgele Orman Modeli İçin Belirlenen Hiperparametreler....	49
3.2.3. Aşırı Gradyan Artırmalı Öğrenme Modeli İçin Belirlenen Hiperparametreler.....	50
3.3. Kullanılan Derin Öğrenme Yöntemleri.....	51
3.3.1. 2 Boyutlu Evrişimli Sinir Ağı (2D-CNN).....	51
3.3.2. Görsel Dönüştürücü (ViT).....	54
3.4. Model Eğitimi İçin Kullanılan Geliştirme Platformu ve Sağladığı Kaynaklar.....	56
3.5. Model Eğitimi İçin Kullanılan Yazılım Dili ve Kütüphaneleri.....	56
4. SONUÇLAR.....	58
4.1. Performans Değerlendirme Metrikleri.....	58
4.2. Kullanılan Derin Öğrenme Yöntemlerinin Sonuçları.....	59
4.2.1. Özelleştirilmiş 2D-CNN.....	59
4.2.2. Görsel Dönüştürücü (ViT).....	64
4.2. Geleneksel Makine Öğrenme Yöntemlerinin Sonuçları.....	69
4.2.1. Aşırı Gradyan Artırmalı Öğrenme.....	69
4.2.2. Rastgele Orman.....	74
4.3. Çalışılan Derin Öğrenme ve Makine Öğrenme Yöntemlerinin Sonuçlarının Kıyaslanması.....	80
4.4. Çalışma Kapsamında Geliştirilen Model Sonuçlarının Örnek Çalışma İle Kıyaslanması.....	81
5. TARTIŞMALAR VE GELECEKTEKİ ÇALIŞMALAR.....	86
KAYNAKLAR.....	87

TABLÖLAR LİSTESİ

	Sayfa
Tablo 3.1. RDRD Veri Seti İçeriği ve Sınıf Dağılımları.....	44
Tablo 3.2. Rastgele Orman Modeli İçin Belirlenen Hiper Parametreler.....	49
Tablo 3.3. Aşırı Gradyan artırmalı Öğrenme İçin Belirlenen Hiper Parametreler.....	50
Tablo 3.4. Özelleştirilmiş 2D-CNN Model Mimarisi.....	52
Tablo 3.5. ViT Model Mimarisi.....	54
Tablo 4.1. RDRD Veri Seti Üzerinde Özelleştirilmiş 2D-CNN Yöntemi kullanılarak Eğitim Sonucu Çıkan Performans Metriklerinin Tablosu.....	61
Tablo 4.2. RDRD Veri Seti Üzerinde ViT (Görsel Dönüştürücü Yöntemi Sonucu) Çıkan Performans Metriklerinin Tablosu.....	66
Tablo 4.3. RDRD Veri Seti Üzerinde Aşırı Gradyan Artırmalı Öğrenme Yöntemi Kullanılarak Eğitim Sonucu Çıkan Performans Metriklerinin Tablosu.....	71
Tablo 4.4. RDRD Veri Seti Üzerinde Rastgele Orman Öğrenme Yöntemi Kullanılarak Eğitim Sonucu Çıkan Performans Metriklerinin Tablosu.....	77
Tablo 4.5. Çalışılan Derin Öğrenme ve Makine Öğrenme Yöntemlerinin Sonuçlarının Kıyaslanması.....	80
Tablo 4.6. Çalışma Kapsamında Geliştirilen Modellerin Sonuçlarının Örnek Çalışma Sonuçları İle Kıyaslanması.....	82

ŞEKİLLER LİSTESİ

	Sayfa
Şekil 2.1. Radar Çalışma Prensipleri.....	6
Şekil 2. 2. Radar Sinyalinin Hedefe Ulaşıp Geri Yansıma Süreci.....	8
Şekil 2.3 Hedef Yönünün Belirlenmesi.....	8
Şekil 2.4. Darbe Tekrarlama Aralığı (PRI).....	9
Şekil 2.5. Radar Veri Matrisinde Hızlı ve Yavaş Zaman Ekseninde Hedef Hareketlerinin Gösterimi.....	10
Şekil 2.6. Radar Sistemlerinde Hızlı Zaman, Yavaş Zaman ve Alıcı Kanal Boyutlarında Veri Küpü Gösterimi.....	11
Şekil 2.7. Sabit Radar ve Hareketli Hedef Senaryosu: Üst Görsel: Radar Hedef Sisteminin Geometrisi, Alt Görsel: Radar Tarafından Gözlemlenen Frekans.....	12
Şekil 2.8. Frekans Modülasyonlu Sürekli Dalga radarı (FMCW) ile Menzil Ölçümü	13
Şekil 2.9. FMCW Radar Blok Diyagramı	14
Şekil 2.10. Hızlı Zaman ve Yavaş Zaman Grafiği üzerinden RD Haritasının Elde Edilmesi.....	17
Şekil 2.11. Rastgele Orman Sınıflandırma Süreci.....	19
Şekil 2.12. Aşırı Gradyan Artırmalı Öğrenme Sınıflandırma Süreci.....	21
Şekil 2.13. İleri Beslemeli Çok Katmanlı Yapay Sinir Ağı.....	22
Şekil 2.14. Görsel Dönüştürücü (ViT) Modeli Sınıflandırma Süreci.....	30
Şekil 2.15. RDRD Veri Seti Üzerinde Dron Sınıfı Örneği İçin Wavelet Tabanlı Gürültü Azaltma Yöntemi.....	32
Şekil 3.1. Veri Ön işleme Adımları.....	38
Şekil 3.2. RAD-DAR Sistemi.....	40
Şekil 3.3. RDRD veri setindeki kullanılan radar sisteminin görüntüsü.....	41

Şekil 3.4.	Radar LOS (Görünürlük) Haritası.....	43
Şekil 3.5.	RDRD Veri Setinin Elde Edildiği Rotalar (Dron için uçuş, İnsan ve Araç için seyahat rotaları).....	43
Şekil 3.6.	Görüntü İşleme Öncesi Elde Edilen Örnek RD Haritaları: Sol Üst Görsel: Araç Sınıfı Görseli, Sağ Üst Görsel: Dron Sınıfı Görseli, Alt Görsel: İnsan Sınıfı Görseli.....	47
Şekil 3.7.	Görüntü İşleme Sonrası Dron Sınıfı Örnek RD Haritası.....	48
Şekil 4.1.	RDRD Veri Seti Üzerinde Özelleştirilmiş 2D-CNN Yöntemi Kullanılarak Eğitim ve Validasyon Kayıplarının Karşılaştırması.....	60
Şekil 4.2.	RDRD Veri Seti Üzerinde Özelleştirilmiş 2D-CNN Yöntemi Kullanılarak Eğitim Sonucu Çıkan Karışıklık Matrisi Sonuçları.....	62
Şekil 4.3.	RDRD Veri Seti Üzerinde Özelleştirilmiş 2D-CNN Yöntemi Kullanılarak Eğitim Sonucu Modelin Doğruluğunu Ölçmek İçin Rastgele Seçilmiş 10 Sabit Yanlış Alarm Oranı.....	63
Şekil 4.4.	RDRD Veri Seti Üzerinde Görsel Dönüştürücü Yöntemi Kullanılarak Eğitim ve Validasyon Kayıplarının Karşılaştırması.....	65
Şekil 4.5.	RDRD Veri Seti Üzerinde Görsel Dönüştürücü Yöntemi Kullanılarak Eğitim Sonucu Çıkan Karışıklık Matrisi Sonuçları.....	67
Şekil 4.6.	RDRD Veri Seti Üzerinde ViT Yöntemi Modelin Doğruluğunu Ölçmek İçin Rastgele Seçilmiş 10 Sabit Yanlış Alarm Oranı.....	68
Şekil 4.7.	RDRD Veri Seti Üzerinde Aşırı Gradyan Artımlı Öğrenme Yöntemi Modelin Doğruluğunu Ölçmek İçin Çok Sınıflı Alıcı İşlem Özellik Eğrisi Grafiği.....	69
Şekil 4.8.	RDRD Veri Seti Üzerinde Aşırı Gradyan Artımlı Öğrenme Yöntemi Kullanılarak Eğitim Sonucu Çıkan Karışıklık Matrisi Sonuçları.....	72

Şekil 4.9. RDRD Veri Seti Üzerinde Aşırı Gradyan Artımlı Öğrenme Yöntemi Modelin Doğruluğunu Ölçmek İçin Rastgele Seçilmiş 10 Sabit Yanlış Alarm Oranı.....	74
Şekil 4.10. RDRD Veri Seti Üzerinde Rastgele Orman Yöntemi Modelin Doğruluğunu Ölçmek İçin Çok Sınıflı Alıcı İşlem Özellik Eğrisi Grafiği..	75
Şekil 4.11. RDRD Veri Seti Üzerinde Rastgele Orman Öğrenme Yöntemi Kullanılarak Eğitim Sonucu Çıkan Karışıklık Matrisi Sonuçlar.....	78
Şekil 4.12. RDRD Veri Seti Üzerinde Rastgele Orman Öğrenme Yöntemi Modelin Doğruluğunu Ölçmek İçin Rastgele Seçilmiş 10 Sabit Yanlış Alarm Oranı.....	79

SİMGELER VE KISALTMALAR LİSTESİ

RD	Menzil-Doppler
MD	Micro-Doppler
RDRD	Real Radar-Based Drones, People, and Cars Dataset
FMCW	Frekans ile Modüleli Sürekli Dalga
RF	Rastgele Orman
XGB	Gradyan Artırmalı Öğrenme
ViT	Görsel Dönüştürücü
CNN	Evrişimli Sinir Ağı
2D-CNN	2 Boyutlu Evrişimli Sinir Ağı
PRI	Darbe Tekrarlama Aralığı
PRF	Darbe Tekrarlama Frekansı
CW	Sürekli Dalga
ML	Makine Öğrenimi
API	Yüksek Seviyeli Uygulama Geliştirme Arayüzü
ANN	Yapay Sinir Ağları
DWT	Ayrık Wavelet Dönüşümü
CFAR	Sabit Yanlış Alarm Oranı
ROC	Alıcı İşletim Karakteristiği
AUC	Eğri Altında Kalan Alan
MLP	Çok Katmanlı Algılayıcı

1. GİRİŞ

Çevre algılama için kullanılabilecek lidarlar, video kameralar, radar sensörleri gibi çeşitli sensörler bulunmaktadır. Kameralar KYM (Kırmızı Yeşil Mavi) bilgilerini algılayabilir ve etkileyici derecede yüksek çözünürlüğe sahiptir, ancak aynı zamanda güneş ışığına karşı onu kör edebilecek bir zayıflığa sahiptir ve olumsuz hava koşullarında eksiklikleri vardır. Öte yandan Lidar, menzilde çözünürlük sağlayan tek sensör olmasına rağmen sis, yağmur veya kar gibi kötü hava koşullarından da zarar görmektedir. Bu tür olumsuz hava koşullarında radar sensörü, çok etkili bir şekilde çalışabilme avantajına sahiptir. Radar, mesafe ölçümünün hassas ve sağlıklı bir şekilde yapılmasının gerekli olduğu birçok farklı uygulamada kullanılan iyi bilinen bir teknolojidir. Son yıllarda, radar menzil doppler (RD) ve mikro doppler (MD) imzaları, nesne tanıma ve sınıflandırmasında son derece popüler hale geldi. Bu tezde, bahsedilen Frekans Modüleli Sürekli Dalga (FMCW) radar sensörü için insan, araç ve dron gibi farklı hareket ve yansıma karakteristiklerine sahip hedeflerin sınıflandırılması amacıyla RD temsilleri kullanılarak makine öğrenmesi ve derin öğrenme tabanlı sınıflandırma sistemleri geliştirilmiştir.

İletilen radar sinyali hedefle etkileşir ve radara yansır. Mikro hareketler olarak adlandırılan hedefin titreşimi, dönüşü veya sallanması gibi özellikler, yansıyan sinyalde ekstra frekans modülasyonlarına neden olabilir. Ayrıca, hedefin her hareketli parçası kendi Doppler sinyaline yol açar. Tüm bu Doppler sinyallerinin süperpozisyonu, MD imzası [1] olarak adlandırılan bir şekilde özetlenir. MD imzaları, zaman ve frekans eksenlerinde analiz edilerek RD imzaları oluşturulur. RD imzaları, radarın algıladığı yansımaların mesafe ve hız (Doppler) içeriğini temsil eder ve MD bileşenlerinin zamanla frekans içindeki dağılımını içerir [18].

RD ve MD imzası, FMCW radar tabanlı çözümler için kullanılan geniş bir çalışma yelpazesine sahiptir. Çeşitli hedeflerin RD ve MD imzası, sınıflandırma veya nesne tanıma için radar cihazlarının çıktısı olarak yorumlanabilir. MD imzasını kullanarak insan kinetiğini tespit etmek için birçok farklı radar sensörü kullanılmıştır. Doppler radarı aracılığıyla MD

imzasını kullanan çeşitli çalışmalar vardır. Kim ve Ling (2009), kullanarak elde ettikleri MD imzaları ile insan aktivitelerini destek vektör makineleri (SVM) aracılığıyla sınıflandırmıştır [3]. Bir diğer çalışmada, elde edilen MD imzası kullanılarak bastonla yürüyen bireylerin yürüme biçimleri analiz edilmiş ve insan yürüyüş tanıma üzerine çalışılmıştır [4]. FMCW radar sistemi kullanarak çeşitli el hareketlerini sınıflandırmak amacıyla, MD sinyallerinden elde edilen öznitelikleri kullanarak geleneksel makine öğrenmesi algoritmaları ile sınıflandırma gerçekleştirmişlerdir. Bu yaklaşım, radar verisiyle insan hareketi sınıflandırmasında derin öğrenme dışı yöntemlerin de başarılı olabileceğini göstermesi açısından literatürde dikkat çekici bir yere sahiptir [2]. Özcan ve arkadaşları (2012), lineer FMCW radar kullanarak tek kuş ve kuş sürüsü gibi hedeflerin MD imzalarını analiz etmiş ve bu imzalar üzerinden ayırım yapılabilmesi üzerine çalışmışlardır [7]. Multistatik pasif radar sistemiyle, tek anten üzerinden elde edilen MD imzasını kullanarak hava sahasındaki cisimlerin ve dronların tespiti gerçekleştirilen Fang ve arkadaşları (2018) aynı zamanda dronlar ile diğer hedeflerin sınıflandırılma işlemini incelemiştir [8]. İlgi konusu dahilinde olan bir diğer çalışmada ise insan hareketleri özelinde MD imzası çıkarımı konusu ele alınmıştır [9]. Buna ek olarak, Vandersmissen ve arkadaşları, insan hareketlerinden elde edilen MD imzaları üzerinden bir özellik öğrenme yaklaşımı önererek ilgili zorluğun üstesinden gelmiş ve İnsanlara Özgü Kimlik Belirleme (Human Target Recognition) konusunda önemli bir katkıda bulunmuştur [10].

FMCW Radar ve RD görüntüleri üzerinde makine öğrenmesi ve derin öğrenme yöntemlerinin etkinliği üzerine çeşitli çalışmalar yer almaktadır. Makine öğrenmesi tabanlı yöntemler, görüntü sınıflandırma problemlerinde yüksek doğruluklu sonuçlar vermektedir. Evrişimli sinir ağları (CNN), görüntü içerik analizini yapma, niteliksel özellikleri çıkartma ve sınıflandırma metodu olarak çalışılmış [11] ve etkili olduğu kanıtlanmıştır. Günümüzde CNN katmanları, görüntü tanıma, algılama ve segmentasyon için en gelişmiş sonuçları sağlamaktadır. Hyun ve Jin (2020), FMCW radar sensöründen elde edilen Doppler spektrum özelliklerini kullanarak insan ve araç sınıflandırması gerçekleştirmiştir [12]. Bir diğer benzer çalışmada, Cha ve arkadaşları (2021), RD haritası ve nokta bulutu haritasını çoklu girişli bir CNN ile işleyerek yüksek sınıflandırma başarımı elde etmiştir [13]. Samimi Fard ve

arkadaşları (2025), 60 GHz FMCW radar kullanarak insan aktivite tanıma üzerine bir çalışma gerçekleştirmiştir. Bu çalışmada, RD, menzıl-Yatay Açık (Range-Azımut) ve menzıl-Dikey Açık (Range-Elevation) gibi çok boyutlu özellik haritaları doğrudan makine öğrenimi ve derin öğrenme modellerine veri vektörleri olarak beslenmiştir. Evrişimli Uzun Kısa Süreli Bellek Ağ (ConvLSTM) modeli, diğer geleneksel makine öğrenimi ve derin öğrenme modellerini geride bırakarak yüksek doğruluk ve F1 skorları elde etmiştir [14]. Abdulatif ve arkadaşları (2017), 25 GHz FMCW radar kullanarak insan ve robot sınıflandırması üzerine bir çalışma yapmıştır. Bu çalışmada, MD imzaları kullanılarak, derin evrişimli sinir ağı (DCNN) ile çok yüksek doğrulukla sınıflandırma başarısı elde edilmiştir [15]. Bu tezin geliştirilmesinde öncü olan bir diğer çalışmada ise araç, insan ve dron gibi farklı hareket ve yansıma karakteristiklerine sahip olan hedeflerin sınıflandırılması amacıyla RD görüntüleri kullanılmış ve özel bir derin öğrenme sistemi geliştirilmiştir [16]. Ayrıca yazarlar, RDRD [17] veri seti ile kamuya açık olan bir kaynak yayınladı ve Kimlik Belirleme (Target Recognition) konusunda gelecekteki çalışmalar için önemli bir katkıda bulundu.

Görsel veya video tabanlı olay ve kişi tanıma, bilgisayarla görü ve makine öğrenimi alanlarında, şu anda ilginç zorluklardan biridir. Özellikle radar sensörleri farklı nesne veya kişiler üzerinden elde edilen MD ve RD imzalarının, her nesne veya kişinin farklı hareket varyasyonlarından oluşması ve çevresel gürültü kaynaklarının da bu imzalar üzerine eklenmesi bu zorluklardan en ciddiileri olarak gösterilebilir. Ek olarak, başka bir sınıfın hareketlerinin, herhangi başka bir sınıfın hareketleri ile benzerlik göstermesi bu zorluklara ilave edilebilir. Özellikle insan ve dron gibi benzer RD imzasına sahip hedeflerin birbirinden ayrıştırılması, sinyalin yorumlanması açısından önemli bir zorluk teşkil etmektedir. Bu çalışma, bu zorluğa odaklanarak radar sistemlerinin ayırt edici gücünü artırmayı hedeflemekte ve sınıflandırma sistemlerinin hassasiyetini artırma yönünde katkı sunmaktadır.

Sadece insan hareketleri üzerine bile konuşulacak olsa, yukarıda bahsedilen zorluklarla yine karşılaşılacaktır. Örnek olarak, insan yürüyüş hareketinden kaynaklı olarak radarın almaç kısmında alınan ve işlenen sinyallerden sonra insanın vücudunun farklı

bölümlerinden elde edilen MD imzalarının, kişi belirleme sınıflandırmasında kullanılan bir çalışma olduğu gösterilebilir [10]. Çoğu durumda, birbirinden farklı iki hareketin sınıflarının net belirlenebilmesi için hareketin yapıldığı ortamın göz önünde bulundurulması önemlidir. Farklı kişilere ait özelliklerin birbirine benzemesi ve sınıflandırmanın gerçekleştiği ortamın sisteme katacağı gürültü yine bu temel zorluklar arasında gösterilebilir. Görsel veya video tabanlı olay ve kişi tanıma, özellikle, insan eylemlerini tanıma, kimliklerini belirleme, video gözetleme gibi çeşitli uygulamalarda kullanılması nedeni ile önemli bir araştırma alanı haline gelmiştir. Eylem tanımda asıl hedef, görsel veya video akışı içerisinde bulunan birbiri ardına gelen resim kesitlerinden belirli olayları veya aktiviteleri tespit edip sınıflandırabilmektir. Kişi veya nesne belirlemede ise, önceden eğitilmiş belirli özellikleri algılamak ve sınıflandırabilmek ön plandadır. Kişi veya nesne belirlemeye örnek olan çalışmada, araç, insan ve dron gibi farklı hareket ve yansıma karakteristiklerine sahip olan hedeflerin (kişilerin ve nesnelerin) sınıflandırılması amacıyla RD görüntüleri kullanılır [16]. Kişi, araç ve dron belirleme yönteminin MD imzaları kullanarak değil de kişilere veya nesnelere ait RD haritaları incelenerek Makine Öğrenimi ve Derin Öğrenme yöntemleri ile sınıflandırılması bu tez kapsamında incelenecektir.

Bu tezde, bahsedilen veri seti [17] tarafından sağlanan RD verileri, incelenen makine öğrenimi yöntemlerinin ve derin öğrenme yöntemleri için sınıflandırma girdileri olarak kullanılmıştır. Başlangıç olarak, RD görüntülerinin uzamsal özellikleri, makine öğrenme yöntemlerinden RF ve XGB, derin öğrenme yöntemlerinden ise Görsel Dönüştürücü (ViT) ve özelleştirilmiş 2D-CNN modeli kullanılarak çıkarılmıştır. Belirtilen işlem sonrasında, gerekli model parametreleri belirlendikten sonra modelin eğitimi (model training) gerçekleştirilmiştir. Sonrasında bahsedilen modeller için sınıflandırma sonuçları (model evaluation) alınmıştır.

Bu tezin geri kalanı şu şekilde düzenlenmiştir. Bölüm 2’de, FMCW radarları tarafından benimsenen cıvıltı (chirp) dizisi frekans modülasyonunu tanıtmaktadır. RD görüntülerinin (veri setinin) nasıl elde edildiği nasıl okunduğu ve işlendiği Bölüm 3’te detaylı olarak açıklanmıştır. İlgili bölümün devamında makine öğrenimi ve derin öğrenme model

mimarileri ve eğitim süreçleri açıklanmıştır. Gerçek RD verilerini kullanan deneysel olarak elde edilen sınıflandırma sonuçları Bölüm 4’te sunulmaktadır. Son olarak, tartışmalar ve gelecekteki çalışmalar Bölüm 5’te verilmiştir.




2. TEORİK ALTYAPI

2.1. Radar Teknolojisi

Radar kelimesi Radio Detection And Ranging kelimelerinin kısaltmasıdır. Elektromanyetik dalgalar yayan ve objelerden gelen yankıyı analiz eden cihazlara radar denilmektedir. Radarlar tüm hava koşullarında, yakın ve uzak menzillerde kullanılabilmekte ve yüksek doğrulukta sonuçlar vermektedir.

2.1.1. Çalışma prensibi

Radarlar ile ölçüm yapılırken, radar öncelikle elektromanyetik darbeler yaymaya başlar ve ardında dinleme moduna geçiş yapar. Radarın yaydığı elektromanyetik darbeler bir obje ile karşılaştığında seker ve radar seken darbelerin yankısından ölçüm yapar. Radar çalışma prensibi Şekil 2.1’de gösterilmiştir.



Şekil 2.1. Radar Çalışma Prensibi

2.1.2. Radar denklemleri

Yansıyan darbelerin oluşturduğu yankının gücü aşağıdaki formül ile hesaplanabilmektedir.

$$P_r = \frac{P_t G^2 \lambda^2 \sigma}{(4\pi)^3 R^4 L} \rightarrow R = \sqrt[4]{\frac{P_t G^2 \lambda^2 \sigma}{(4\pi)^3 L P_r}} \quad (2.1)$$

P_t : İletim gücü;

G : Anten kazancı;

λ : Radar çalışma dalga boyu;

σ : Hedef radar kesiti (RCS);

R : Radardan hedefe menzil;

L : Diğer kayıplar (sistem, yayılma).

Uzak menzilli ölçümlerde düşük frekanslı darbeler tercih edilir ve düşük radar kesit alanına sahip objeler daha zor tespit edilebilmektedir.


2.1.3. Radar ile uzaklık ölçümü

Radar ile uzaklık ölçümü sırasında aşağıdaki formül kullanılmaktadır.

$$R = \frac{rc}{2} \quad (2.2)$$

Formülde (2.2), c elektromanyetik dalgaların hareket hızıdır ve ışık hızına (3×10^8 m/s) eşittir ve r ekodaki gecikmeye eşittir.


Radar tarafından yayılan titreşimin hedefe ulaşması ve hedeften yansiyarak tekrar radara geri dönmesi süreci, zaman-mesafe ekseninde Şekil 2.2’de gösterilmiştir.



Şekil 2. 2. Radar Sinyalinin Hedefe Ulaşıp Geri Yansıma Süreci

2.1.4. Yön Belirlenmesi

Hedefin yönü, antenin yönlülüğü yani antenin enerjiyi belirli bir yönde iletme yeteneği ile belirlenir. Yankı sinyali alındığında antenin baktığı yön ölçülerek hem hedefin azimut hem de yükseklik açıları belirlenebilir. Hedefin yönünün belirlenmesi Şekil 2.3'te belirtilmiştir.



Şekil 2.3. Hedef Yönünün Belirlenmesi


2.1.5. Darbe Tekrarlama Aralığı (PRI)

Darbe tekrarlama aralığı, birbirini izleyen darbeler arasındaki zaman aralığı olarak tanımlanır (2.3) ve Şekil 2.4'te gösterilmiştir. Darbe tekrarlama frekansının (PRF) tersidir.

$$PRF = \frac{1}{PRI} \quad (2.3)$$

Görev döngüsü konsepti (2.4) ise, iletimin gerçekleştiği PRI'nin zaman oranı olarak tanımlanır.

$$Görev\ döngüsü = \frac{T}{PRI} \quad (2.4)$$



Şekil 2.4. Darbe Tekrarlama Aralığı (PRI)


2.1.6. Maksimum Belirsiz Menzil

Bir radar ancak belirli mesafelerdeki objeleri tespit edebilmektedir. Bu mesafenin dışında kalan objeler radar için belirsizdir. Bu mesafe aşağıdaki formül ile hesaplanmaktadır.

$$R_{max} = \frac{c(PRI)}{2} = \frac{c}{2(PRF)} \quad (2.5)$$

2.1.7. Veri Matrisi (Data Matrix)

Her bir PRI'dan gelen radar veri geri dönüşü, daha sonraki işlemler için bellekte saklanmaktadır.




Şekil 2.5. Radar Veri Matrisinde Hızlı ve Yavaş Zaman Ekseninde Hedef Hareketlerinin Gösterimi

Yukarıda gösterilen Şekil 2.5'te, iki hedef örneği, biri aynı çözünürlük kutusunda (turuncu) ve diğeri farklı çözünürlük kutularında hareket eden (yeşil) gösterilmektedir. Hızlı Zaman, örnekleme hızına bağlı olarak bir PRI oluşturan farklı zaman dilimlerini ifade etmektedir. Yavaş Zaman her PRI'yi güncellemektedir.

2.1.8. Veri Küpü

Veri Küpü, uzamsal örnekleme boyutunu da içerecek şekilde, Veri Matrisi (Data Matrix) yapısının üç boyutlu bir uzantısıdır. Radar sistemlerinde birden fazla alıcı kanalın kullanıldığı durumlarda, her alıcıdan elde edilen veri matrisleri uzamsal boyutta bir araya

getirilerek üç boyutlu bir veri küpü hâlinde organize edilir.



Şekil 2.6. Radar Sistemlerinde Hızlı Zaman, Yavaş Zaman ve Alıcı Kanal Boyutlarında Veri Küpü Gösterimi


N alıcı kanalından oluşan bir sistemde her PRI ve M PRI'deki L zaman örnekleri için bir veri küpünün gösterimi yukarıda verilmiştir.

2.1.9. Dalga Sinyali Spektrumu

Çalışma frekansı f_0 olan bir sürekli dalga (CW) radarını ele alalım. Radyal hız u_r ile hareket eden bir hedefin varlığında, Doppler fenomeni nedeniyle, yankılanan sinyalin frekansı aşağıdaki formülde belirtilen şekilde değişmektedir.

$$f_D = \frac{u_r}{c} f_0 \quad (2.6)$$

Eşitlik (2.6) için; Pozitif Doppler kaymaları ($f_D > 0$) hedefin radara doğru hareket ettiğini, negatif ($f_D < 0$) ise radardan uzaklaştığını göstermektedir. Şekil 2.7’de sabit radar ve hareketli hedef senaryosunun temsili gösterimi yapılmıştır.




Şekil 2.7. Sabit Radar ve Hareketli Hedef Senaryosu: Üst Görsel: Radar Hedef Sisteminin Geometrisi, Alt Görsel: Radar Tarafından Gözlemlenen Frekans.

2.2. FMCW Radar

FMCW Radarı çok basit bir Sürekli Dalga (CW) Radarında olduğu gibi, sürekli dalga yollayan radar sensörlerinin bir çeşididir. CW radarının aksine, bir FMCW radarı, ölçüm yapıldığı anlarda gönderilen işaretin çalışma frekansını değiştirebilir. Bu durum, gönderim işaretinin frekansının modüle ediliyor olması anlamına gelmektedir. Gelen işaretin frekansındaki bu değişim neticesinde, yeni ölçüm imkanları ortaya çıkmıştır. Basit CW

radarlarında gönderim ve alım işaretleri sebebiyle oluşan dalganın sürekli. Bu nedenle, gerekli olan bir zaman noktası işaretlenemez ve gidiş – dönüş süreleri arasındaki Δt zaman farkı ya da $\Delta \phi$ faz farkı ölçülemez. Şekil 2.8’de gösterildiği üzere, FMCW radarı ile hareketsiz bir canlı veya nesnenin menzilin ölçümü için gerekli böyle bir zaman referansı, ancak gönderim işaretinin frekansının modülasyonu ile hesaplanabilir.




Şekil 2.8. Frekans Modülasyonlu Sürekli Dalgalar (FMCW) ile Menzil Ölçümü

FMCW radarının önemli özellikleri arasında, çok kısa menzillerde dahi ölçüm yapabilme yeteneği vardır. Menzil ve radyal hız aynı anda ölçülebilir ve menzil ölçümünün doğruluk değeri çok yüksektir. Karıştırma (Mixer) devresi kullanılarak yankı işaretlerinin frekansı düşük seviyelere indirgenir. Bu sayede hem çalışılan devreler oldukça basit bir hale indirilir hem de düşük güçlü ve sürekli sinyal gönderilir. Dolayısı ile yüksek güçlü darbeleri radarlar gibi tehlikeli ışımlar meydana getirmediği için güvenli kabul edilebilir.

2.2.1. Temel FMCW Radar Yapısı

Bir FMCW radarı esas olarak alıcı-verici ve mikroişlemcili bir kontrol ünitesinden oluşur. Alıcı ve verici aynı modüldedir. Radarın verici kısmı, yüksek frekanslı sinyalleri voltaj kontrollü bir osilatör (VCO) aracılığıyla üretir ve bu sinyaller anten üzerinden ortama iletilmeden önce güçlendirici bir devre (amplifikatör) ile yükseltilir. Osilatör tarafından

üretile yüksek frekans sinyalinin bir kısmı ise ayrılarak (akuple edilerek) karıştırıcı (mixer) bileşenine yönlendirilir. Karıştırıcı, gönderilen sinyalle hedeften yansıyarak geri dönen ve alıcı tarafından alınan yankı sinyalini karşılaştırarak frekans farkını (beat frequency) oluşturur. Bu fark, hedefin uzaklığı hakkında bilgi sağlar. Şekil 2.9’da temel bir FMCW Blok Diyagramı gösterilmiştir.



Şekil 2.9. FMCW Radar Blok Diyagramı

2.2.2. FMCW Radar ile Menzıl Ölçümü

Menzil ölçümü, alınan işaretin frekansının bir referans işareti frekansı ile karşılaştırılması ile hesaplanır. Yansıtıcı nesnenin R uzaklığı aşağıdaki formülle hesaplanır.

$$R = \frac{C_0 |\Delta t|}{2} = \frac{C_0 |\Delta f|}{2 \left(\frac{d(f)}{d(t)} \right)} \quad (2.7)$$

Yukarıdaki eşitlikte (2.7), C_0 : Işık Hızı = 3.10^8 [m/s], Δt : Zaman [s], Δf : Ölçülen frekans hızı [Hz], R : Anten ile nesne arasındaki uzaklık [m], $\frac{d(f)}{d(t)}$: Birim zamandaki frekans kaymasını ifade etmektedir.

2.2.3. Maksimum Menzil ve Menzil Çözünürlüğü

Radar çözünürlüğü, birim zaman başına frekans sapmasının uygun seçimi ile belirlenir. Frekans süresinin arttırılması ile (Şekil 2.1'de f eksen) ile maksimum belirsiz olmayan aralık belirlenebilir. Uygulanan devrenin teknolojisi ile maksimum kenarın frekans kayması ve dikliği, cihazın yeteneklerine bağlı olarak değişebilir. FMCW radarının menzil çözünürlüğü için, radarın iletilen sinyalinin bant genişliği belirleyicidir (chirp radarında olduğu gibi). Ancak, Hızlı Fourier Dönüşümünün teknik olanakları zamanla sınırlıdır (Şekil 2.1'de t süresi).

FMCW radarının çözünürlüğü, bu zaman sınırı içinde meydana gelen frekans değişikliği ile belirlenir.

$$\Delta f_{FFT} = \frac{1}{T} = \frac{\partial(f)}{\partial(t) \cdot (f_y - f_a)} \quad (2.8)$$

Yukarıdaki eşitlikte (2.8), Δf_{FFT} : ölçülebilir en küçük frekans farkı, $\frac{\delta(f)}{\delta(t)}$: frekans sapmasının dikliği, f_y : üst frekans, f_a : alt frekansı ifade etmektedir.

2.3. Menzil Doppler Haritalar

2.3.1 Menzil Doppler Analizi


RD alanında bir sinyali görselleştirmek, hedefler arasındaki bağlantıları sezgisel olarak anlamamıza yardımcı olabilir. Bir RD haritasından aşağıdaki uygulamalar

yapılabilmektedir.

Hedeflerin ne kadar uzakta oldukları, hedeflerin yaklaşma veya uzaklaşma hızları ölçülebilmektedir. Çeşitli hızlardaki ve menzillerdeki hedefler arasında ayırım yapılabilmektedir. Örneğin;

Eğer verici platformu sabitse, RD haritasında bulunan sabit nesneler için alınan cevap sıfır Dopplerdir. Eğer verici platformu sabitse, RD haritasında bulunan hareketli nesneler için alınan cevap sıfırdan farklıdır.

Hareketli bir hedefte, alınan her bir darbede faz bilgisi vardır ve farklı tepkiler Doppler düzleminde ayrıştırılabilir. RD haritası elde edilmesi için, Şekil 2.10 da gösterildiği gibi Fourier Dönüşümü uygulanarak Hızlı zaman Menzil'e ve Yavaş zaman Doppler'e dönüştürmektedir.



Şekil 2.10. Hızlı Zaman ve Yavaş Zaman Grafiği üzerinden RD Haritasının Elde Edilmesi

3 hedef senaryosu: ikisi aynı aralıkta kutu ve farklı hızda (yeşil ve turuncu) ve biri farklı aralıkta (mavi), (L) Veri matrisinde iki hedef ayrılabilir, (R) RD haritasında 3 hedef de ayrılabilir.

2.4. Makine Öğrenimi

Makine öğrenimi (ML), bilgisayar sistemlerinin açıkça programlamadan, verilerden öğrenerek görevleri yerine getirme yeteneği kazanmasını sağlayan bir yapay zeka alt dalıdır. Temel olarak, makine öğrenimi, sistemlerin verilerdeki örüntüleri tanıyarak tahmin yapma, karar verme veya belirli görevleri otomatikleştirme becerisi geliştirilmesine odaklanır.

Makine öğrenimi, bir algoritmanın geçmiş verilerden (örneğin, örnekler veya deneyimler) öğrenerek yeni verilere genelleme yapmasını sağlar. Örneğin, bir makine öğrenimi modeli, binlerce köpek ve kedi fotoğrafına bakarak bu hayvanları ayırt etmeyi öğrenebilir ve daha sonra yeni bir fotoğrafta hangi hayvanın olduğunu tahmin edebilir.

Makine öğrenimi, Arthur Samuel'in terimi popülerleştirmesi ve erken uygulamalarıyla başlamış, ancak Turing, Rosenblatt, Hebb ve daha sonra Hinton, LeCun gibi birçok araştırmacının katkılarıyla şekillenmiştir. Alan, kolektif bir çabayla gelişmiş ve bugün veri bilimi ile yapay zekanın temel taşlarından biri haline gelmiştir.

2.4.1. Rastgele Orman


Rastgele Orman (RF), hem sınıflandırma hem de regresyon problemleri için kullanılan, topluluk öğrenmesi (ensemble learning) temelli güçlü bir makine öğrenimi algoritmasıdır. Adından da anlaşılacağı gibi, birden çok karar ağacının bir araya gelerek oluşturduğu bir "orman"dır. Bu ormandaki her bir ağaç, veri kümesinin farklı bir alt kümesi ve farklı bir özellik alt kümesi üzerinde birbirinden bağımsız olarak eğitilir. Sonuçlar birleştirilerek (sınıflandırmada oylama, regresyonda ortalama) daha sağlam ve kararlı bir tahmin yapılır. Tek bir karar ağacı genellikle yüksek varyansa sahiptir: eğitim verisinde çok başarılı olabilir ama testte başarısız olur. RF, birden fazla bağımsız ağaç oluşturarak bu sorunu çözer. Sonuç olarak, RF tek bir karar ağacının potansiyel zayıflıklarını (aşırı uyum gibi) azaltır ve daha genelleme ve sağlam bir model ortaya çıkarır.

Sınıflandırmada, her ağaç kendi sınıf tahminini yapar. Çoğunluğun (majority vote) verdiği sınıf, nihai sonuç olur. Regresyonda ise her ağaç bir sayı tahmini yapar, ortalaması alınır ve sonuç elde edilir.

$$\hat{y} = \frac{1}{B} \sum_{i=1}^B T_i(x) \quad (2.9)$$

Bu eşitlikte (2.9), $\hat{y}$ modelin tahmin ettiği nihai sürekli değeri, B değeri RF içerisindeki toplam karar ağacı sayısını, $T_i(x)$ i numaralı karar ağacının giriş verisi için yaptığı tahmini ve x ise girdi verisini ifade eder.

Şekil 2.11’de Rastgele Orman sınıflandırma süreci görselleştirilmiştir.



Şekil 2.11. Rastgele Orman Sınıflandırma Süreci

2.4.2. Aşırı Gradyan Artırmalı Öğrenme (XGB - Extreme Gradient Boosting)

Gradyan artırmalı öğrenme (gradient boosting) çerçevesi üzerine inşa edilmiş, optimize edilmiş ve dağıtılmış bir açık kaynak makine öğrenimi kütüphanesidir. Temel amacı, hızı ve performansı en üst düzeye çıkarmaktır. XGB hem sınıflandırma hem de regresyon problemleri için yaygın olarak kullanılan güçlü ve popüler bir algoritmadır ve birçok makine öğrenimi yarışmasında (örneğin Kaggle) üstün başarı göstermiştir. Temelinde bir topluluk öğrenmesi algoritması olan XGB, zayıf öğrencileri (genellikle karar ağaçları) sıralı bir şekilde birleştirerek güçlü bir tahmin modeli oluşturur. Ancak RF'den farklı olarak, XGB ağaçları bağımsız olarak değil, önceki ağaçların hatalarını düzelterek ardışık olarak eğitir.

XGB, öğrenme sürecinde optimize ettiği iki kavramdan oluşan bir amaç fonksiyonu kullanır. Bunlardan ilki kayıp fonksiyonu (loss function), tahmin hatasını ölçer (örneğin: log loss, mean squared error). İkincisi ise düzenleme (regularization), model karmaşıklığını cezalandırır (çok fazla dallanma, aşırı uyum riski). Bu sayede hem genel performans artar hem de aşırı uyum (overfitting) önlenir. Ağaç yapısı oluşturulurken her adımda bölme (split) noktaları gradyan kazancı (gain) üzerinden belirlenir. Bölme işlemleri, modelin hatayı en çok azaltacağı şekilde optimize edilir. Her yaprak düğüm, sabit bir tahmin değeri taşır. Yeni ağaç, daha önceki modelin hatalarını düzeltmeye çalışır. Toplam tahmin, önceki modelin çıktısı + yeni modelin çıktısı olarak güncellenir:

$$\hat{y}^{(t)} = \hat{y}^{(t-1)} + \eta f_{t(x)} \quad (2.10)$$

Bu formülde;


$\hat{y}^{(t)}$: t. iterasyondaki modelin tahmini (güncellenmiş tahmin)

$\hat{y}^{(t-1)}$: bir önceki iterasyondaki tahmin

η : öğrenme oranı (learning rate)

$f_{t(x)}$: t. ağacın tahmini (t. zayıf öğrenci)

Şekil 2.12’de Aşırı Gradyan Artırmalı Öğrenme için sınıflandırma süreci görselleştirilmiştir.



Şekil 2.12. Aşırı Gradyan Artırmalı Öğrenme Sınıflandırma Süreci

2.5. Sinir Ağları


Bu bölümde sinir ağları kavramı kısaca açıklanmıştır. Tez çalışmasında odak noktası olacak bazı model ve model geliştirme parametrelerinin tanımları üzerinde durulacaktır. Şekil 4.1’de basit bir İleri Beslemeli Yapay Sinir ağı yapısı görülmektedir.

2.5.1. Yapay Sinir Ağları (ANN)

Yapay sinir ağları (ANN), algılayıcı (perceptron) veya nöron adı verilen basit bilgi işlem birimlerinden oluşan bir ağıdır. Sınıfları atanmış büyük boyutta girdi datalarından öğrenme işlemini gerçekleştirerek çıktıyı tahmin ederler. Sinir ağı terimi literatürdeki yerini canlı beyindeki merkezi sinir sisteminden esinlenilerek almıştır. Birbirine paralel olup

aralarında herhangi bir bağ olmayan nöron dizisine katman denir. Bir katman içerisindeki nöronların çıktısı, bir sonraki katmanda ağırlık matrisi cinsinden girdi olarak değerlendirilir. Bir ağı derinliği ardı ardına gelen katmanlar ile arttırabilir.

En bilinen ANN modeli ileri beslemeli çok katmanlı algılayıcıdır (MLP). Bu model içinde her nöron –eğer var ise- bir önceki ve bir sonraki katmandaki nöronlara bağlıdır. Bu yüzden MLP, Tam Bağlı Ağ (FCN – Fully Connected Network) olarak da bilinmektedir. İleri beslemeli teriminin çıkış noktası, ağ üzerinde veri akarken ve katmanlardaki nöronların ağırlıkları yenilenirken herhangi bir geri besleme döngüsü olmamasından kaynaklanır. Geri besleme döngüsüne sahip olan yapay sinir ağı, Özyinelemeli Sinir Ağı (RNN) olarak adlandırılır. Bölüm 2.5’in devamında ayrı bir kısım olarak bahsedilecektir. Şekil 2.13’de basit bir İleri Beslemeli Çok Katmanlı Yapay Sinir Ağı yapısı görülmektedir. Bir yapay sinir ağı yapısını anlamak, evrimsel sinir ağlarına geçişte bir temel oluşturması ve tezde kullanılan 2D-CNN modelini kavrayabilmek açısından önemlidir.



Şekil 2.13. İleri Beslemeli Çok Katmanlı Yapay Sinir Ağı

2.5.2. Algılayıcılar ve Aktivasyon Fonksiyonları

Algılayıcı, bir diğer ifade ile nöron, bir $x \{x_0, \dots x_m\}$ vektörünü girdi olarak alan, bu vektörün, $w_j \{w_{j0}, \dots w_{jm}\}$ ağırlık vektörü ile nokta çarpımını hesaplayan ve çıktı olarak skaler $v_j(n)$ vektörünü veren bir fonksiyondur. Bu vektörün uzun formu aşağıda gösterilmiştir.

$$v_j(n) = \sum_{i=0}^m (w_{ji}(n)x_i(n)) = w_j^T x \quad (2.11)$$

Denklemdeki (2.11) “j”, nöron indeksini, “n” anlık iterasyon ve “m” girdi sayısını ifade etmektedir. Ağırlık vektörü w_{j0} , j nöronunun sapma değerine eşittir. Sapma (bias) değeri aktivasyon fonksiyonunu sağa veya ötelenmesini (shift) sağlayan değerdir. Aktivasyon fonksiyonu $f_j: \mathbb{R} \rightarrow \mathbb{R}$ uygulandıktan sonra nöron çıktısı $y_j(n) = f_j(v_j(n))$.

Aktivasyon fonksiyonu, ağırlıklı girdi için doğrusal olmayan bir karar sınırı alanı üretir ve sonucu, olasılığa dönüştürür. Fonksiyon genellikle sigmodial bir doğrusalsızlık ve Logistic sigmoid fonksiyonunun bir formu olarak uygulanır. Fonksiyon aşağıda belirtilmiştir.

$$f_{sigmoid}(x) = \frac{1}{1 + e^{-x}} \quad (2.12)$$

Bir diğer aktivasyon fonksiyonu ise Hiperbolik tanjant fonksiyonu olarak adlandırılan ve aşağıdaki uzun hali verilen fonksiyondur.

$$f_{tanh}(x) = \frac{e^{2x} - 1}{e^{2x} + 1} \quad (2.13)$$

Fonksiyon (2.13) temel olarak, ilk fonksiyonun yeniden ölçeklendirilmiş ve taraflı (biased) versiyonudur. Hâlihazırda, derin sinir ağları için en popüler ve en çok önerilen

aktivasyon fonksiyonu, “rectifier” olarak adlandırılır ve fonksiyon aşağıda verilmiştir.

$$f_{LU}(x) = (0, x) \quad (2.14)$$

Rectifier aktivasyonundaki öğeler, Rectified Linear Units veya ReLU olarak adlandırılır. ReLU’nun popülerliğinin arkasında nöron ağ eğitimi uygulamalarını, diğer operasyonlara göre katlarca daha hızlı yapma yeteneğidir. Sigmoidal doğrusalsızlıklar aksine, yoğunlaştırıcı bir fonksiyon değildir. ReLU’nun yoğunlaştırıcı bir fonksiyon olmadığı gradyan inişi gibi gradyan tabanlı fonksiyonların optimizasyonunu hızlandırması ile kanıtlanmıştır.

Çıktı katman aktivasyonları için durum, gizli katman aktivasyonlarındaki durumdan farklıdır. İkili sınıflandırma için tercih edilen çıktı katman nöronu aktivasyon fonksiyonu, logistic sigmoid, diğer bir adı ile “logit” modelidir. Çok sınıflı sınıflandırma işlemlerinde ise “multinomial logit” modeli uygulanır. Bu model “softmax” doğrusalsızlığını kullanır ve her bir bileşen için x vektörü aşağıda belirtildiği gibi tanımlanmaktadır.

$$f_{softmax}(x_j) = \frac{e^{x_j}}{\sum_{k=1}^K e^{x_k}} \quad (2.15)$$

Burada (2.15) “K” tüm farklı sınıfların sayısını temsil etmektedir. Softmax regresyonu, çok sınıflı bir lojistik regresyon modelinin geliştirilmiş halidir. Çıktı olarak tek sıcak kodlanmış (one-hot encode) sınıf olasılıkları vermektedir ve söz konusu sınıfların birbirlerini tamamen dışlayan sınıflar olması tercih edilmektedir.

2.5.3. Regülerizasyon

Derin ANN’deki büyük miktardaki ağırlık nedeniyle, aşırı öğrenme kaçınılmaz bir sorun haline gelmektedir. Aşırı öğrenme, ağır eğitim verisini dolaysız bir şekilde öğrenmesi ile henüz elde edilmemiş veri için fazla taraflı olması ve yeterince genelleşmiş olamama

durumdur. Bu durum derin öğrenme için temel bir problemdir ve bunu azaltmak için birkaç yöntem vardır. Regülerizasyon bunlardan biridir.

Regülerizasyon yöntemlerinden biri bırakma (dropout) tekniğidir. Bu teknik, gizli ağ katmanının aktivasyonlarına sabit miktarda gürültü ekler, bu da belirli bir olasılıkla nöron aktivasyonunun yapılmadığı anlamına gelir. Örneğin, bırakma oranı 0.4 ise, bu durumda %40 olasılıkla, hesaplamalardan çıktıya doğru gizli bir birim (nöron) düşürülür. Tekniğin dezavantajı ise öğrenme sürecini yavaşlatmasıdır.

Derin ANN öğrenimi (eğitimi) genellikle birden çok iterasyon içermektedir ve eğer bırakma gibi bir regülerizasyon metodu kullanıldıysa, süreç daha da fazla zaman almaktadır. Bu sebeple, eğitim sırasında “tanh” gibi doygun aktivasyon fonksiyonları kullanmak, eğitimi zorlaştırmaktadır. Bu problem, içsel eşdeğer kaydırma (internal covariate shift) olarak adlandırılır ve bu sorun doğru parametre ile başlatma veya giriş katmanının normalleştirilmesi ile azaltılır.

2.5.4. Evrişimsel Sinir Ağları (CNN)

Pasif Radar mimarisinde aydınlatıcı olarak farklı frekans ve modülasyon özelliklerine sahip analog veya sayısal aydınlatıcılar kullanılmaktadır. Çıkış gücü, bant genişliği, taşıyıcı frekansı ve modülasyon türü aydınlatıcı seçiminde kritik önem arz etmektedir. FM radyo aydınlatıcıları, dijital televizyon aydınlatıcıları, uydu tabanlı GNSS aydınlatıcıları ve GSM aydınlatıcıları bunlara örnektir. Pasif Radarlar belirli bir frekansta yayın yapmadıkları için gizli radarlar olarak da bilinirler ve elektronik harp sistemleri tarafından tespit edilmesi zor sistemlerdir. Ancak, geleneksel radarlara göre daha az maliyetlidirler ve dijital haberleşme modülasyonlarının gelişmesiyle frekans spektrumun aynı anda farklı amaçlar için kullanılmasına imkân tanır.

2.5.5. 2 Boyutlu Evrişimsel Sinir Ağları

Evrişimli sinir ağlar konsepti en temelinde tam bağlı MLP’ye benzerdir. Her ikisi de ağırlık ve eğilimlere sahiptir. Temel fonksiyonelliklerini giriş ve nöron ağırlıklarının

çarpımı ile gerçekleştirirler. Ancak, bu yapıdaki nöronlar tam bağlı MLP yapısının aksine giriş verisinin küçük bir kısmına bağlanır.

$$y_{xy} = f \left(\sum_i \sum_j w_{ij} v_{(x+i)(y+j)} + b \right) \quad (2.16)$$

Bu formülde (2.16) $y_{xy}(x,y)$ deki özellik haritasını, w_{ij} kernel ağırlığını ve $v_{(x+i)(y+j)}$ deki girdi bilgisini ifade etmektedir.

2D-CNN mimarisi, evrişim (convolution), aktivasyon (activation), havuzlama (pooling), bırakma (dropout), flatten (düzleştirme) ve tam bağlantılı (fully connected) katmanlardan oluşur. Evrişim katmanları, girdi üzerinde filtreler uygulayarak kenar, doku ve desen gibi yerel özellikleri (features) çıkarır. Aktivasyon katmanları, her nöronun çıktısına uygulanan matematiksel fonksiyonlarla düz çizgiyle ayrılabilir ilişkilerin ötesine geçilmesini (örn: ReLU fonksiyonu ile) sağlar. Böylece ağ, sınırlı doğrusal modellerin öğrenemeyeceği eğri yapılar ve karmaşık desenleri de yakalayabilir. Havuzlama katmanları (örneğin max pooling), uzamsal boyutları küçülterek parametre sayısını azaltır ve özniteliklerin konumsal değişimlere karşı dayanıklı olmasını sağlar. Bırakma katmanı, eğitim sürecinde aşırı öğrenmeyi önlemek amacıyla kullanılan düzenleme (regularization) yöntemlerinden biridir. Düzleştirme (flatten) katmanı, çok boyutlu öznitelik haritalarını tek boyutlu vektöre dönüştürerek tam bağlı katmanlara geçişi sağlar. Tam bağlantılı katmanlar ise, çıkarılan özniteliklere göre nihai sınıflandırma veya regresyon işlemlerini gerçekleştirir.

2.5.6. Görüntü Dönüştürücüsü (ViT)

Görüntü dönüştürücüsü (ViT), görsel verileri işlemek için geliştirilmiş bir yapay zeka modelidir ve özellikle görüntü sınıflandırma gibi görevlerde kullanılır. Geleneksel evrişimli sinir ağlarına (CNN) alternatif olarak, doğal dil işleme (NLP) alanında başarılı olan Transformer mimarisini bilgisayarlı görü (computer vision) alanına uygular. ViT, Ekim

2020 yılında Google Research tarafından tanıtılmış ve görüntü işleme alanında çığır açan bir yaklaşım olarak dikkat çekmiştir. Bu yaklaşım, görüntüleri küçük parçalara ayırarak ve bu parçaları sıralı vektörler olarak işleyerek çalışır. Dikkat (Attention) mekanizması sayesinde görüntüdeki global bağlamı etkili bir şekilde yakalar. Büyük ölçekli veri setleriyle eğitildiğinde yüksek performans gösteren ViT, görüntü sınıflandırma, nesne algılama ve segmentasyon gibi alanlarda yenilikçi çözümler sunar. Ancak, hesaplama maliyeti ve veri bağımlılığı gibi sınırlamaları da bulunmaktadır.

ViT geleneksel CNN'lerde olduğu gibi tüm görüntüyü tek seferde almaz. Onun yerine girdi görüntüsü (örneğin 224x224 piksel, 3 kanal) küçük parçalara (patch) ayrılır. Örneğin, 16x16 piksellik yamalarla bu görüntüden toplam 196 adet patch (14x14) elde edilir. Her bir yama (patch), düzleştirilip bir vektöre dönüştürülür ve bir gömme (embedding) işlemine tabi tutulur. Bu işlem, her yamanın özelliklerini içeren sabit boyutlu bir vektör haline getirilmesini sağlar.

$$e_j = x_j W e + b_e \quad (2.17)$$

Bu eşitlikte:

x_j : düzleştirilmiş j. yama (patch)

$W e$: öğrenilen ağırlık matrisi

b_e : bias terimi

e_j : gömme vektörü

Dönüştürücü (transformer) mimarisi sıralı verilerle çalışır, fakat yama vektörleri doğal bir sıra içermez. Bu yüzden her yamaya (patch) konum bilgisi (positional encoding) eklenir. Ancak, bu durum Görsel Dönüştürücü için geçerli değildir. Görsel dönüştürücüde; Görüntü 224x224 olarak kabul edilir ve bu görüntüler eşit parçaya bölünür (16x16). Her yama düzleştirilir (flatten) ve bir vektöre çevrilir. Ancak bu yama normal bir sıraya sahip değildir.

Her yamaya gömülü vektöre (embedding) karşılık gelen konum vektörü eklenir:

$$Z_0 = [x_{class}; x_p^1 E; \dots; x_p^N E] + E_{pos} \quad (2.18)$$

Bu eşitlikte:

x_{class} : öğrenilebilir class token vektörü

x_{pi} : i. yamanın embedding vektörü

E_{pos} : her pozisyon için ayrı bir embedding vektörü içeren matris (learnable)

ViT, her yama vektörünü Transformer Encoder bloklarından geçirir. Her blok şunları içerir:

Çok Başlı Dikkat (Multi-Head Self Attention): Her yama, diğer tüm yamalarla olan ilişkisini değerlendirir. Dikkat mekanizması sayesinde model, görüntüdeki global bağlamı anlayabilir. Örneğin: Bir kedinin kuyruğunun, yüzünden uzakta olduğunu ama aynı nesneye ait olduğunu öğrenir. Çok başlı dikkat matematiksel ifadesi (2.19) eşitliğinde verilmiştir.

Katman Normalizasyonu (Layer Norm) ve Artık Bağlantılar (Residuals): Derin ağlarda stabil öğrenme için kullanılır. Bilgi akışını kaybetmeden, önceki katman bilgileri korunur.

Çok Katmanlı Algılayıcı (MLP) Blok: Her bir yama (patch) vektörü, küçük bir sinir ağı olan MLP'den geçer. Bu bloklar, öğrenilen dikkat çıktılarından daha soyut özellikler üretir. MLP matematiksel ifadesi (2.20) deki eşitlikte verilmiştir.

NOT: Bu bloklar genellikle 12 veya daha fazla kez tekrarlanır.

$$Z_l = MSA(LN(Z_{l-1})) + Z_{l-1} \quad (2.19)$$

$$Z_l = MLP(Z_l) + Z_l \quad (2.20)$$

Bu iki denklem, bir dönüştürücü kodlayıcı (transformer encoder) bloğunun temel yapısını yansıtır. İlk denklemde, dikkat mekanizması (attention) uygulanır; ikinci denklemde ise yoğun katmanlar (MLP) ile daha soyut temsiller elde edilir. Her ikisinde de artık bağlantılar kullanılarak bilgi akışı korunur ve gradyanların kaybolması engellenir.

Eşitlik (2.19) için, Z_l Bu katmandan çıkan yeni özellik temsilini, (Z_{l-1}) ise bir önceki katmandan $(l-1)$ çıkan özellik (feature) temsilini yapar. *MSA* girdi dizisinin kendi içindeki ilişkilerini öğrenir, *LN* ise girdinin istatistiksel olarak normalize edilmesini sağlar.

Eşitlik (2.20) için ise, Z_l (2.19)'dan gelen güncellenmiş özellik temsilidir. *MLP* Çok Katmanlı Algılayıcıdır. Genellikle bir veya iki katmanlı, tam bağlı (fully connected) yapıdır. Dönüştürücü bloklarında kendine dikkat mekanizmasından (self-attention) sonra gelir. $+Z_l$ ise yine bir rezidual bağlantıdır; *MLP* çıktısı, girdisiyle toplanır ve bu, öğrenmenin derinleşmesini kolaylaştırır.

NLP'de olduğu gibi, ViT bir [CLS] (class) token'ı da ekler. Bu özel token, tüm görüntü hakkındaki özet bilgiyi öğrenir ve en sonunda sınıflandırma için kullanılır. Son Encoder bloğundan çıkan CLS token, bir tam bağlı katmana (fully connected layer) gönderilir. Bu katman, görüntünün ait olduğu sınıfı belirler (örneğin: kedi, köpek, araba vs.).

Tüm ViT formüllerinin toplu olarak gösterildiği formül aşağıdadır.

$$\hat{y} = softmax(W \cdot z_{class}) \quad (2.21)$$


Bu formülde:

z_{class} : son encoder'dan çıkan CLS token temsilidir.

W : sınıf sayısı kadar çıkış üreten ağırlık matrisi

$\hat{y}$: modelin tahmin ettiği olasılık dağılımı

Şekil 2.14’de Görsel Dönüştürücü (ViT) Modeli için sınıflandırma süreci görselleştirilmiştir.



Şekil 2.14. Görsel Dönüştürücü (ViT) Modeli Sınıflandırma Süreci

2.6. Görüntü İşleme

Derin öğrenme modellerinin performansını arttırmak için bozulmuş görüntülerden gürültünün arındırılması ve orijinal görüntünün kurtarılması esastır. Gürültülü ve gürültüden arındırılmış örnek bir resim Şekil 3.5’te gösterilmiştir.

Görüntü işleme, sayısal görüntüler üzerinde çeşitli işlemler uygulayarak bu görüntülerden anlamlı bilgi çıkarmayı, kalitesini artırmayı veya belirli özellikleri ön plana çıkarmayı amaçlayan bir disiplindir. Görüntü işleme teknikleri, özellikle bilgisayarla görü ve derin öğrenme alanlarında model başarımını doğrudan etkileyen kritik bir adımdır.

Makine öğrenimi ve derin öğrenme modellerinin performansını arttırmak için,

bozulmuş görüntülerden gürültünün arındırılması (görüntü gürültü azaltma) ve orijinal görüntünün yeniden elde edilmesi (restorasyon) büyük önem taşır. Çünkü modeller, genellikle yüksek kaliteli ve temiz verilerle daha doğru sonuçlar üretir.

Bu bağlamda, görüntü işleme teknikleri, özellikle gürültü filtreleme ve iyileştirme süreçlerinde aktif olarak kullanılarak derin öğrenme modellerine daha sağlam ve güvenilir giriş verileri sağlanmasına olanak tanır.

Radar verilerinde, özellikle RD haritalarında, sistem kaynaklı parazitler, çevresel gürültü ve sinyal yansımasından doğan yüksek frekanslı gürültü bileşenleri sıkça karşılaşılan bozulmalar kaynakları arasındadır. Bu tür parazitler, hedef nesnelerin RD haritasındaki ayırt edilebilirliğini azaltarak derin öğrenme modellerinin performansını olumsuz etkileyebilir

Sıklıkla kullanılan gürültü giderme filtreleri arasında: Medyan filtre, Gauss filtresi (bulanıklaştırarak düşük frekanslı gürültüleri bastırır), Ortalama filtre (komşuluk ortalamasına göre yumuşatma yapar) yer alır.

Bu çalışmada, RD gürültüsünün giderilmesi ve görüntü kalitesinin artırılması amacıyla, iki farklı gürültü bastırma tekniği uygulanmıştır.

- ❖ Medyan filtre: Ani değer sapmalarını ve yalıtılmış parazit noktalarını ortadan kaldırmada etkilidir. Kenar koruma özelliği sayesinde hedef bölgelerin yapısını bozmadan sadeleştirme sağlar.
- ❖ Wavelet tabanlı gürültü bastırma: Görüntüyü çoklu frekans bileşenlerine ayırarak, yüksek frekanslı (gürültü taşıyan) bileşenleri baskılayıp düşük frekanslı (anlamı taşıyan) bileşenleri korur. Bu yöntem, özellikle leke/parazit (speckle) gürültüsü gibi radar verisine özgü parazitlerin bastırılmasında başarılıdır.


Medyan filtre, özellikle ani parlaklık değişimleri ve dağınık nokta gürültüsü (örneğin radar sistemlerinde karşılaşılan yalıtılmış parazit noktaları) üzerinde oldukça etkilidir. Ayrıca kenar bilgilerini koruyarak, hedef tespitine yönelik sınıflandırma algoritmalarına

daha sağlıklı giriş verisi sağlar.

Wavelet tabanlı gürültü bastırma ise, RD haritalarındaki çok ölçekli yapıları koruyarak yapısal detayların kaybını en aza indirir ve leke/parazit desenleri (speckle) gibi radar verisine özgü karmaşık gürültülerin etkili bir şekilde bastırılmasını mümkün kılar.

2.6.1. Wavelet Tabanlı Gürültü Bastırma

Wavelet tabanlı gürültü azaltma yöntemi, sinyal veya görüntü içerisindeki istenmeyen gürültü bileşenlerini azaltmak amacıyla sıklıkla kullanılan etkili bir tekniktir. Bu yöntem, sinyalin farklı frekans bileşenlerine ayrılmasını sağlayan wavelet dönüşümünün sunduğu çok çözünürlüklü analiz imkânından yararlanır. Gürültü genellikle yüksek frekans bileşenlerinde yoğunlaştığı için, sinyalin hem düşük hem de yüksek frekans bilgilerini ayrı ayrı değerlendirmek, gürültünün belirlenmesi ve bastırılması amaçlanır. Şekil 2.15’de konuya dair örnek bir görsel sunulmuştur.



Şekil 2.15. RDRD Veri Seti Üzerinde Dron Sınıfı Örneği İçin Wavelet Tabanlı Gürültü Azaltma Yöntemi

Bu yöntemin ilk adımında, işaret veya görüntü Ayırık Wavelet Dönüşümü (DWT) kullanılarak çoklu bileşenlere ayrılır. Bu dönüşüm sonucunda elde edilen katsayılar, düşük frekanslı yaklaşık (approximation) ve yüksek frekanslı detay (detail) bileşenlerden oluşur.

Asıl sinyal içeriği genellikle yaklaşık katsayılarda yoğunlaşırken, gürültü büyük oranda detay katsayılarında yer alır. Bu nedenle, gürültü bastırma işlemi detay katsayıları üzerinde gerçekleşir.

Gürültünün azaltılması amacıyla, detay katsayılarına eşikleme işlemi uygulanır. Eşikleme, belirli bir eşik değeri altında kalan katsayıların sıfırlanması ya da küçültülmesi prensibine dayanır. Bu işlem sırasında genellikle sert eşikleme (hard thresholding) ya da yumuşak eşikleme (soft thresholding) kullanılır. Sert eşikleme yaklaşımında, eşik değerinin altında kalan tüm katsayılar sıfırlanırken, yumuşak eşikleme yaklaşımında eşik altı katsayılar sıfırlamakta, eşik üzerindeki değerler ise eşik değeri kadar küçülmektedir. Eşik değeri, genellikle sinyale gömülü olan gürültünün istatistiksel özelliklerine göre belirlenir ve bu noktada VisuShrink, BayesShrink gibi adaptif eşikleme yöntemleri sıklıkla kullanılmaktadır.

Eşikleme işlemi tamamlandıktan sonra, elde edilen katsayılar yardımıyla Ters Ayırık Wavelet Dönüşümü (Inverse DWT) uygulanarak sinyalin gürültüden arındırılmış hali yeniden oluşturur. Bu işlem sırasında, yalnızca sinyalin anlamlı bileşenlerinin korunması hedeflenir ve böylece hem yapısal bütünlük korunur hem de gürültü önemli ölçüde bastırılmış olur.

Bu bağlamda, Daubechies dalgacıkları, yüksek düzeyde sıkıştırma ve ayırıştırma yetenekleri ile özellikle sinyal ve görüntü işleme alanında yaygın olarak tercih edilmektedir. Daubechies ailesi, adını Ingrid Daubechies'ten alır ve ortonormal tabanlar oluşturan kompakt destekli wavelet fonksiyonları içerir. Bu ailedeki her wavelet, belirli bir Sıfır Moment Sayısı (NNN) değeriyle tanımlanır.

Kodda kullanılan db4, Daubechies ailesinin 4 sıfır momentli ($N=4$) versiyonudur. Bu wavelet, hem düşük frekans bileşenlerini hem de hızlı geçişleri temsil edebilme özelliğine sahip olduğundan, gürültü bastırma uygulamaları için ideal bir tercihtir. db4 wavelet'i, özellikle kenar bilgilerini korurken yüksek frekanslı gürültü bileşenlerinin baskılanmasında etkilidir.

I. Wavelet Dönüşümü;

$$A_j(k) = n \sum f(n) \cdot \phi_j, k(n), D_j(k) = n \sum f(n) \cdot \psi_j, k(n) \quad (2.22)$$

Burada:

$\phi_j, k(n)$: Ölçeklenmiş ve ötelenmiş ölçek fonksiyonu olarak tanımlanır (scaling function).

$\psi_j, k(n)$: Ölçeklenmiş ve ötelenmiş wavelet fonksiyonudur.

j : Ölçek, k : Zaman yer bilgisi.

II. Eşikleme (Thresholding);

a. Sert Eşikleme (Hard Thresholding) :

$$\hat{D}_j(k) = \begin{cases} D_j(k), & \text{eğer } |D_j(k)| \geq T \\ 0, & \text{aksi halde} \end{cases} \quad (2.23)$$

b. Yumuşak Eşikleme (Soft Thresholding) :

$$\hat{D}_j(k) = \begin{cases} \text{sgn}(D_j(k)) \cdot (|D_j(k)| - T), & \text{eğer } |D_j(k)| \geq T \\ 0, & \text{aksi halde} \end{cases} \quad (2.24)$$

Bu formüllerde:

T: Eşik değeri,

sgn(x): işaret fonksiyonu

III. Ters Wavelet Dönüşümü (Rekonstrüksiyon)

Eşitlenmiş katsayılarla sinyalin yeniden inşası, Ters Wavelet Dönüşümü (IDWT) ile yapılır.

$$\hat{f}(t) = \sum_{j,k} \hat{A}_j(k) \cdot \phi_{j,k}(t) + \sum_{j,k} \hat{D}_j(k) \cdot \psi_{j,k}(t) \quad (2.25)$$

Burada $\hat{A}_j(k)$ genellikle değiştirilmeden kullanılır, ise $\hat{D}_j(k)$ eşiklenmiş detay katsayılarıdır.

Eşik değeri seçimi örneği için, VisuShrink yönteminde kullanılan tipik eşik değeri aşağıdaki formüldeki gibi tanımlanabilir:

$$T = \sigma \sqrt{2 \log N} \quad (2.26)$$

Bu formülde:

σ : Gürültünün standart sapması

N : Sinyalin örnek sayısıdır.

2.6.2. Görüntü Ön İşleme Yöntemleri

Bu bölümde, çalışma kapsamı boyunca gerçekleştirilen görüntü ön işleme yöntemleri tanıtılacaktır. Bölüm 3.1'ta kullanımları bahsedileceği üzere, Wavelet gürültü bastırma işleminden sonra min - max normalizasyonu ve medyan filtreleme yöntemleri kullanılmıştır. Ayrıca ViT modeli özelinde ara değerlendirme yöntemi de kullanılmıştır. Bu yöntemlerden kısaca bahsetmek gerekirse:

- I. Min – Max Normalizasyonu: Radar sistemlerinden elde edilen menzil-Doppler (RD) görüntüleri, ham haliyle oldukça geniş ve değişken bir değer aralığına

sahip olabilir. Bu değerler, radar sinyallerinin yansıma şiddetlerini temsil ettiğinden dolayı hedefin tipi, mesafesi, ortam gürültüsü gibi birçok faktöre bağlı olarak büyük değişiklikler gösterebilir. Ancak bu farklılıklar, özellikle makine öğrenimi ve derin öğrenme modellerinin eğitimi sırasında, modelin veriyi anlamasında ölçek kaynaklı sapmalara yol açabilir. Bu nedenle, RD haritalarındaki tüm piksellerin değerlerinin ortak bir ölçeğe indirgenmesi (genellikle $[0, 1]$ veya $[-1, 1]$) oldukça kritik bir ön işleme adımıdır. Bu çalışmada, verilerin belirli bir aralığa yeniden ölçeklendirilmesi amacıyla Min-Max normalizasyonu yöntemi kullanılmıştır. Bu yöntem, özellikle makine öğrenmesi ve istatistiksel modelleme uygulamalarında, değişkenler arasındaki ölçek farklılıklarının modelin öğrenme sürecini olumsuz etkilemesini önlemek amacıyla yaygın şekilde tercih edilmektedir.


- II. Medyan Filtreleme: Radar verilerinde, özellikle RD haritalarında karşılaşılan ani değer sapmaları, izole parazit noktaları ve darbe gürültüleri türü gürültüler, hedef tespiti ve sınıflandırma aşamalarında önemli sorunlara yol açmaktadır. Bu tür ani sıçramalı gürültülerin etkili bir şekilde bastırılabilmesi için doğrusal olmayan bir filtreleme yöntemi olan medyan filtreleme, sıkça tercih edilmektedir. Medyan filtre, her bir pikselin veya sinyal örneğinin değerini, çevresindeki komşuluk penceresinde yer alan değerlerin medyanı (ortanca değeri) ile değiştirerek çalışır. Bu yöntem, uç değerlerin neden olduğu bozulmaları azaltırken, sinyalin ya da görüntünün yapısal bütünlüğünü ve özellikle kenar bilgilerini koruma konusunda başarılıdır. Bu yönüyle, doğrusal filtrelerde sıkça görülen bulanıklık ve detay kaybı, medyan filtrelemede minimum düzeyde kalır.
- III. Ara Değerleme: Makine öğrenimi ve özellikle derin öğrenme modelleri, sabit boyutlarda giriş görsellerine (verilere) ihtiyaç duyar. Bu nedenle, farklı çözünürlüklerdeki görüntülerin modele uyumlu hale getirilmesi için yeniden boyutlandırma işlemi zorunlu bir ön işleme adımıdır. Rastgele kırpma veya

doğrudan ölçekleme gibi basit yöntemler, görüntüdeki uzamsal tutarlılığı bozabileceğinden, daha doğru ve sürekli değerler üretebilen bir yeniden örnekleme (resampling) yöntemi tercih edilmelidir. Bu bağlamda, çift doğrusal (bilinear) ara değerlendirme yöntemi; her çıktı pikselinin, giriş görüntüsündeki dört en yakın komşusunun konumlarına bağlı ağırlıklı ortalamasını alarak daha yumuşak geçişler ve görsel tutarlılık sağlar. Bu sayede modelin, yeniden boyutlandırılmış görüntülerden daha sağlıklı özellikler öğrenmesi mümkün olur. Bu özellikleri göz önünde bulundurularak çalışma süresince çift doğrusal ara değerlendirme yönteminin kullanılması tercih edilmiştir. Çalışma boyunca kullanılan Görsel Dönüştürücü (ViT) mimarisi özelinde, giriş olarak genellikle sabit boyutlu ve eşit bölgelere ayrılabilen (örneğin 224×224 piksellik) kare görüntüler beklemektedir. Ancak radar verileri olan RD haritaları, farklı çözünürlüklerde ve orantılarda olabilir. Bu nedenle:

- ❖ Modelin beklediği sabit formata uygunluk sağlamak,
- ❖ Tüm görüntüleri eş boyuta getirmek (standardizasyon),
- ❖ Ve bu sırada veri kaybı olmadan detayları korumak için, bilinear interpolasyon ile yeniden boyutlandırma uygulanmıştır.

3. KULLANILAN METOTLAR

Bu kısımda, RD haritalarının sınıflandırılmasına yönelik olarak kullanılan yöntemler ve mimariler ayrıntılı biçimde ele alınacaktır. İlk olarak, sınıflandırma sürecinde kullanılan radar verilerinin yapısal özellikleri doğrultusunda uygulanan ön işleme (pre-processing) adımları açıklanacaktır. Şekil 3.1’de çalışma boyunca gerçekleştirilecek olan veri ön işleme adımları gösterilmiştir.




Şekil 3.1. Veri Ön işleme Adımları

Çalışma kapsamında sınıflandırma amacıyla hem geleneksel makine öğrenmesi yöntemleri hem de derin öğrenme mimarileri kullanılmıştır. Makine öğrenmesi yöntemleri arasında, literatürde yüksek başarı oranlarına sahip olan Aşırı Gelişmiş Gradyan Artırmalı Öğrenme ve Rastgele Orman algoritmaları tercih edilmiştir. Bu yöntemlerin sınıflandırma sürecindeki mimari yapılandırmaları ve hiper parametre seçimleri ilgili alt başlıklarda açıklanmıştır.

Derin öğrenme yaklaşımları kapsamında ise özelleştirilmiş 2D-CNN ve ViT mimarileri kullanılmıştır. Bu mimariler, RD haritalarının uzamsal desenlerini öğrenmeye yönelik olarak katmanlı bir yapıda kurgulanmış; bu çalışmada kullanılan özelleştirilmiş İki Boyutlu Evrişimli Sinir Ağı (2D-CNN) mimarisi, RD (Range–Doppler) haritalarındaki uzamsal desenleri öğrenmeye yönelik olarak katmanlı bir yapı şeklinde tasarlanmıştır. Özelleştirilmiş 2D-CNN model mimarisi; sırasıyla konvolüsyon (evrişim), aktivasyon işlevleri, toplu normalizasyon (batch normalization) ve havuzlama (pooling) katmanlarından oluşmaktadır. Ayrıca, modelin katman sayısı, filtre boyutları ve eğitim parametreleri ilerleyen bölümlerde ayrıntılı olarak sunulacaktır. Çalışmada ayrıca, son yıllarda görsel sınıflandırma alanında öne çıkan Görsel Dönüştürücü (ViT) mimarisi de uygulanmıştır. İlerleyen bölümlerde, ViT tabanlı modelin katman yapısı, girdi ön işleme adımları, dönüştürücü (transformer) bileşenleri (multi-head attention, positional encoding vb.) ve eğitim süreci ayrıntılı olarak açıklanmıştır.

Tez kapsamında kullanılan veri seti, literatür çalışmalarında ve tez süreci boyunca kullanılmak üzere halka açık olarak yayınlanmış olan RDRD (Real radar-based Drones, people, and cars Dataset) veri setidir [17]. RDRD veri seti, RAD-DAR sistemi tarafından üretilip, 17.485 veriden oluşmaktadır. RAD–DAR sistemi, merkez frekansı 8.75 GHz olan ve maksimum 500 MHz bant genişliğine sahip bir FMCW sinyali kullanmaktadır. Radar sistemine ait genel blok diyagramı Şekil 3.2'de sunulmuştur. Sistem, mikroşerit teknolojisi kullanılarak tasarlanmış anten alt bileşenlerine sahiptir. Bu yapı sayesinde, yükselme düzleminde 10 derecelik, azimut düzleminde ise 90 derecelik yarım güç hüzmeye genişliği elde edilmektedir. Sistem, bir adet verici anten ile her biri sekiz elemanlı anten dizisine sahip

sekiz alıcı antenden oluşmaktadır.



Şekil 3.2. RAD-DAR Sistemi

RAD-DAR Sistemi üzerinde gerçekleştirilen sinyal işleme adımlarından sonra elde edilen görüntü matrisleri her sahne (belli bir anda alınan tüm radar yansımalarının matrisi) için 4092x512'dir.

Veri setinin elde edildiği test ortamı Şekil 3.3'de gösterilmiştir.



Şekil 3.3. RDRD veri setindeki kullanılan radar sisteminin görüntüsü

Sınıflandırma algoritmalarının başarısı, büyük ölçüde kullanılan verinin çeşitliliği ve güvenilirliği ile doğrudan ilişkilidir. Bu kapsamda, insan, araç ve dron hedeflerine ait gerçek radar verilerinden oluşan etiketli bir veri tabanı oluşturmak amacıyla, kontrollü saha testleri gerçekleştirilmiş ve RDRD veri seti hazırlanmıştır.

RDRD veri seti, Kaggle platformunda CC BY 4.0 lisansı ile kamuya açık olarak sunulmaktadır. Bu sayede araştırmacılar, veri setini özgürce kullanabilmekte, üzerinde değişiklik yapabilmekte ve kendi algoritmalarını gerçek radar verileri üzerinde test edebilmektedir. Veri seti, her biri 11×61 boyutlarında olup radar yansıma gücünü (dBm cinsinden) temsil eden binlerce CSV dosyasından oluşmaktadır. Örnekler; “Araç”, “Dron” ve “İnsan” olmak üzere üç ana sınıfa ayrılmış, her sınıf kendi klasöründe toplanmış ve zamanla ilişkili örnekler alt klasörlerde organize edilmiştir. Literatürde bilindiği kadarıyla, gerçek bir çevrede kaydedilmiş ilk halka açık ve kalıcı RD radar veri tabanı olma özelliğine sahiptir. Veri seti, İspanya'nın Avila bölgesinde yer alan Riocabado köyündeki açık görüş alanına sahip bir çiftlikte kaydedilmiştir. Kayıtların gerçekleştirildiği alan, yaklaşık 5 kilometreye kadar engelsiz görüş hattı sunmaktadır.

Veri çeşitliliğini sağlamak amacıyla; kara hedefleri (insan ve araç) farklı uzaklık ve hızlarda, çeşitli yönelimlerde hareket ettirilmiş, uygun güzergâhlar dijital yükseklik modeli yardımıyla belirlenmiştir. Sadece belirli yolları (rotaları) izleyebilmişlerdir ve algılanabilmeleri için doğrudan görüş hattı (Line of Sight – LoS) gerekmiştir. Bu nedenle, sayısal arazi modeli kullanılarak Şekil 3.4'teki görüş haritası çıkarılmış ve Şekil 3.5'te gösterilen en uygun rotalar belirlenmiştir. Bu doğrultuda, hedeflerin farklı yönelimlerle tespit edilmesini sağlayan iki ana güzergâh kullanılmıştır:

- Rota A: 2,57 km uzunluğunda olup, hedefler başlangıçta radar doğrultusuna dik, sonrasında ise radyal yönde hareket etmektedir.
- Rota B: 1,56 km uzunluğunda ve eğimli bir yapıya sahiptir, bu da farklı yönelimlerin yakalanmasına katkı sağlamaktadır.



Şekil 3.4. Radar LOS (Görünürlük) Haritası



Şekil 3.5. RDRD Veri Setinin Elde Edildiği Rotalar (Dron için uçuş, İnsan ve Araç için seyahat rotaları)

Tablo 3.1. RDRD Veri Seti İçeriği ve Sınıf Dağılımları

Hedef Türü	Örnek Sayısı	Yüzdelik Dağılım (%)
İnsan	6700	38,32
Araç	5720	32,71
Dron	5065	28,97
Toplam	17485	100

3.1. Kullanılan Veri Ön İşleme Adımları

Kullanılan RDRD veri seti içerisindeki ham görüntüler aşağıda bahsedilen görüntü işleme adımlarından geçirilecektir.

3.1.1. Wavelet Tabanlı Gürültü Bastırma

Tez çalışma süresi boyunca RD haritalarında yüksek frekanslı gürültülerin etkili şekilde bastırılması ve kenar bilgilerinin korunması amacıyla, bu çalışmada wavelet tabanlı gürültü azaltma yöntemi olarak skimage.restoration kütüphanesinden denoise_wavelet fonksiyonu tercih edilmiştir. Bu fonksiyon içeriye aktarıldıktan (yazılıma import edildikten sonra), kodda kullanılan db4 parametresi, Daubechies ailesinin 4 sıfır momentli (N=4) versiyonudur. Bu wavelet, hem görüntüdeki genel yapıyı hem de ani değişimleri (kenarlar gibi) iyi temsil eder. Aynı zamanda mod yumuşak (soft) kullanılmıştır. Bu yöntem, gürültüyü azaltırken görüntüdeki geçişleri daha düzgün hale getirir. Sert eşikleme, eşik değerinin altındaki detay katsayılarını sıfırlarken, üzerindeki olduğu gibi bırakır. Bununla

beraber ayrışım seviyesi, seviye 1 (level 1) olarak belirlenmiştir. Ayrışım seviyesi (level), sinyalin ne kadar derine analiz edildiğini gösterir. Seviye 1 (Level 1) ayrışım kullanmak, sinyalin yalnızca bir kez en temel düşük frekanslı (yaklaşım) ve yüksek frekanslı (detay) bileşenlerine ayrıldığı anlamına gelir. En son olarak ‘Ölçeklenmiş Gürültü Standart Sapması’’ (rescale_sigma) doğru (true) olarak ayarlanmıştır. Bu ayar, eşik değerinin belirlenmesinde kullanılan gürültü standart sapması (σ) değerinin, wavelet katsayılarının farklı seviyelerdeki ölçeklenmelerine göre otomatik olarak ayarlanmasını sağlar. Bu wavelet, hem düşük frekans bileşenlerini hem de hızlı geçişleri temsil edebilme özelliğine sahip olduğundan, gürültü bastırma uygulamaları için ideal bir tercihtir. Sonuç olarak Db4 wavelet’i, özellikle kenar bilgilerini korurken yüksek frekanslı gürültü bileşenlerinin baskılanmasında etkilidir.

3.1.2. Ara Değerleme (Interpolation)

Modelin giriş verisi olarak kullanılan görüntülerin boyutlarını standart hale getirmek amacıyla, yeniden boyutlandırma işlemi gerçekleştirilmiştir. Bu işlem, PyTorch kütüphanesinde yer alan F.interpolate fonksiyonu aracılığıyla uygulanmıştır. Daha sonrasında, çift doğrusal (bilinear) enterpolasyon yöntemi kullanılarak 224x224 piksel boyutlarına ölçeklendirilmiştir. Bu boyutlandırma işlemi sırasında, enterpolasyonun daha tutarlı sonuçlar vermesini sağlamak adına align_corners=False parametresi kullanılmıştır. Çift doğrusal enterpolasyon, her bir pikselin değerini, çevresindeki dört pikselin ağırlıklı ortalamasını alarak hesapladığından, görüntüdeki geçişlerin daha yumuşak olmasına katkı sağlamaktadır. Bu şekilde, tüm görüntülerin sabit bir giriş boyutuna getirilmesi, modelin eğitimi sırasında tutarlı bir öğrenme süreci elde edilmesine olanak tanımaktadır.

NOT: Bu Ön işleme adımı sadece Görsel Dönüştürücü (VİT) modeli için kullanılmıştır.

3.1.3. Medyan Filtreleme (Median Filtering)

Bölüm 2.6.4.’de bahsedilen min-max normalizasyon formülü uygulandıktan sonra,


scipy.ndimage kütüphanesinden median_filter fonksiyonu aracılığıyla medyan filtreleme yapılarak veri aykırı değerlerden temizlenmektedir. Bu süreçte 3x3 medyan filtreleme kullanılmıştır. 3x3 filtrelemede her komu pikseli ele alırken, onunla çevresindeki sekiz komşu pikseli de değerlendirme sürecine dahil eder. Yani, her adımda toplamda dokuz adet piksel değeri üzerinden işlem yapılmıştır. Bu sayede görüntüdeki gürültüler etkili şekilde bastırılırken, hedef nesnelerin yapısal bütünlüğü korunmuştur. Dolayısıyla, modelin eğitim performansı önemli ölçüde artmaktadır

3.1.4. Min – Max Normalizasyonu

Bu bölümün önceki başlıklarında bahsedildiği gibi Wavelet dönüşümü, görüntüyü (veriyi) ayrıntılı şekilde analiz ederek gürültüyü derinlemesine temizler ve gerçek sinyali daha net ortaya çıkarır. Bu işlemin, özellikle radar görüntüleri gibi düşük sinyal-gürültü oranına sahip verilerde önemli bir avantaj sunduğu açıklanmıştır.

Bu dönüşüm görüntüye (veriyi) uygulanmadan önce, min-max normalizasyonu gerçekleştirilmiştir. Görüntü üzerine (veriyi) uygulanan min-max normalizasyonun, Bölüm 2.6.4'te bahsedilen ham formülü kullanılmıştır. Min-Max normalizasyonu ile veriler 0 ile 1 arasına ölçeklendirilmiş, böylece farklı özelliklerin sahip olabileceği ölçek farklarından kaynaklanabilecek karşılaştırma sorunları önlenmiş ve veri kümesi standardize edilmiştir. Bu ön işleme adımları hem wavelet dönüşümünün etkinliğini artırmakta hem de sonrasında uygulanan sınıflandırma modellerinin daha istikrarlı ve güvenilir sonuçlar üretmesine olanak sağlamaktadır.

Şekil 3.6'da veri setinden farklı sınıflar özelinde alınmış görüntülere ait örneklemeler yapılmıştır. Bahsedilen örneklerde yukarıda bahsedilen görüntü işleme adımlarından herhangi biri kullanılmamıştır.




Şekil 3.6. Görüntü İşleme Öncesi Elde Edilen Örnek RD Haritaları:

Sol Üst Görsel: Araç Sınıfı Görseli, Sağ Üst Görsel: Dron Sınıfı Görseli, Alt Görsel: İnsan Sınıfı Görseli

Şekil 3.7’de veri setinden alınmış ve bahsedilen görüntü işleme adımlarından geçirilmiş dron sınıfına ait bir görüntü örnek gösterilmiştir. Bu örnekte sırasıyla, Wavelet tabanlı gürültü bastırma, medyan filtreleme ve en son min-max normalizasyonu görüntü işleme adımları kullanılmıştır. Bu işlemler sonucunda geliştirilen modellerin test verisi üzerindeki doğruluklarının %0.15-0.45 aralığında arttığı gözlemlenmiştir.

Görüntü İşlemesi Yapılmış Örnek (Wavelet + Median + Min-Max) #8539 - Sınıf: Dron



Şekil 3.7. Görüntü İşleme Sonrası Dron Sınıfı Örnek RD Haritası

3.2. Kullanılan Makine Öğrenmesi Yöntemleri

3.2.1. Eğitim Süreçleri

Veri seti, %80 eğitim (train) ve %20 test (test) oranında eğitim test verilerini ayırma (train_test_split) yöntemi kullanılarak ayrılmıştır. Bu ayırma oranı, veri setinin büyüklüğü göz önünde bulundurularak modelin öğrenme kapasitesi ile değerlendirme güvenilirliği arasında denge kurulması amacıyla tercih edilmiştir. Bu ayırma oranının (%80-%20) oranı tercih edilmesinde, hem literatürde sık kullanılan bir uygulama olması hem de eğitim verisinin büyük kısmını kapsayarak modelin daha iyi öğrenmesini sağlaması öne çıkan nedenler olmuştur. Joseph ve arkadaşları (2022), veri setinin eğitim ve test alt kümelerine bölünmesine ilişkin oranların belirlenmesinde literatürde önerilen farklı yaklaşımları derinlemesine incelemişlerdir. Yapılan çalışmada, %80-%20 gibi sık kullanılan oranların,

Pareto prensibine dayanan pratik bir yaklaşım olarak benimsendiği vurgulanmıştır [20].

Bu ayırma işlemi sonrasında, sınıflar eşit olarak dağılmamıştır. Araç sınıfı örneği sayısı 4576, Dron sınıfı örneği sayısı 4052 Dron, İnsan sınıfı örneği ise 5360'tır. Modelin eğitimi, NVIDIA T-4 grafik işlem birimi (GPU) kullanılarak gerçekleştirilmiştir. Bölüm 4.1'de eğitim sonuçları incelenirken, modelin performansı değerlendirilecek ayrıca test verisi üzerinde doğruluk (accuracy), F1 skoru, duyarlılık (recall) gibi metriklerin ne ifade ettiği açıklanacak ve sonuçlara bu metrikler de eklenecektir. Kullanılan her iki makine öğrenmesi modeli için belirlenen hiper parametreler, model.fit fonksiyonuna parametre olarak geçirilmiş ve modelin bu fonksiyon ile eğitim süreci başlatılmıştır.

3.2.2. Rastgele Orman Modeli İçin Belirlenen Hiperparametreler

Rastgele Orman (Random Forest) sınıflandırıcısı için en uygun hiper parametreler, Optuna kütüphanesiyle yapılan Bayesian arama sonuçları temel alınarak değerlendirilmiş, ancak nihai seçimler manuel olarak optimize edilerek belirlenmiştir. Bayesian arama, önceki denemelerde elde edilen performans ölçütlerini dikkate alarak yeni hiper parametreleri daha bilinçli şekilde seçen bir optimizasyon yöntemidir [21]. Elde edilen en iyi parametreler aşağıdaki Tablo 3.2'te belirtilmiştir.

Tablo 3.2. Rastgele Orman Modeli İçin Belirlenen Hiper Parametreler

Hiper Parametre	Açıklama	Değer
n_estimators	Ağaç Sayısı	100
max_depth	Maksimum Ağaç Derinliği	20

3.2.3. Aşırı Gradyan Artırmalı Öğrenme Modeli İçin Belirlenen Hiperparametreler

Aşırı Gradyan Artırmalı Öğrenme (XGBoost) sınıflandırıcısı için en uygun hiper parametreler, Optuna kütüphanesiyle yapılan Bayesian arama sonuçları temel alınarak değerlendirilmiş, ancak nihai seçimler manuel olarak optimize edilerek belirlenmiştir. Belirlenen en iyi hiper parametre değerleri aşağıdaki Tablo 3.3’te verilmiştir.

Tablo 3.3. Aşırı Gradyan artırmalı Öğrenme İçin Belirlenen Hiper Parametreler

Hiper Parametre	Açıklama	Değer
n_estimators	Ağaç Sayısı	100
max_depth	Maksimum Ağaç Derinliği	25
learning_rate	Öğrenme Oranı	1.0
objective	Amaç Fonksiyonu	multi:softprob
tree_method	Ağaç Oluşturma Yöntemi	gpu_hist
predictor	Tahminleyici	gpu_predictor
early_stopping_rounds	Erken Durdurma Adımı	10

3.3. Kullanılan Derin Öğrenme Yöntemleri

Kullanılan özelleştirilmiş 2D-CNN ve ViT modelleri, T4 grafik işlem birimi (GPU) üzerinde, derlenerek (compile edilerek) 1000 eğitim döngüsü (epoch) boyunca Adam optimizasyon algoritması kullanılarak eğitilmiştir. Kayıp fonksiyonu olarak birleştirilmiş (fused) yapı ile Çapraz Entropi Kaybı (Cross Entropy Loss) tercih edilmiştir. Ayrıca, aşırı öğrenmenin (overfitting) önüne geçmek amacıyla erken durdurma (Early Stopping) yöntemi uygulanmış; bekleme süresi (patience) 10 adım, minimum iyileşme eşiği (min. delta) ise 1×10^{-4} olarak ayarlanmıştır. Eğitim ve doğrulama kayıpları her eğitim döngüsünün sonunda izlenmiş ve kayıt altına alınmıştır.

Kullanılan özelleştirilmiş 2D-CNN modeli toplamda 146.435 parametreye sahiptir. Google araştırma ekibinin geliştirdiği ViT (ViT-base) modeli yaklaşık 86.6 milyon parametreye sahiptir [19]. Çalışma boyunca bu parametre sayısı değiştirilmemiştir. Yalnızca eğitim sırasında güncellenebilecek parametre sayısını azaltmak adına modelin tüm parametreleri dondurulmuş, yalnızca sınıflandırıcı (classifier) ve Katman Normalizasyonu (LayerNorm) katmanları eğitime açık bırakılmıştır. Öğrenme oranları (learning rate), 2D-CNN modeli için 1×10^{-3} , ViT modeli için ise 5×10^{-5} olarak belirlenmiştir.

3.3.1. 2 Boyutlu Evrişimli Sinir Ağı (2D-CNN)

Radar verileri (N, 1, 11, 61) boyutunda tensörlere dönüştürülmüş ve PyTorch kütüphanesi kullanılarak Tablo 3.4'te gösterilen mimari tanımlanmıştır. Model toplamda 146.435 parametreye sahiptir ve bu parametrelerin tamamı eğitilebilirdir.

Tablo 3.4. Özelleştirilmiş 2D-CNN Model Mimarisi

Katman No.	Katman Açıklaması	Çıkış Boyutu	Parametre Sayısı
0	Giriş Katmanı	$[-1,1,11,61]$ (Batch, 1 Kanal, 11x61 görüntü)	0
1	Evrişim Katmanı	$[-1,16,11,61]$ (Batch, 16 Kanal, 11x61 görüntü)	160
2	Maksimum Havuzlama Katmanı	$[-1,16,5,30]$ (Batch, 16 Kanal, 5x30 görüntü)	0
3	Evrişim Katmanı	$[-1,32,5,30]$ (Batch, 32 Kanal, 5x30 görüntü)	464
4	Maksimum Havuzlama Katmanı	$[-1,32,2,15]$ (Batch, 32 Kanal, 2x15 görüntü)	0
5	Evrişim Katmanı	$[-1,64,2,15]$ (Batch, 64 Kanal, 2x15 görüntü)	18,496

Katman No.	Katman Açıklaması	Çıkış Boyutu	Parametre Sayısı
6	Tam Bağlantı Katmanı	$[-1,64]$	122,944
7	Bırakma (Dropout) Katmanı	$[-1,64]$	0
8	Çıkış Katmanı	$[-1,3]$ (3 özellik)	195

Bu çalışmada kullanılan 2D-CNN mimarisi çalışma özelinde tasarlanmış ve toplamda 9 katmandan oluşmaktadır. Modelin girişinde, radar tarafından elde edilen 11×61 boyutunda ve tek kanallı RD görüntüsü yer almakta olup bu görüntü, ağın giriş katmanı tarafından alınır. İlk evrişim katmanı, bu girişten 16 adet 3×3 çekirdek ile özellik haritaları çıkarır ve kenar bilgisini koruyabilmek adına kenar doldurma (padding) uygulanır. Bu katmanı takip eden maksimum havuzlama katmanı, 2×2 boyutunda pencerelerle uzamsal boyutu yarıya indirerek öznitelik sayısını korurken işlem yükünü azaltır.

İkinci evrişim katmanı, önceki katmandan gelen 16 kanalı 32 kanala çıkarır ve yine 3×3 çekirdeklerle detaylı özellik çıkarımı yapar. Ardından gelen havuzlama katmanı, benzer şekilde uzamsal boyutu tekrar yarıya indirir.

Üçüncü evrişim katmanında kanal sayısı 64'e yükseltilir. Bu sayede daha soyut ve yüksek düzeyli özellikler öğrenilebilir. Bu katmanda da kenar doldurma işlemi sürdürülmektedir. Elde edilen $64 \times 2 \times 15$ boyutundaki özellik haritası, düzleştirilerek (flatten) tam bağlantılı katmana aktarılır.

Tam bağlantılı katmanda 64 adet düğüm bulunur. Bu katmandan sonra, modelin aşırı öğrenmesini önlemek amacıyla %50 oranında düğüm bırakma (dropout) uygulanmıştır. Son olarak, çıkış katmanı, sınıflandırma işlemini gerçekleştirmek üzere 3 nörondan oluşmaktadır ve her biri bir sınıfı (örneğin insan, araç, dron) temsil etmektedir.

3.3.2. Görsel Dönüştürücü (ViT)

Bu çalışmada kullanılan ViT mimarisinin temel parametreleri Tablo 3.5'te sunulmuştur.

Tablo 3.5. ViT Model Mimarisi

Özellik	Değer
Yama Boyutu	16 x 16
Giriş Boyutu	224 x 224
Gizli Katman Boyutu	768
Dönüştürücü Blok Sayısı	12
Dikkat Başlığı Sayısı	12
Çok Katmanlı Algılayıcı Ara Katmanı	3072
Toplam Parametre Sayısı	~86 M

İlk olarak, giriş olarak verilen 224×224 çözünürlüğündeki görüntü, her biri 16×16 piksel boyutunda olacak şekilde küçük parçalara (yamalara) ayrılmaktadır. Bu işlem sonucunda toplam 196 adet yama elde edilir. Her bir yama, modelin öğrenme sürecine uygun şekilde, 768 boyutlu bir vektöre dönüştürülerek temsil edilir. Dönüştürülen bu yamalar daha sonra ardışık olarak yapılandırılmış 12 adet dönüştürücü (transformer) bloğundan geçirilir. Her blok içerisinde çoklu başlıklı dikkat mekanizması (multi-head self-attention), doğrusal olmayan dönüşüm gerçekleştiren çok katmanlı algılayıcılar (MLP) ve katman normalizasyon işlemleri bulunmaktadır. Bu yapı sayesinde model, görüntüdeki hem yerel hem de küresel ilişkileri etkili bir şekilde öğrenebilmektedir. Dönüştürücü bloklardan elde edilen nihai temsiller, sınıflandırma katmanına aktarılır. Bu sınıflandırıcı, 768 boyutundaki girdi vektörünü kullanarak, belirlenen üç sınıftan birine ait olasılıkları üretmekte ve son karar vermeyi gerçekleştirmektedir.

Modern GPU'lar, genellikle 32-bit (FP32) kayan noktalı sayılarına ek olarak, 16-bit (FP16) sayılarıyla yapılan hesaplamalar çok daha hızlı gerçekleştirilebilir. Böylece, derin öğrenme modellerinin eğitimini hızlandırmak ve bellek kullanımını optimize etmek için “karışık hassasiyet” eğitimine olanak tanır. Ancak FP'16 ya geçmek bazı sorunlara sebep olabiliyor; özellikle çok küçük gradyan değerleri, FP16'da çalışmayacak kadar küçülebilir ve aşağı taşma (underflow) durumuna yol açabilir. Bunu önlemek için de Gradyan Ölçekleyici (Gradient Scaler) kullanılmıştır. Ayrıca, `model.parameters()` fonksiyonu kullanılarak tüm modelin gradyan hesaplaması devre dışı bırakılmıştır (`requires_grad=False`). Bu da modelin ağırlıklarının eğitim sürecinde güncellenmesinin önüne geçer. Daha sonra, belirli modüllerin parametreleri seçici olarak yeniden etkinleştirilmiştir.

`model.classifier.parameters()` fonksiyonu, modelin çıktı katmanını (sınıflandırma) yeni eğitime özgü öğrenmesini sağlamak için kullanılmıştır.

`model.vit.layernorm.parameters()`, genellikle çoğu modelde bulunan son

normalizasyon katmanını stabil ve daha iyi yakınsama için kullanılmıştır.

`model.vit.encoder.layer[-(i+1)].parameters()` fonksiyonu, özellikle Görsel Dönüştürücü gibi mimarilere sahip olan modellerde N transformatör bloğunu da çözerek daha kompleks ve o hedefe özgün öğrenilmesi amaçlamıştır. Modelin genel yapısını korurken aynı zamanda yeni veri setine adaptasyonunu maksimize etmeyi amaçlamıştır.

3.4. Model Eğitimi İçin Kullanılan Geliştirme Platformu ve Sağladığı Kaynaklar

Model eğitimi için seçilen yazılım geliştirme platformu Google Cloud Collaboratory'dir. Google Cloud Collaboratory seçiminde, derin sinir ağı mimarilerinin eğitimi için, yazılım geliştirme araçlarının bile hafızasının yetmediği yerlerde ek hizmetler sunabilmesinin etkisi çok büyüktür. Platformda sağlanan kaynaklar 51.0 GB RAM, Intel Xeon CPU, T-4 GPU ve A-100 GPU'dur.

3.5. Model Eğitimi İçin Kullanılan Yazılım Dili ve Kütüphaneleri

Öncelikle bu tezin araştırma sürecinde ana programlama dilinin Python olarak seçilmesinde, birçok popüler sinir ağı kütüphanelerinin (Tensorflow, Pytorch, Keras, Theano, OpenCV vb.) bu dilde yazılmasının, masaüstü yazılım geliştirme aracı olan Jupyter Notebook ve web üzerinde yazılım geliştirme aracı olan Google Cloud Collaboratory gibi çok ortamda yazılım geliştirme imkanının bulunmasının önemi büyüktür.

PyTorch kütüphanesi kullanılarak model eğitimi, yığın (batch) işlemleriyle gerçekleştirilmiştir. PyTorch'ta DataLoader sınıfı, verileri yığınlar (batch) hâlinde yüklemek için kullanılır. Böylece model, tüm veriyi belleğe almak yerine her iterasyonda sadece bir yığın kadar veri ile eğitilir. Bu işlem, eğitim verisinin GPU belleğine sığmasını sağlar ve belleği verimli kullanır.

Bölüm 3.1'de bahsedilen veri ön işleme metotlarının uygulama aşamasında, Numpy, Skimage ve Scimage kütüphanesinden gürültü bastırma ve dolgulama işlemlerinde yararlanılmıştır. Numpy kütüphanesi ise model eğitiminin ihtiyaç duyduğu girdi olacak

verilerin boyutlarının yeniden boyutlandırılmasında ve küçültülmesinde kullanılmıştır. Sinir ağı kütüphanesi olarak Pytorch kütüphanesi kullanılmıştır. Günümüzde yapay sinir ağı kütüphanesi olarak en çok tercih edilen kütüphane Pytorch kütüphanesidir. Pytorch'un hem düşük seviye hem yüksek seviyeli uygulama geliştirme arayüzü (API) vardır. Pytorch kütüphanesi Pytorch üzerinde çalışan yüksek seviye yazılım geliştirme arayüzüdür. Yüksek seviyeli uygulama geliştirme arayüzlerini daha da basit bir halde tanımlamış ve kütüphaneyi daha kullanıcı dostu bir hale getirmiştir. Bu arayüzlerin bazılarında Bölüm 3.3'te katmanların implementasyonunda yararlanılmıştır. Model eğitimi ve model sonuçlarının değerlendirilmesinde de yine Pytorch'un API'larına başvurulmuştur.

Bölüm 3'te de bahsedildiği üzere RDRD veri seti kullanılarak, belirli bir rota üzerinde seyahat eden Araç, Dron ve İnsan sınıfına ait hareket (uçuş ve seyahat) paterninden elde edilen RD görüntüleri, RDRD veritabanının 'range_doppler' isimli ve .npy uzantılı dosyalar olarak kaydedilmiştir. Her bir hedef için eğitim, validasyon ve test verileri ayrı klasörlerde tutulmuştur. Araç, Dron, İnsan'a ait RD görüntüleri eğitim, validasyon ve test verilerine göre okunup ayrı ayrı etiketlenmiştir. Radar sistemi üzerinde gerçekleştirilen sinyal işleme adımlarından sonra her sahne için 4092x512'lik bir matris elde edilmiştir; burada satırlar uzaklık hücreleri, sütunlar doppler frekansları ve değerler dBm cinsindendir. Bölüm 3.1'de veri ön işleme adımlarından sonra görüntülerin 11x61 boyutuna yeniden şekillendirdiğini göz önünde bulundurarak, seçilen makine öğrenimi ve 2D-CNN modeli için 11x61, VİT için ise 224x224 çift doğrusal (bilinear) olarak yeniden boyutlandırılmıştır.

Modelin eğitime başlamadan önce, her bir sınıfa ait .npy uzantılı eğitim verileri, numpy kütüphanesi ile np.append fonksiyonu kullanılarak birleştirilmiştir. Kullanılan derin öğrenme modelleri özelinde, ilgili RD görüntüleri PyTorch tensörlerine dönüştürülmüştür. Ardından torch.utils.data. TensorDataset sınıfı kullanılarak bir veri kümesine (dataset) çevrilmiştir. Kullanılan makine öğrenimi yöntemleri için ise, RD görüntüleri diziye (array) dönüştürülmüştür.

Eğitim ve validasyon verilerini ayırmak ve model eğitimi sürecinde kullanmak için sklearn.model_selection.train_test_split API'si kullanılmıştır.

4. SONUÇLAR

4.1. Performans Değerlendirme Metrikleri

Model performansını değerlendirmek için üç temel performans metriği kullanılmıştır:

- ❖ Kesinlik (Precision): Modelin pozitif olarak tahmin ettiği örneklerden kaç tanesinin gerçekten doğru olduğunu gösterir. Aşağıdaki formül ile hesaplanır.

$$Kesinlik = \frac{Doğru Pozitif}{Doğru Pozitif + Yanlış Pozitif} \quad (4.1)$$

- ❖ Duyarlılık (Recall): Gerçek pozitif sınıflardan kaç tanesinin model tarafından doğru tespit edildiğini gösterir. Aşağıdaki formül ile hesaplanır.

$$Duyarlılık = \frac{Doğru Pozitif}{Doğru Pozitif + Yanlış Negatif} \quad (4.2)$$

- ❖ Özgüllük (Specificity): Gerçek negatif sınıflardan kaç tanesinin model tarafından doğru tespit edildiğini gösterir. Aşağıdaki formül ile hesaplanır.

$$Özgüllük = \frac{Doğru Negatif}{Doğru Negatif + Yanlış Pozitif} \quad (4.3)$$

- ❖ F1-Skoru (F1-score): Kesinlik ve duyarlılığın harmonik ortalamasıdır; dengesiz veri setlerinde genel performansı özetlemek için kullanılır. Aşağıdaki formül ile hesaplanır.

$$F1 - Skoru = 2 \times \frac{Kesinlik \times Duyarlilik}{Kesinlik + Duyarlilik} \quad (4.4)$$


- ❖ ROC Eğrisi: Farklı eşik değerlerine göre modelin duyarlılık ve 1- özgüllük değerlerini karşılaştıran grafiksel bir gösterimdir. Modelin sınıfları ayırma yeteneğini görsel olarak değerlendirmeye yarar.
- ❖ AUC: ROC eğrisinin altında kalan alanı ifade eder. Bu değer 0 ile 1 arasında değişir. AUC değeri 1'e yaklaştıkça modelin pozitif ve negatif sınıfları doğru ayırt etme yeteneği artar.
- ❖ Destek (Support): Herhangi bir sınıfın veri setinde kaç örneğe sahip olduğunu ifade eder.

NOT: Çalışma kapsamında modeller arasında karşılaştırma metrikleri olarak kullanılan Kesinlik ve AUC benzer kavramlar gibi görünse de farklı kavramlardır. Kesinlik sadece pozitif tahminlerin doğruluğunu belirli bir eşik değeri için ölçerken, AUC modelin genel ayırt etme kapasitesini, tüm eşik değerleri boyunca ölçer. Bu nedenle yüksek bir AUC değeri, modelin sınıfları ayırma yetisinin yüksek olduğunu gösterir, ancak bu durum modelin kesinliğinin de yüksek olduğu anlamına gelmez. İki metrik, farklı senaryolarda farklı anlamlar taşır ve birlikte değerlendirilmelidir.

4.2. Kullanılan Derin Öğrenme Yöntemlerinin Sonuçları

4.2.1. Özelleştirilmiş 2D-CNN

Bu bölümde, özelleştirilmiş 2D-CNN modeli ile eğitilen modelin eğitim sonrasında verdiği deneysel sonuçlar değerlendirilecektir. Model eğitimi bölümünde oluşturulan eğitim ve validasyon verisinin eğitim süresince birbirine karşı olan tavırları Şekil 4.1'de gösterilmiştir.



Şekil 4.1. RDRD Veri Seti Üzerinde Özelleştirilmiş 2D-CNN Yöntemi Kullanılarak Eğitim ve Validasyon Kayıplarının Karşılaştırması

Yukarıdaki grafikte eğitim ve validasyon setlerinin iterasyon sayısına göre kayıp değerlerini karşılaştırmaktadır. Bu grafiklerden eğitimin 24. epokta aşırı öğrenmeye başladığı ve bu nedenle 24. epokta eğitimin durduğu söylenebilir.

Modelin her sınıf için hesaplanan kesinlik, duyarlılık ve F1-skoru değerleri ile birlikte, bu metriklerin makro ve ağırlıklı ortalamaları ve genel doğruluk değeri Tablo 4.1'de gösterilmiştir.


Tablo 4.1. RDRD Veri Seti Üzerinde Özelleştirilmiş 2D-CNN Yöntemi Kullanılarak Eğitim Sonucu Çıkan Performans Metriklerinin Tablosu

	Kesinlik	Duyarlılık	F1-Skoru	Destek
Araç	0.9617	0.8785	0.9182	1144
Dron	0.8698	0.9625	0.9138	1013
İnsan	0.9910	0.9843	0.9876	1340
Doğruluk			0.9434	3497
Makro Ortalama	0.9408	0.9418	0.9399	3497
Ağırlıklı Ortalama	0.9463	0.9434	0.9435	3497

Kesinlik özellikle tüm sınıflar özelinde yüksektir. “İnsan” sınıfı için kesinlik en yüksek değere sahiptir (%99,10).

Duyarlılık tüm sınıflar özelinde yüksektir. “İnsan” sınıfı için duyarlılık en yüksek değere sahiptir (%98,43).

Tüm sınıflar için ortalama F1-skoru 0.91-0.98 aralığında, bu da oldukça iyi bir performansa işaret eder.



Şekil 4.2. RDRD Veri Seti Üzerinde Özelleştirilmiş 2D-CNN Yöntemi Kullanılarak Eğitim Sonucu Çıkan Karışıklık Matrisi Sonuçları

Şekil 4.2’de, modelin performansını gösteren karışıklık matrisi incelendiğinde, genel doğruluk oranının oldukça yüksek olduğu görülmektedir. Üç sınıf (Araç, Dron, İnsan) üzerinden yapılan sınıflandırmada modelin, özellikle “İnsan” sınıfında son derece başarılı tahminlerde bulunduğu dikkat çekmektedir. Toplam 1340 adet “İnsan” örneğinden 1319’unu doğru şekilde tahmin edilmesi, bu sınıf için modelin isabet oranının oldukça yüksek olduğunu göstermektedir. Bu sonuç, modelin özellikle insan gibi belirgin yapısal ve uzamsal

Öte yandan, “Araç” ve “Dron” sınıfları arasında gözle görülür bir karışıklık söz konusudur. “Araç” sınıfındaki örneklerden doğru tahmin edilemeyenlerin çoğu, 131’i, yanlışlıkla “Dron” olarak sınıflandırılmış, sadece 8’i insan olarak bulunmuştur. Benzer şekilde, “Dron” sınıfında olduğu halde tespit edilemeyen 38 örneğin 34’ü “Araç” olarak tahmin edilmiştir. Bu durum, modelin bu iki sınıf arasında ayırım yapmakta çok az da olsa zorlandığını göstermektedir. Araçlar ve dronlar, özellikle belirli açılardan elde edilen veya düşük çözünürlüklü görüntülerde benzer görsel özellikler taşıyabileceğinden, bu karışıklık anlaşılabilir bir durumdur.

[2D-CNN] 10 Rastgele CFAR Görüntüsü - Doğru: 9/10


63

Şekil 4.3'te, modelin rastgele seçilmiş 10 adet Sabit Yanlış Alarm Oranı (Constant False Alarm Rate- CFAR) radar görüntüsüne uyguladığı sınıflandırma sonuçları yer almaktadır. Her bir görüntünün üst kısmında, gerçek sınıf etiketi ve modelin tahmin ettiği sınıf ile bu tahmin ettiği sınıf doğru veya yanlış olarak belirtilmiştir. Görüntü başlıklarında kullanılan renkler, modelin tahmininin doğru (yeşil) ya da yanlış (kırmızı) olduğunu göstermektedir. Yeşil başlıklar doğru sınıflamaları (correct classifications), kırmızı başlıklar ise hatalı sınıflamaları (incorrect classifications) ifade etmektedir.

Sonuç olarak model 10 resimden 9'unu doğru tahmin ederken 1 tane yanlış tahminde bulunmuştur. Böylelikle bu görsel, modelin genel anlamda başarılı ve tutarlı tahminlerde bulunduğunu göstermektedir. Görüntülerin çoğunda doğru tahmin elde edilmiş olması, modelin güçlü bir performansa sahip olduğunu ortaya koymaktadır.

4.2.2. Görsel Dönüştürücü (ViT)

Bu bölümde, Görsel Dönüştürücü modeli ile eğitilen modelin eğitim sonrasında verdiği deneysel sonuçlar değerlendirilecektir. Model eğitimi bölümünde oluşturulan eğitim ve validasyon verisinin eğitim süresince birbirine karşı olan tavırları Şekil 4.4'de gösterilmiştir.



Şekil 4.4. RDRD Veri Seti Üzerinde Görsel Dönüştürücü Yöntemi Kullanılarak Eğitim ve Validasyon Kayıplarının Karşılaştırması

Şekil 4.4’de eğitim ve validasyon setlerinin iterasyon sayısına göre hata sonuçlarını karşılaştırmaktadır. Bu grafiklerden eğitimin 35. epokta aşırı öğrenmeye başladığı ve bu nedenle 35. epokta eğitimin durduğu söylenebilir.

Modelin her sınıf için hesaplanan kesinlik, duyarlılık ve F1-skoru değerleri ile birlikte, bu metriklerin makro ve ağırlıklı ortalamaları ve genel doğruluk değeri Tablo 4.2’de gösterilmiştir.


Tablo 4.2. RDRD Veri Seti Üzerinde ViT (Görsel Dönüştürücü Yöntemi Sonucu) Çıkan Performans Metriklerinin Tablosu

	Kesinlik	Duyarlılık	F1-Skoru	Destek
Araç	0.9217	0.8846	0.9028	1144
Dron	0.8722	0.9161	0.8936	1013
İnsan	0.9880	0.9843	0.9892	1340
Doğruluk			0.9319	3497
Makro Ortalama	0.9273	0.9283	0.9275	3497
Ağırlıklı Ortalama	0.9328	0.9319	0.9321	3497

Kesinlik özellikle “İnsan” sınıfı için oldukça yüksektir (%98,80). "Araç" sınıfında kesinlik yüksek olsa da duyarlılık daha düşük (yüksek yanlış negatif var) değerdedir.

Duyarlılık “İnsan” sınıfı için oldukça yüksektir (%98,43). Bu sonuç, modelin insan sınıfına ait örnekleri tespit etme başarısının yüksek olduğunu göstermektedir.

Tüm sınıflar için ortalama F1-skoru 0.90–0.98 aralığında, bu da iyi bir performansa işaret eder.




Şekil 4.5. RDRD Veri Seti Üzerinde Görsel Dönüştürücü Yöntemi Kullanılarak Eğitim Sonucu Çıkan Karışıklık Matrisi Sonuçları

Şekil 4.5’de modelin performansını gösteren karışıklık matrisi incelendiğinde, genel doğruluk oranının oldukça yüksek olduğu görülmektedir. Üç sınıf (Araç, Dron, İnsan) üzerinden yapılan sınıflandırmada modelin, özellikle “İnsan” sınıfında son derece başarılı tahminlerde bulunduğu dikkat çekmektedir. Toplam 1340 adet “İnsan” örneğinden 1319’ninin doğru şekilde tahmin edilmesi, bu sınıf için modelin isabet oranının oldukça

yüksek olduğunu göstermektedir. Bu durum, modelin insanlar gibi daha belirgin görsel özelliklere sahip nesneleri tanıma konusunda güçlü bir performansa sahip olduğunu ortaya koymaktadır.

Genel doğruluk oranı %93,19 olan bu model de sınıflandırma görevinde iyi bir performans sergilemiştir.



Şekil 4.6. RDRD Veri Seti Üzerinde ViT Yöntemi Modelin Doğruluğunu Ölçmek İçin Rastgele Seçilmiş 10 Sabit Yanlış Alarm Oranı

Şekil 4.6’da, modelin rastgele seçilmiş 10 adet CFAR radar görüntüsüne uyguladığı sınıflandırma sonuçları yer almaktadır. Her bir görüntünün üst kısmında, gerçek sınıf etiketi ve modelin tahmin ettiği sınıf doğru veya yanlış olarak belirtilmiştir. Görüntü başlıklarında kullanılan renkler, modelin tahmininin doğru (yeşil) ya da yanlış (kırmızı) olduğunu göstermektedir. Yeşil başlıklar doğru sınıflamaları (correct classifications), kırmızı başlıklar ise hatalı sınıflamaları (incorrect classifications) ifade etmektedir.


Sonuç olarak model 10 resimden 7’sini doğru tahmin ederken 3 tane yanlış tahminde bulunmuştur. Böylelikle bu görsel, modelin genel anlamda kısmen başarılı ve tutarlı tahminlerde bulunduğunu göstermektedir. Görüntülerin çoğunda doğru tahmin elde edilmiş

olması, modelin kısmen güçlü bir performansa sahip olduğunu ortaya koymaktadır.

4.2. Geleneksel Makine Öğrenme Yöntemlerinin Sonuçları

4.2.1. Aşırı Gradyan Artırmalı Öğrenme

Bu bölümde, Aşırı Gradyan Artırmalı Öğrenme (XGB) algoritmasıyla eğitilen modelin ikili sınıflandırma performansını değerlendirmek amacıyla gerçekleştirilen deney sonuçları sunulmuştur. Modelin eğitim sürecinde, eğitim veri kümesi kullanılarak öğrenme gerçekleştirilmiş ve bu verinin bir alt kümesi doğrulama (validasyon) veri kümesi olarak ayrılmıştır. Modelin farklı sınıflandırma eşik değerlerindeki başarısını görselleştirmek ve analiz etmek için Alıcı İşletim Karakteristiği (ROC) eğrisi ve bu eğrinin altında kalan alan (AUC) metrikleri hesaplanmış ve Şekil 4.7’de sunulmuştur.



Şekil 4.7. RDRD Veri Seti Üzerinde Aşırı Gradyan Artırmalı Öğrenme Yöntemi Modelin Doğruluğunu Ölçmek İçin Çok Sınıflı Alıcı İşletim Özellik Eğrisi Grafiği

Grafikte her bir hedef sınıf (Araç, Dron, İnsan) için ayrı bir Çok Sınıflı Alıcı İşletim Karakteristiği Eğrisi (ROC) eğrisi çizilmiş ve her eğrinin altında kalan alan (AUC) değeri hesaplanmıştır. AUC değeri, modelin ilgili sınıfı diğer sınıflardan ne kadar iyi ayırt edebildiğinin özet bir ölçüsüdür. AUC değeri 1'e ne kadar yakınsa, modelin o sınıf için ayırım gücü o kadar yüksektir; 0.5 değeri ise rastgele tahmine eşdeğer performansı gösterir.

İncelenen grafikteki AUC değerleri incelendiğinde, modelin tüm sınıflar için istisnai derecede yüksek bir ayırım gücüne sahip olduğu görülmektedir:

- ❖ Araç için AUC değeri 0.98'dir.
- ❖ Dron için AUC değeri 0.98'dir.
- ❖ İnsan için AUC değeri ise 1.00'dür.

Her üç sınıf için elde edilen bu yüksek AUC değerleri, modelin veri setindeki sınıfları birbirinden başarılı bir şekilde ayırabileceğini açıkça göstermektedir. Özellikle “İnsan” sınıfı için elde edilen AUC değerinin 1.00 olması, modelin bu sınıfa ait örnekleri sıralama (sınıf puan sıralaması) bazında diğer sınıflardan hatasız bir şekilde ayırabildiğini göstermektedir. Araç ve Dron için de 0.98 gibi oldukça yüksek AUC değerleri, bu sınıflarda da modelin çok güçlü bir performans sergilediğini teyit etmektedir. ROC eğrilerinin de beklendiği gibi kesikli rastgele çizgiden belirgin bir şekilde yukarıda ve sol üst köşeye yakın seyretmesi, modelin genel sınıflandırma yeteneğinin üstün olduğunu doğrulamaktadır. Bu sonuçlar, modelin ilgili sınıflandırma görevi için yüksek güvenilirlikte tahminler üretildiğini ortaya koymaktadır.

Modelin her sınıf için hesaplanan kesinlik, duyarlılık ve F1-skoru değerleri ile birlikte, bu metriklerin makro ve ağırlıklı ortalamaları ve genel doğruluk değeri Tablo 4.3'te gösterilmiştir.


Tablo 4.3. RDRD Veri Seti Üzerinde Aşırı Gradyan Artımlı Öğrenme Yöntemi Kullanılarak Eğitim Sonucu Çıkan Performans Metriklerinin Tablosu

	Kesinlik	Duyarlılık	F1-Skoru	Destek
Araç	0.9257	0.8706	0.8973	1144
Dron	0.8699	0.9240	0.8961	1013
İnsan	0.9695	0.9731	0.9713	1340
Doğruluk			0.9254	3497
Makro Ortalama	0.9217	0.9226	0.9216	3497
Ağırlıklı Ortalama	0.9263	0.9254	0.9253	3497

Kesinlik özellikle “İnsan” sınıfı için oldukça yüksektir (%96,95). "Araç" sınıfında kesinlik yüksek olsa da duyarlılık daha düşük (yüksek yanlış negatif) bir değerdedir.

Duyarlılık “İnsan” sınıfı için oldukça yüksektir (%97,31). Bu, modelin insan sınıfına ait örnekleri tespit etme başarısının yüksek olduğunu göstermektedir.

Tüm sınıflar için ortalama F1-skoru 0.89–0.97 aralığında, bu da iyi bir performansa işaret eder.



Şekil 4.8. RDRD Veri Seti Üzerinde Aşırı Gradyan Artımlı Öğrenme Yöntemi Kullanılarak Eğitim Sonucu Çıkan Karışıklık Matrisi Sonuçları


Şekil 4.8'deki karışıklık matrisinde, satırlar gerçek sınıf etiketlerini, sütunlar ise model tarafından tahmin edilen sınıf etiketlerini temsil etmektedir. Köşegen üzerindeki değerler, modelin doğru sınıflandırma yaptığı örnek sayılarını göstermektedir. Buna göre, modelin her bir sınıf için yüksek sayıda doğru tahminde bulunduğu gözlemlenmektedir:

- ❖ Gerçekte Araç olan 996 örnek doğru bir şekilde Araç olarak tahmin edilmiştir.
- ❖ Gerçekte Dron olan 936 örnek doğru bir şekilde Dron olarak tahmin edilmiştir.
- ❖ Gerçekte İnsan olan 1304 örnek doğru bir şekilde İnsan olarak tahmin edilmiştir.

Köşegen dışındaki değerler ise modelin yaptığı hatalı sınıflandırmaları ifade etmektedir. Bu hatalar, gerçekte bir sınıfa ait olan örneklerin yanlışlıkla başka bir sınıfa atanması şeklinde ortaya çıkmıştır. Özellikle aşağıdaki yanlış sınıflandırmalar dikkat çekmektedir:

- ❖ Gerçekte Araç olan 118 örnek Dron olarak ve 30 örnek İnsan olarak tahmin edilmiştir. Bu durum, modelin Araç'ı Dron ve İnsan ile karıştırma eğilimini göstermektedir.
- ❖ Gerçekte Dron olan 66 örnek Araç olarak ve 11 örnek İnsan olarak tahmin edilmiştir.
- ❖ Gerçekte İnsan olan 14 örnek Araç olarak ve 22 örnek Dron olarak tahmin edilmiştir. Bu sınıfta yapılan yanlış sınıflandırma sayısı diğer sınıflara göre daha düşüktür.

Genel olarak değerlendirildiğinde, XGB sınıflandırma modeli ele alınan üç sınıf için de tatmin edici bir performans sergilemektedir. Yüksek sayıda doğru tahmin, modelin ayırt edici özelliklerini başarıyla öğrendiğini göstermektedir. Ancak, özellikle Araç için yapılan yanlış sınıflandırmalar, modelin bu sınıfı diğer sınıflardan ayırmada kısmen zorlandığı söylenebilir.



Şekil 4.9. RDRD Veri Seti Üzerinde Aşırı Gradyan Artımlı Öğrenme Yöntemi Modelin Doğruluğunu Ölçmek İçin Rastgele Seçilmiş 10 Sabit Yanlış Alarm Oranı


Şekil 4.9’da, XGB’nin rastgele seçilmiş 10 adet CFAR radar görüntüsü için sınıflandırma sonuçları yer almaktadır. Her bir görüntünün üst kısmında, gerçek sınıf etiketi ve modelin tahmin ettiği sınıf ile bu tahminin doğru veya yanlış olduğu belirtilmiştir. Görüntü başlıklarında kullanılan renkler, modelin tahmininin doğru (yeşil) ya da yanlış (kırmızı) olduğunu göstermektedir. Yeşil başlıklar doğru sınıflamaları (correct classifications), kırmızı başlıklar ise hatalı sınıflamaları (incorrect classifications) ifade etmektedir.

Sonuç olarak model 10 resim üzerinden hepsini doğru tahmin ederek çok güçlü bir sınıflandırma performansı göstermiştir.

4.2.2. Rastgele Orman

Bu bölümde, Rastgele Orman (Random Forest) algoritmasıyla eğitilen modelin ikili sınıflandırma görevindeki performansını değerlendirmek amacıyla elde edilen deneysel sonuçlar sunulmuştur. Modelin eğitim sürecinde, eğitim veri kümesi kullanılarak öğrenme gerçekleştirilmiş ve bu verinin bir alt kümesi doğrulama (validasyon) veri kümesi olarak

ayrılmıştır. Modelin farklı sınıflandırma eşik değerlerindeki başarısını görselleştirmek ve analiz etmek için Alıcı İşletim Karakteristiği (ROC) eğrisi ve bu eğrinin altında kalan alan (AUC) metrikleri hesaplanmış ve Şekil 4.10'da sunulmuştur.



Şekil 4.10. RDRD Veri Seti Üzerinde Rastgele Orman Yöntemi Modelin Doğruluğunu Ölçmek İçin Çok Sınıflı Alıcı İşletim Özellik Eğrisi Grafiği

Grafikte her bir hedef sınıf (Araç, Drone, İnsan) için ayrı bir Çok Sınıflı Alıcı İşletim Özellik Eğrisi (ROC) eğrisi çizilmiş ve her eğrinin altında kalan alan (AUC) değeri hesaplanmıştır. AUC değeri, modelin ilgili sınıfı diğer sınıflardan ne kadar iyi ayırt edebildiğinin özet bir ölçüsüdür. AUC değeri 1'e ne kadar yakınsa, modelin o sınıf için ayırma gücü o kadar yüksektir; 0.5 değeri ise rastgele tahmine eşdeğer performansı gösterir.

İncelenen grafikteki AUC değerleri incelendiğinde, modelin tüm sınıflar için istisnai derecede yüksek bir ayırım gücüne sahip olduğu görülmektedir:

- ❖ Araç için AUC değeri 0.97'dir.
- ❖ Drone için AUC değeri 0.98'dir.
- ❖ İnsan için AUC değeri ise 0.99'dür.

Her üç sınıf için elde edilen bu yüksek AUC değerleri, modelin veri setindeki sınıfları birbirinden başarılı bir şekilde ayırabileceğini açıkça göstermektedir. Özellikle İnsan için elde edilen mükemmel AUC değeri (0.99), modelin bu sınıfı diğer sınıflardan çok az hata yaparak (analiz edilen eşikler dahilinde) ayırt edebildiğini belirtmektedir. Araç için 0.97 ve Drone için de 0.98 gibi oldukça yüksek AUC değerleri, bu sınıflarda da modelin çok güçlü bir performans sergilediğini teyit etmektedir. ROC eğrilerinin de beklendiği gibi kesikli rastgele çizgiden belirgin bir şekilde yukarıda ve sol üst köşeye yakın seyretmesi, modelin genel sınıflandırma yeteneğinin üstün olduğunu doğrulamaktadır. Bu sonuçlar, modelin ilgili sınıflandırma görevi için yüksek güvenilirlikte tahminler üretildiğini ortaya koymaktadır.

Modelin her sınıf için hesaplanan kesinlik, duyarlılık ve F1-skoru değerleri ile birlikte, bu metriklerin makro ve ağırlıklı ortalamaları ve genel doğruluk değeri Tablo 4.4'te gösterilmiştir.

Tablo 4.4. RDRD Veri Seti Üzerinde Rastgele Orman Öğrenme Yöntemi Kullanılarak Eğitim Sonucu Çıkan Performans Metriklerinin Tablosu


	Kesinlik	Duyarlılık	F1-Skoru	Destek
Araç	0.9377	0.8287	0.8798	1144
Dron	0.8436	0.9427	0.8904	1013
İnsan	0.9564	0.9664	0.9614	1340
Doğruluk			0.9145	3497
Makro Ortalama	0.9126	0.9126	0.9106	3497
Ağırlıklı Ortalama	0.9176	0.9145	0.9142	3497

Kesinlik özellikle “İnsan” sınıfı için oldukça yüksektir (%95,64). "Araç" sınıfında kesinlik yüksek olsa da duyarlılık daha düşük (yüksek yanlış negatif var) değerdedir.

Duyarlılık “İnsan” için sınıfı için oldukça yüksektir (%96,64). Bu sonuç, modelin insan sınıfına ait örnekleri tespit etme başarısının yüksek olduğunu göstermektedir.

Tüm sınıflar için ortalama F1-skoru 0.87–0.96 aralığında, bu da iyi bir performansa

işaret eder.



Şekil 4.11. RDRD Veri Seti Üzerinde Rastgele Orman Öğrenme Yöntemi Kullanılarak Eğitim Sonucu Çıkan Karışıklık Matrisi Sonuçları


Şekil 4.11'deki karışıklık matrisinde, satırlar gerçek sınıf etiketlerini, sütunlar ise model tarafından tahmin edilen sınıf etiketlerini temsil etmektedir. Köşegen üzerindeki değerler, modelin doğru sınıflandırma yaptığı örnek sayılarını göstermektedir. Buna göre, modelin her bir sınıf için yüksek sayıda doğru tahminde bulunduğu gözlemlenmektedir:

- ❖ Gerçekte Araç olan 948 örnek doğru bir şekilde Araç olarak tahmin edilmiştir.
- ❖ Gerçekte Dron olan 955 örnek doğru bir şekilde Dron olarak tahmin edilmiştir.
- ❖ Gerçekte İnsan olan 1295 örnek doğru bir şekilde İnsan olarak tahmin edilmiştir.

Köşegen dışındaki değerler ise modelin yaptığı hatalı sınıflandırmaları ifade etmektedir. Bu hatalar, gerçekte bir sınıfa ait olan örneklerin yanlışlıkla başka bir sınıfa atanması şeklinde ortaya çıkmıştır. Özellikle aşağıdaki yanlış sınıflandırmalar dikkat çekmektedir:

- ❖ Gerçekte Araç olan 149 örnek Dron olarak ve 47 örnek İnsan olarak tahmin edilmiştir. Bu durum, modelin Araç'ı Dron ve İnsan ile karıştırma eğilimini göstermektedir.
- ❖ Gerçekte Dron olan 46 örnek Araç olarak ve 12 örnek İnsan olarak tahmin edilmiştir.
- ❖ Gerçekte İnsan olan 17 örnek Araç olarak ve 28 örnek Dron olarak tahmin edilmiştir. Bu sınıfta yapılan yanlış sınıflandırma sayısı diğer sınıflara göre daha düşüktür.

Genel olarak değerlendirildiğinde, RF sınıflandırma modeli ele alınan üç sınıf için de tatmin edici bir performans sergilemektedir. Yüksek sayıda doğru tahmin, modelin ayırt edici özelliklerini başarıyla öğrendiğini göstermektedir. Ancak, özellikle Araç için yapılan yanlış sınıflandırmalar, modelin bu sınıfı diğer sınıflardan ayırmada çok az da olsa zorlandığı söylenebilir.



Şekil 4.12. RDRD Veri Seti Üzerinde Rastgele Orman Öğrenme Yöntemi Modelin Doğruluğunu Ölçmek İçin Rastgele Seçilmiş 10 Sabit Yanlış Alarm Oranı

Bu görselde, RF'in rastgele seçilmiş 10 adet CFAR radar görüntüsüne uyguladığı sınıflandırma sonuçları yer almaktadır. Her bir görüntünün üst kısmında, gerçek sınıf etiketi ve modelin tahmin ettiği sınıf ile bu tahminin doğru veya yanlış olduğu belirtilmiştir. Görüntü başlıklarında kullanılan renkler, modelin tahmininin doğru (yeşil) ya da yanlış (kırmızı) olduğunu göstermektedir. Yeşil başlıklar doğru sınıflamaları kırmızı başlıklar ise hatalı sınıflamaları ifade etmektedir.

Sonuç olarak model 10 resim üzerinden 10'nu da doğru tahmin ederek görsellerin büyük çoğunluğunda doğru sınıflamalar yapmıştır. Bu durum, görsel modelin genel anlamda başarılı ve tutarlı tahminlerde bulunduğunu göstermektedir.

4.3. Çalışılan Derin Öğrenme ve Makine Öğrenme Yöntemlerinin Sonuçlarının Kıyaslanması

Bu bölümde, çalışma boyunca kullanılan makine öğrenimi ve derin öğrenme yöntemlerinin karşılaştırması Tablo 4.5'te verilmiştir.

Tablo 4.5. Çalışılan Derin Öğrenme ve Makine Öğrenme Yöntemlerinin Sonuçlarının Kıyaslanması

Model	Doğruluk	Kesinlik	Duyarlılık
Özelleştirilmiş 2D-CNN	0.9434	0.9408	0.9418
VIT	0.9319	0.9273	0.9283
XGB	0.9254	0.9217	0.9226
RF	0.9145	0.9126	0.9126

Özelleştirilmiş 2D-CNN modeli, tüm metriklerde en yüksek performansı göstermiştir. Özellikle doğruluk oranı (%94.34) ile veri seti üzerinde en başarılı sınıflandırmayı gerçekleştiren model olmuştur. ViT ve XGB, derin öğrenme tabanlı özelleştirilmiş 2D-CNN modelinin hemen ardından gelmekte ve oldukça güçlü alternatifler olarak öne çıkmaktadır. Ayrıca kullanılan makine öğrenmesi yöntemleri arasında en yüksek doğruluğa sahiptir. RF modeli dengeli bir performans sergilemiş, ancak XGB modeline kıyasla tüm metriklerde biraz daha düşük sonuçlar vermiştir. ViT modeli çok yüksek sayıda parameter içermesine rağmen, özelleştirilmiş 2D-CNN modeline göre daha düşük bir performans göstermiştir. Bu durum, modelin RD eğitim verisinin miktarına veya yapısına karşı daha duyarlı olabileceğini göstermektedir.

Genel olarak değerlendirildiğinde, bu çalışma kapsamında geliştirilen modeller arasında, özelleştirilmiş 2D-CNN modeli sınıflandırma görevinde en başarılı sonuçları vermiştir. Bu nedenle, uygulama bağlamında yüksek doğruluk ve güvenilirlik gerektiren senaryolarda öncelikli tercih olarak önerilmektedir. Ancak daha düşük kaynak tüketimi veya model karmaşıklığına önem verilen durumlarda geleneksel makine öğrenimi yöntemlerinden XGB modeli de güçlü bir alternatiftir.

4.4. Çalışma Kapsamında Geliştirilen Model Sonuçlarının Örnek Çalışma İle Kıyaslanması

Bu bölümde, çalışmada geliştirilen modeller (özelleştirilmiş 2D-CNN, ViT, XGB ve RF) ile birlikte literatürde yaygın olarak kullanılan bazı önceden eğitilmiş derin öğrenme mimarilerinin (DopplerNet, MobileNetV2, NasNetMobile) sınıflandırma performansları karşılaştırılmıştır [16]. Karşılaştırma; doğruluk (accuracy), kesinlik (precision), duyarlılık (recall) ve model karmaşıklığını temsil eden parametre sayısı metrikleri üzerinden gerçekleştirilmiştir. Elde edilen sonuçlar Tablo 4.6’da özetlenmiştir:

Tablo 4.6. Çalışma Kapsamında Geliştirilen Modellerin Sonuçlarının Örnek Çalışma Sonuçları İle Kıyaslanması

Model	Doğruluk	Kesinlik	Duyarlılık	Parametre Sayısı
DopplerNet	0.9948	0.9948	0.9948	3.818.755
MobileNetV2	0.9894	0.9895	0.9894	3.325.043
NasNetMobile	0.9769	0.9771	0.9769	4.272.887
Özelleştirilmiş 2D-CNN	0.9434	0.9342	0.9357	146.435
ViT	0.9319	0.9273	0.9283	86.000.000
RF	0.9145	0.9126	0.9126	Parametresiz
XGB	0.9254	0.9217	0.9226	Parametresiz

Tablo 4.6’da görüldüğü üzere, en yüksek sınıflandırma başarısına sahip olan model DopplerNet olmuştur. Bu model, %99.48 doğruluk, kesinlik ve duyarlılık değerleriyle birlikte yüksek sınıflandırma performansı ile öne çıkmaktadır. MobileNetV2 modeli de %98.94 doğruluk oranı ile oldukça başarılı sonuçlar vermiş ve mobil cihazlarda kullanım için uygun bir seçenek sunmuştur. NasNetMobile, bu iki modele göre biraz daha düşük

performans göstermiş olmasına rağmen, hâlâ yüksek doğruluk oranları sunmaktadır. Ancak ilgili modellerdeki parametre sayısının yüksek olması, hafıza ve işlem gücü kısıtlı olan gömülü sistemlerde veya uygulamalarda dezavantaj oluşturabilir.

Çalışma kapsamında geliştirilen özelleştirilmiş 2D-CNN modeli, 146.435 gibi oldukça düşük bir parametre sayısına sahip olmasına rağmen %94.34 doğruluk oranına ulaşmıştır. Bu sonuç, modelin mimari olarak oldukça sade ve düşük parametre sayısına sahip olmasına rağmen, karmaşık radar görüntülerinden anlamlı özellikler çıkarma konusunda yüksek başarı sağladığını göstermektedir. Geliştirilen model, parametre sayısı açısından karşılaştırılan derin modellerin çok çok altında olmasına rağmen, yakın doğruluk düzeylerine ulaşarak son derece verimli bir alternatif sunmaktadır. Bu yönüyle, özellikle gerçek zamanlı işlem gerektiren, hafıza ve işlem gücü kısıtlı olan gömülü sistemlerde veya mobil cihazlarda uygulanabilirliği yüksek bir çözüm olarak öne çıkmaktadır. Modelin düşük parametre sayısı; daha düşük eğitim süresi, daha az donanım gereksinimi ve enerji tasarrufu ayrıca daha hızlı özellik çıkarımı gibi önemli avantajlar sağlamaktadır. Modelin eğitimi, verinin çevrimiçi olarak sağlandığı bir ortamda A-100 GPU desteği ile gerçekleştirilmiş ve toplam eğitim süresi 85 saniye sürmüştür. Bu avantajlar düşünüldüğünde, geliştirilen özelleştirilmiş 2D-CNN modeli, hem akademik hem de endüstriyel uygulamalarda radar RD verisiyle çalışan sistemler için güçlü ve pratik bir aday haline gelmektedir.

Derin öğrenme tabanlı bir model olan ViT, karşılaştıran derin model tabanlı yöntemlerin arasında en yüksek parametre sayısına (86 milyon) sahip olmasına rağmen doğruluk oranı %93.19 düzeyinde kalmıştır. Bu sonuç ise, ViT gibi büyük modellerin yüksek performansa ulaşabilmeleri için, özellikle bu çalışma özelinde, daha büyük ve çeşitli veri setlerine ihtiyaç duyduğunu ortaya koymaktadır. Özellikle, ViT'in görüntüleri küçük yamalara ayırarak işlemesi, doğal görüntüler için avantaj sağlasa bile RD haritalarındaki ince yapısal farklılıkların daha iyi temsil edilebilmesi için daha zengin ve dengeli radar RD veri setleri ile eğitilmeleri gerektiği anlaşılmaktadır. ViT gibi yüksek parametrelili bir modelin bu çalışma kapsamında değerlendirilme nedeni de tam olarak bu sonucun irdelenme ihtiyacından kaynaklanmaktadır. Ayrıca modelin eğitimi, verinin çevrimiçi olarak

sağlandığı bir ortamda A-100 GPU desteği ile gerçekleştirilmiş ve toplam eğitim süresi 280 saniye sürmüştür.

Geleneksel makine öğrenmesi yöntemlerinden XGB ve RF, parametresiz doğaları ile model karmaşıklığının önemli olmadığı durumlarda tercih edilebilir. Ancak doğruluk oranları sırasıyla %92.54 ve %91.45 düzeyinde kalmış, derin öğrenme tabanlı modellere kıyasla daha düşük performans göstermiştir. Bununla birlikte, bu yöntemlerin karmaşık mimari yapı gerektirmemesi ve daha az hesaplama kaynağı kullanması, çok fazla kaynak kısıtı olan uygulamalarda avantaj sağlayabileceklerini göstermektedir. XGB ve RF yöntemlerinin eğitimi, verinin çevrimiçi olarak sağlandığı bir ortamda Intel Xeon CPU kullanılarak gerçekleştirilmiş ve toplam eğitim süresi 45 saniye sürmüştür.

Özellikle bu çalışma kapsamında, RD görüntüleri üzerinde XGB ve RF gibi geleneksel makine öğrenimi yöntemlerinin uygulanması, alan literatüründe nadir rastlanan bir geliştirme niteliği taşımaktadır. Bu yöntemler, RD verisi özelinde derin öğrenme modelleri kullanımına alternatif olabilir mi sorusuna yönelik ilk adım olarak değerlendirilmiştir. Ancak elde edilen sonuçlar, RD görüntülerinin detaylı yapısı nedeniyle, öğrenme kapasitesi daha yüksek olan derin öğrenme tabanlı modellerin bu tür veriler üzerinde daha başarılı performanslar sergilediğini ortaya koymaktadır.

Genel olarak değerlendirildiğinde, DopplerNet modeli, en yüksek doğruluk değerine ulaşarak sınıflandırma performansı açısından en etkili model olarak öne çıkmaktadır. Özellikle gerçek zamanlı ve kaynak kısıtlı sistemlerde, çalışma kapsamında geliştirilen özelleştirilmiş 2D-CNN modeli ise yalnızca 146.435 parametre ile kıyaslanan çalışmadaki yüksek parametrelili derin öğrenme modellerine yakın doğruluk oranları elde etmiş ve bu yönüyle dikkat çeken bir başarı sergilemiştir. Düşük parametre sayısına rağmen sağladığı yüksek doğruluk, bu modelin gerçek zamanlı işlem gerektiren, hafıza ve işlem gücü kısıtlı olan gömülü sistemler gibi sınırlı kaynaklara sahip ortamlarda pratik bir çözüm sunabileceğini göstermektedir. Geleneksel makine öğrenmesi yöntemleri olan XGB ve RF ise uygulanabilirlik açısından avantajlı olmakla birlikte, hem özel olarak tasarlanmış derin öğrenme mimarilerinin hem de ViT gibi yüksek kapasiteli modellerin gerisinde kalmıştır.

Yine de model sadeliđi ve kolay uygulanabilirliđi ile beraber çok fazla kaynak kısıtı olan uygulamalarda iyi bir alternatif olarak öne çıkmaktadır. Öte yandan, ViT modeli, sahip olduđu yaklaşık 86 milyon parametreye rağmen bu görev özelinde beklenen başarıyı gösterememiştir. ViT'in görüntüleri yamalara bölerek işleyen yapısı, doğal görüntülerde avantaj sağlasa bile düşük çözünürlüklü ve sınırlı örnek içeren RD haritalarında yeterli genelleme yapamamasına neden olmuştur. Bu durum, ViT'in başarılı olabilmesi için daha fazla çeşitlilik ve detay içeren büyük bir RD veri setine ihtiyaç duyduđunu ortaya koymaktadır.



5. TARTIŞMALAR VE GELECEKTEKİ ÇALIŞMALAR

Uygulama sürecinde, RDRD veri seti üzerinde yer alan araç, insan ve dron sınıflarına ait menzil-Doppler (RD) görüntülerinin uzamsal (spatial) özellikleri dikkate alınarak modellemeler gerçekleştirilmiştir.

Kamuya açık RDRD veri setinin, insan, araç ve dron gibi farklı hedef türlerine ait menzil-Doppler (RD) görüntülerini içerdiği ve belirli bir yol boyunca seyahat eden araç, dron ve insan sınıflarına ait ardışık görüntülerin birleştirilerek sınıflar özelinde görüntü yığınlarının oluşturulduğu önceki bölümlerde bahsedilmiştir. Bu görüntü yığınları, ilgili sınıfların video temsilleri olarak değerlendirilebilir.

Gelecek çalışmalarda, RDRD veri setinin sınıfları özelinde değerlendirilebilecek bu video temsilleri (görüntü yığınları), RD görüntülerin yalnızca uzamsal değil, aynı zamanda zamansal (temporal) boyutları da dikkate alınarak sınıflandırılmasına bir kapı açabilecektir. Bu kapsamda, RDRD veri setinin RD görüntüleri özelinde hem uzamsal hem de zamansal ilişkileri öğrenebilen daha gelişmiş mimarilerin uygulanması önerilmektedir.

Bu doğrultuda, Üç Boyutlu Evrişimli Sinir Ağları (3D-CNN) ile Evrişimli Sinir Ağı ve Uzun Kısa Süreli Bellek (CNN-LSTM) tabanlı hibrit modeller, potansiyel olarak sınıflandırma başarısını artıracabilecek aday yöntemler arasında değerlendirilebilir.

KAYNAKLAR

- [1] V. C. Chen, F. Li, S.-S. Ho, and H. Wechsler, "Micro-Doppler effect in radar: Phenomenon, model, and simulation study," *IEEE Trans. Aerosp. Electron. Syst.*, vol. 42, no. 1, pp. 2–21, Jan. 2006.
- [2] Y. Sun, T. Fei, F. Schliep and N. Pohl, "Gesture Classification with Handcrafted Micro-Doppler Features using a FMCW Radar," *2018 IEEE MTT-S International Conference on Microwaves for Intelligent Mobility (ICMIM)*, 2018, pp. 1-4, doi: 10.1109/ICMIM.2018.8443507.
- [3] Youngwook Kim and Hao Ling, "Human activity classification based on micro-Doppler signatures using a support vector machine," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 47, no. 5, May 2009.
- [4] Ann-Kathrin Seifert, Abdelhak M. Zoubir and Moeness G. Amin, "Radar-based human gait recognition in cane-assisted walks," *IEEE Radar Conference*, May 2017.
- [5] O Youngwook Kim and Brian Toomajian, "Hand gesture recognition using micro-Doppler signatures with convolutional neural network," *IEEE Access*, vol. 4, 2016
- [6] A Gang Li, Rui Zhang, Matthew Ritchie and Hugh Griffiths, "Sparsity-based dynamic hand gesture recognition using micro-Doppler signatures," *IEEE Radar Conference*, May 2017.
- [7] A. H. Özcan, S. Baykut, D. S. A. Şahinkaya and İ. K. Yalçın, "Micro-doppler effect analysis of single bird and bird flock for linear FMCW radar," *2012 20th Signal Processing and Communications Applications Conference (SIU)*, 2012, pp. 1-4, doi: 10.1109/SIU.2012.6204484

- [8] G. Fang, J. Yi, X. Wan, Y. Liu, and H. Ke, "Experimental Research of Multistatic Passive Radar with a Single Antenna for Drone Detection," *IEEE Access*, vol. 6, pp. 33542–33551, Jun. 2018
- [9] Ö. T. Alemdaroğlu, Ç. Candan, and S. Koç, "İnsan hareketlerinden mikro-doppler özelliklerin çıkarılması," in *2014 22nd Signal Processing and Communications Applications Conference*, SIU 2014 - Proceedings, 2014, pp. 726–729.
- [10] B. Vandersmissen et al., "Indoor Person Identification Using a Low-Power FMCW Radar," in *IEEE Transactions on Geoscience and Remote Sensing*, vol. 56, no. 7, pp. 3941–3952, July 2018, doi: 10.1109/TGRS.2018.2816812.
- [11] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition," *CoRR*, vol. abs/1512.03385, 2015. [Online]. Available: <https://arxiv.org/abs/1512.03385>
- [12] J. Hyun and S. Jin, "Doppler Spectrum Feature Based Target Classification for FMCW Radar Sensor," *Sensors*, vol. 20, no. 7, p. 2001, 2020.
- [13] Y. Cha, D. Kim, J. Kim, J. Lim and D. Kim, "Multi-Input Deep Learning-Based Target Classification Using FMCW Radar," *Electronics*, vol. 10, no. 10, p. 1144, 2021.
- [14] M. Samimi Fard, S. Shlezinger, T. Blumensath, and Y. C. Eldar, "Multi-Domain Human Activity Recognition Using FMCW Radar With Deep Learning," *arXiv preprint*, arXiv:2503.05629, Mar. 2025.

- [15] T. Abdulatif, F. Hoffmann, B. Kleiner, and U. Schneider, "Human and Robot Activity Recognition Using FMCW Radar With Deep Convolutional Neural Networks," *arXiv preprint*, arXiv:1711.09177, Nov. 2017.
- [16] Roldan, I., del-Blanco, C.R., Duque de Quevedo, Á., Ibañez Urzaiz, F., Gismero Menoyo, J., Asensio López, A., Berjón, D., Jaureguizar, F. and García, N. (2020), DopplerNet: a convolutional neural network for recognising targets in real scenarios using a persistent range–Doppler radar. *IET Radar Sonar Navig.*, 14: 593-600. <https://doi.org/10.1049/iet-rsn.2019.0307>
- [17] RDRD database – Kaggle'. Available at: <https://www.kaggle.com/ioldan/real-doppler-raddar-database>, accessed June 2019
- [18] Kim, Y., & Ling, H. (2009). Human activity classification based on micro-Doppler signatures using a support vector machine. *IEEE Transactions on Geoscience and Remote Sensing*, 47(5), 1328–1337. <https://doi.org/10.1109/TGRS.2009.2012849>
- [19] Alexey Dosovitskiy, Lucas Beyer, Alexander Kolesnikov, Dirk Weissenborn, Xiaohua Zhai, Thomas Unterthiner, Mostafa Dehghani, Matthias Minderer, Georg Heigold, Sylvain Gelly, Jakob Uszkoreit, Neil Houlsby: An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale. ICLR 2021
- [20] Joseph, V. Roshan. (2022). Optimal ratio for data splitting. *Statistical Analysis and Data Mining: The ASA Data Science Journal*. 15. 10.1002/sam.11583.
- [21] David Assaf, Shmuel Zamir "Optimal Sequential Search: A Bayesian Approach," *The Annals of Statistics*, *Ann. Statist.* 13(3), 1213-1221, September, 1985. <https://doi.org/10.1214/aos/1176349665>