



**DERİN ÖĞRENME ALGORİTMALARI
KULLANILARAK HABERLEŞME VE
SEYRÜSEFER SİSTEMLERİ İLE JAMMER
SİNYALLERİNİN SINIFLANDIRILMASI**

Yalçın KAPLAN

Doktora Tezi

Eskişehir 2024

**DERİN ÖĞRENME ALGORİTMALARI KULLANILARAK HABERLEŞME VE
SEYRÜSEFER SİSTEMLERİ İLE JAMMER SİNYALLERİNİN
SINIFLANDIRILMASI**

Yalçın KAPLAN

Doktora Tezi

Havacılık Elektrik ve Elektronik Anabilim Dalı

Danışman: Dr. Öğr. Üyesi Kadriye YAMAN

Eskişehir

Eskişehir Teknik Üniversitesi

Lisansüstü Eğitim Enstitüsü

Haziran 2024

Bu tez çalışması BAP Komisyonu tarafından kabul edilen 22DRP189 no.lu proje kapsamında desteklenmiştir.

JÜRİ VE ENSTİTÜ ONAYI

Yalçın KAPLAN'ın DERİN ÖĞRENME ALGORİTMALARI KULLANILARAK HABERLEŞME VE SEYRÜSEFER SİSTEMLERİ İLE JAMMER SİNYALLERİNİN SINIFLANDIRILMASI başlıklı çalışması 28/06/2024 tarihinde aşağıdaki jüri tarafından değerlendirilerek "Eskişehir Teknik Üniversitesi Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliği"nin ilgili maddeleri uyarınca, Havacılık Elektrik ve Elektronik Anabilim dalında Doktora Tezi olarak kabul edilmiştir.

Jüri Üyeleri

Unvan Adı Soyadı

İmza

Üye (Tez Danışmanı) : Dr. Öğr. Üyesi Kadriye YAMAN
Üye : Prof.Dr. Hakan OKTAL
Üye : Prof.Dr. Emre KIYAK
Üye : Doç.Dr. Hasan Serhan YAVUZ
Üye : Doç.Dr. Erol SEKE

Prof. Dr. Semra KURAMA

Lisansüstü Eğitim Enstitüsü Müdürü

28/06/2024

DANIŐMAN ONAYI

DaniŐmanlıđını yurttuđuđum Doktora ođrencisi Yalçın KAPLAN, DERİN ÖĐRENME ALGORİTMALARI KULLANILARAK HABERLEŐME VE SEYRÜSEFER SİSTEMLERİ İLE JAMMER SİNYALLERİNİN SINIFLANDIRILMASI baŐlıklı tez çalıŐmasını tamamlamıŐtır. HazırlamıŐ olduđu tez tarafımda incelenmiŐ ve ođrencinin tez savunma sınavına alınması bilimsel ve etik açıdan uygun görülmüŐtür.

Tez DaniŐmanı

Dr. Öđr. Üyesi Kadriye YAMAN

ÖZET

DERİN ÖĞRENME ALGORİTMALARI KULLANILARAK HABERLEŞME VE SEYRÜSEFER SİSTEMLERİ İLE JAMMER SİNYALLERİNİN SINIFLANDIRILMASI

Yalçın KAPLAN

Havacılık Elektrik ve Elektronik Anabilim Dalı

Eskişehir Teknik Üniversitesi, Lisansüstü Eğitim Enstitüsü, Haziran 2024

Danışman: Dr. Öğr. Üyesi Kadriye YAMAN

Günümüzde gelişen teknolojiyle birlikte sayıları her geçen gün artan ve pek çok alanda farklı amaçlarla kullanılan çok sayıda sinyal yayıcı cihaz bulunmaktadır. Bu cihazlar, faydalı olabilecekleri gibi bazen kasıtlı sinyal karıştırma ve yanıltma gibi amaçlarla da kullanılabilir ve hava taşımacılığı gibi yüksek maliyetli sektörlere zarar verebilmektedir.

Bu çalışmada belirli bir bölge içerisinde yer istasyonlarından toplanan çok sayıda RF sinyal verisinin kısa bir süre içerisinde sınıflandırılarak yayın yapan vericilerin kimliklendirilmesi için bir model geliştirilmesi hedeflenmiştir. Bu kapsamda geliştirilen sınıflandırma modeli ile insan iş yükü ve maliyetini en aza indireyecek analitik bir yaklaşım ortaya konulması hedeflenmiştir. Önerilen yaklaşımda GSM, radar, telsiz ve jammer sinyallerinin band genişliği, dalga boyu, güç ve genlik değerleri dikkate alınarak sınıflandırma işlemi üç farklı derin öğrenme mimarisi (AlexNet, ResNet, UNet) ile K-Ortalama ve K-En Yakın Komşuluk algoritmaları kullanılarak gerçekleştirilmiştir. Sınıflandırma işlemi sonrasında kullanılan ağların işlem süresi ve doğruluk oranları karşılaştırılmıştır. Geliştirilen sınıflandırma modeli, gerçek verilerden oluşturulan örneklenmiş veri kümeleri ile çalıştırıldığında, yüksek başarı oranı elde edilmiştir.

Anahtar Sözcükler: Sinyal sınıflandırma, Derin öğrenme, Makine öğrenmesi, K ortalama kümeleme, K en yakın komşuluk.

ABSTRACT

CLASSIFICATION OF COMMUNICATION AND NAVIGATION SYSTEMS AND JAMMER SIGNALS USING DEEP LEARNING ALGORITHMS

Yalçın KAPLAN

Department of Avionics

Eskişehir Technical University, Institute of Graduate Programs, June 2024

Supervisor: Asst. Prof. Dr. Kadriye YAMAN

With the developing technology, the number of signal-emitting devices used for various purposes in many fields is increasing day by day. While these devices can be beneficial, they can also be used for intentional signal jamming and deception, causing harm to high-cost sectors like aviation. Considering the critical applications where time is of the essence, it is extremely important to classify and identify a large number of signals in a short time and to distinguish interfering signals from them.

This study within a certain region aims to develop a model for the classification and identification of signal emitters by processing a large number of signal data collected from ground stations in a short period. The goal of the developed classification model is to propose an analytical approach that minimizes human workload and cost. In the proposed approach, the classification process is carried out using three different deep learning networks (AlexNet, ResNet, UNet) along with K-Means and K-Nearest Neighbors algorithms, taking into account the bandwidth, wavelength, power, and amplitude values of GSM, radar, radio, and jammer signals. The purpose of using Deep Learning and Machine Learning simultaneously in the study is to determine the architecture or algorithm that provides the best performance. After the classification process, the processing times and accuracy rates of the networks used were compared. When the developed classification model was run with sampled datasets created from real data, a high success rate was achieved in with the sampled dataset.

Keywords: Signal classification, Deep learning, Machine learning, K means, K nearest neighbors.

TEŞEKKÜR

Bu çalışmanın gerçekleştirilmesinde, değerli bilgilerini benimle paylaşan, kullandığı her kelimenin hayatıma kattığı önemini asla unutmayacağım, güler yüzünü ve samimiyetini benden esirgemeyen ve gelecekteki mesleki hayatımda da bana verdiği değerli bilgilerden faydalanacağımı düşündüğüm kıymetli ve danışman hoca statüsünü hakkıyla yerine getiren saygıdeğer danışman hocam, Dr. Öğr. Üyesi Kadriye YAMAN'a teşekkürü bir borç biliyor ve şükranlarımı sunuyorum. Yine çalışmamda konu, kaynak ve yöntem açısından bana sürekli yardımda bulunarak yol gösteren, değerli zamanını bana ayırıp tezimin olgunlaşmasına katkıda bulunan Tez İzleme Komitesi ve Savunma Üyesi değerli hocam Doç. Dr. Hasan Serhan YAVUZ'a teşekkürlerimi sunarım.

Ayrıca kıymetli zamanını benim hazırladığım çalışmaya ayırıp değerli fikir, görüş ve tecrübelerini aktararak her zaman yapıcı eleştiriler ve önerilerde bulunan, öğrendiği ve bildiği her türlü bilgiyi paylaşmaktan kaçınmayan, hayata karşı duruşu, gösterdiği olgunluk ve yaklaşımı ile hayatın her anında bana örnek olan, iş yoğunluğuna rağmen bana vakit ayıran Tez İzleme Komitesi ve Savunma Üyesi çok kıymetli hocam Prof. Dr. Hakan OKTAL'a çok teşekkür ederim. Ayrıca Savunma Jürimde yer alan değerli hocalarım Prof. Dr. Emre KIYAK ve Doç. Dr. Erol SEKE'ye çok teşekkür ederim.

Bu çalışmada kullandığım gerçek verileri bana sağlayan Savunma Sanayi Firması çalışanı değerli büyüğüm emekli Deniz Albayı Yusuf Uğur KOCABAŞ'a, analiz süresince yardımlarını esirgemeyen Elektrik Elektronik Mühendisi SG Pilot Üsteğmen Ahmet Buğrahan UĞUR'a ve Savunma Sanayi firması mühendislerine teşekkürü bir borç bilirim.

Bütün tez hazırlama sürecinde ve hayatım boyunca yanımda yer alan, gösterdikleri sabır, anlayış ve sevgiyle beni her zaman destekleyen, bugünlere ulaşmamda oldukça büyük emek ve fedakârlık göstermiş aileme de sonsuz teşekkür ederim. Bu zorlu süreçte bana gösterdikleri sabır ve tahammül yanı sıra, sonsuz sevgisi, manevi desteği ve özverisi ile çalışmamı tamamlamamda oldukça büyük emeği geçen hayata karşı duruşu ile örnek bir eş ve öğrencilerine örnek bir hoca olan değerli eşim Öğretim Üyesi Doç. Dr. Başak MANSIZ KAPLAN ve oğlum Çınar KAPLAN'a sevgilerimi sunuyor ve bu çalışmayı onlara ithaf ediyorum.

Yalçın KAPLAN

ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ

Bu tezin bana ait, özgün bir çalışma olduğunu; çalışmamın hazırlık, veri toplama, analiz ve bilgilerin sunumu olmak üzere tüm aşamalarında bilimsel etik ve kurallara uygun davrandığımı; bu çalışma kapsamında elde edilen tüm veri ve bilgiler için kaynak gösterdiğimi ve bu kaynaklara kaynakçada yer verdiğimi; bu çalışmanın Eskişehir Teknik Üniversitesi tarafından kullanılan “bilimsel intihal tespit programı”yla tarandığını ve hiçbir şekilde “intihal içermediğini” beyan ederim. Herhangi bir zamanda, çalışmamla ilgili yaptığım bu beyana aykırı bir durumun saptanması durumunda, ortaya çıkacak tüm ahlaki ve hukuki sonuçları kabul ettiğimi bildiririm.

Yalçın KAPLAN

İÇİNDEKİLER

Sayfa

BAŞLIK SAYFASI	I
JÜRİ VE ENSTİTÜ ONAYI.....	II
DANIŞMAN ONAYI.....	III
ÖZET	IV
ABSTRACT.....	V
TEŞEKKÜR	VI
ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ.....	VII
İÇİNDEKİLER	VIII
TABLolar DİZİNİ	X
ŞEKİLLER DİZİNİ	XII
SİMGELER VE KISALTMALAR DİZİNİ.....	XIV
1. GİRİŞ	1
1.1. Tez Çalışmasının Amacı ve Önemi	3
1.2. Tez Çalışmasının Yöntemi.....	4
1.3. Literatür Araştırması	5
1.4. Tez Çalışmasının Özgünlüğü	35
2. MATERYAL VE YÖNTEM.....	37
2.1. Makine Öğrenmesi.....	37
2.1.1.K-En Yakın Komşuluk algoritması.....	37
2.1.2.K-Ortalama Kümeleme algoritması.....	38
2.2. Derin Öğrenme.....	39
2.2.1.UNet mimarisi	40
2.2.2.AlexNet mimarisi.....	41
2.2.3.ResNet mimarisi	42
2.3. RF Sinyal Verileri	43
2.4. Zaman-Frekans Dönüşümleri ve Öznitelik Çıkarma	44
2.4.1.Hilbert-Huang dönüşümü	44

2.4.2.Yıldızküme diyagramı	45
2.4.3.Mutlak ortalama öznitelik çıkarımı	46
2.5. Makine Öğrenmesi ve Derin Öğrenme Mimarisinin Karşılaştırılması	46
2.6. Sınıflandırmada Kullanılan Performans Metrikleri	47
3. GELİŞTİRİLEN SİNYAL SINIFLANDIRMA MODELİ.....	50
3.1. Veri Önışleme	50
3.1.1. Hilbert-Huang dönüşümü ile veri önışleme.....	51
3.1.2. Yıldızküme diyagramı ile veri önışleme.....	53
3.2. Veri Kümeleri Oluşturma	57
3.2.1.Hilbert-Huang dönüşümü ile oluşturulan I. veri kümesi	57
3.2.2.HH dönüşümü ve YD ile oluşturulan II. veri kümesi	59
4. BULGULAR VE TARTIŞMA.....	64
4.1. Deneysel Çalışma Ortamı	64
4.2. Makine Öğrenmesi Analiz Sonuçları	64
4.3. Derin Öğrenme Mimarileri Analiz Sonuçları	67
4.3.1. UNet mimarisi analiz sonuçları	68
4.3.2. AlexNet mimarisi analiz sonuçları.....	70
4.3.3. ResNet mimarisi analiz sonuçları	73
4.4. Makine Öğrenmesi ve Derin Öğrenme Performans Sonuçları.....	75
5. SONUÇ VE ÖNERİLER.....	79
KAYNAKÇA.....	81
ÖZGEÇMİŞ	

TABLULAR DİZİNİ

Sayfa

Tablo 1.1. Literatürde yer alan sinyal sınıflandırma çalışmaları.....	24
Tablo 3.1. Veri paketinde yer alan veriler	51
Tablo 3.2. Cihaz tiplerine göre sınıflara atanan rakamlar	53
Tablo 3.3. Cihaz tiplerine göre sınıflara atanan harfler.....	56
Tablo 3.4. I. Veri kümesi için etiket bilgileri ve 600'lük veri setinde yer alan toplam örnek sayıları.....	57
Tablo 3.5. I. Veri kümesi için etiket bilgileri ve 2000'lik veri setinde yer alan toplam örnek sayıları.....	58
Tablo 3.6. I. Veri kümesi için etiket bilgileri ve 20.000'lik veri setinde yer alan toplam örnek sayıları.....	58
Tablo 3.7. I. Veri kümesi için etiket bilgileri ve 120.000'lik veri setinde yer alan toplam örnek sayıları.....	59
Tablo 3.8. II. Veri kümesi için etiket bilgileri ve 600'lük veri setinde yer alan toplam örnek sayıları.....	60
Tablo 3.9. II. Veri kümesi için etiket bilgileri ve 2000'lik veri setinde yer alan toplam örnek sayıları.....	61
Tablo 3.10. II. Veri kümesi için etiket bilgileri ve 20.000'lik veri setinde yer alan toplam örnek sayıları.....	62
Tablo 3.11. II. Veri kümesi için etiket bilgileri ve 120.000'lik veri setinde yer alan toplam örnek sayıları	63
Tablo 4.1. Çalışma Ortamı	64
Tablo 4.2. K-Ortalama Kümeleme Algoritması için sınıflandırma performansı	65
Tablo 4.3. K-Ortalama Kümeleme ile yapılan analizlerde I. Veri kümesi için sınıflandırma sonuçları.....	65
Tablo 4.4. K-Ortalama Kümeleme ile yapılan analizlerde II. Veri kümesi için sınıflandırma sonuçları.....	66
Tablo 4.5. K-En Yakın Komşuluk Algoritması için sınıflandırma performansı.....	66
Tablo 4.6. K-En Yakın Komşuluk ile yapılan analizlerde I. Veri Kümesi için sınıflandırma sonuçları.....	67

Tablo 4.7. K-En Yakın Komşuluk ile yapılan analizlerde II. Veri Kümesi için sınıflandırma sonuçları.....	67
Tablo 4.8. Unet mimarisi için sınıflandırma performansı	68
Tablo 4.9. U-Net mimarisi ile yapılan analizlerde I. Veri Kümesi için sınıflandırma sonuçları.....	69
Tablo 4.10. U-Net mimarisi ile yapılan analizlerde II. Veri Kümesi için sınıflandırma sonuçları.....	69
Tablo 4.11. AlexNet mimarisi için sınıflandırma performansı	71
Tablo 4.12. I. Veri kümesi için AlexNet mimarisi ile yapılan analizlerde sınıflandırma sonuçları.....	71
Tablo 4.13. II. Veri kümesi için AlexNet mimarisi ile yapılan analizlerde sınıflandırma sonuçları.....	72
Tablo 4.14. ResNet mimarisi için sınıflandırma performansı	73
Tablo 4.15. I. Veri Kümesi için ResNet mimarisi ile yapılan analizlerde sınıflandırma sonuçları.....	74
Tablo 4.16. II. Veri Kümesi için ResNet mimarisi ile yapılan analizlerde sınıflandırma sonuçları.....	74

ŞEKİLLER DİZİNİ

Sayfa

Şekil 1.1.	Model akış şeması.....	6
Şekil 1.2.	Çalışmanın genel akış şeması	7
Şekil 1.3.	Örnek sınıf görüntüleri.....	7
Şekil 1.4.	Örnek görüntüler (a) Yıldızküme diyagramı (b) Kontör yıldızı dönüşümü ..	8
Şekil 1.5.	Model yapısı.....	9
Şekil 1.6.	Örnek görüntüler ve modelin sonuçları	9
Şekil 1.7.	Sınıflandırma modeli	10
Şekil 1.8.	Örnek görüntü grubu.....	11
Şekil 1.9.	Yıldızküme diyagramı örnek görüntü grubu.....	12
Şekil 1.10.	Örnek görüntü grubu.....	12
Şekil 1.11.	Yıldızküme diyagramı ve Grid diyagramı ile elde edilen görüntü grupları.	13
Şekil 1.12.	Çeşitli gürültü oranlarında yıldızküme görüntüleri.....	13
Şekil 1.13.	Önerilen Model-Orijinal Model.....	14
Şekil 1.14.	Modelin örnek görüntü grupları.....	14
Şekil 1.15.	Modelin genel akış şeması	15
Şekil 1.16.	Yıldızküme diyagramı ile görüntü oluşturma evreleri.....	15
Şekil 1.17.	Sinyallerin iki farklı görüntü ile sınıflandırılması	16
Şekil 1.18.	SPWVD örnek görüntüsü, Born-Jordan örnek görüntüsü	17
Şekil 1.19.	On farklı çok darbeli radar sinyalinin TFI'leri	19
Şekil 2.1.	U-Net mimarisi	40
Şekil 2.2.	AlexNet mimarisi.....	42
Şekil 2.3.	ResNet mimarisi.....	43
Şekil 2.4.	İkili sınıflandırma için karmaşıklık matrisi.....	48
Şekil 3.1.	HH dönüşümü ile oluşturulmuş GSM Tip-1 örnek görüntüsü.....	52
Şekil 3.2.	İkili giriş sinyal gösterimi	54

Şekil 3.3.	QPSK Yıldızküme diyagramı gösterimi süreçleri	54
Şekil 3.4.	BPSK, QPSK, 4-QAM, 16-QAM ve 32-QAM modülasyonlu sinyal verileri için Yıldızküme diyagramı görüntü örnekleri	55
Şekil 3.5.	Yıldızküme diyagramı kullanılarak oluşturulan sınıfların etiketleri.....	56
Şekil 4.1.	I. Veri kümesi için UNet karmaşıklık matrisi	70
Şekil 4.2.	II. Veri kümesi için UNet karmaşıklık matrisi.....	70
Şekil 4.3.	I. Veri kümesi için AlexNet karmaşıklık matrisi	72
Şekil 4.4.	II. Veri kümesi için AlexNet karmaşıklık matrisi.....	73
Şekil 4.5.	I. Veri kümesi için ResNet karmaşıklık matrisi	75
Şekil 4.6.	II. Veri kümesi için ResNet karmaşıklık matrisi	75
Şekil 4.7.	Makine Öğrenmesi sınıflandırma doğruluk oranları.....	76
Şekil 4.8.	Derin Öğrenme Mimarileri sınıflandırma doğruluk oranları	76
Şekil 4.9.	Makine Öğrenmesi ve Derin Öğrenme mimarileri için doğruluk oranları ..	77
Şekil 4.10.	Önerilen modelin akış şeması	78

SİMGELER VE KISALTMALAR DİZİNİ

2ASK	: 2 Amplitude Shift Keying (İkili Genlik Kaydırmalı Anahtarlama)
2FSK	: 2 Frequency Shift Keying (İkili Frekans Kaydırmalı Anahtarlama)
4ASK	: 4 Amplitude Shift Keying (4'lü Genlik Kaydırmalı Anahtarlama)
4FSK	: 4 Frequency Shift Keying (4'lü Frekans Kaydırmalı Anahtarlama)
4PAM	: 4 Pulse Amplitude Modulation (4'lü Darbeli Genlik Modülasyonu)
8FSK	: 8 Frequency Shift Keying (8'li Frekans Kaydırmalı Anahtarlama)
8PSK	: 8 Phase Shift Keying (8'li Faz Kaydırmalı Anahtarlama)
16QAM	: 16 Quadrature Amplitude Modulation (16'lı Karesel Genlik Modülasyonu)
32QAM	: 32 Quadrature Amplitude Modulation (32'li Karesel Genlik Modülasyonu)
64QAM	: 64 Quadrature Amplitude Modulation (64'lü Karesel Genlik Modülasyonu)
ALRT	: Average Likelihood Ratio Test (Ortalama Olabilirlik Oranı Testi)
AlexNet	: Alex Network (Alex Ağı)
AMC	: Automatic Modulation Classification (Otomatik Modülasyon Sınıflandırma)
AMD	: Advanced Micro Devices (Gelişmiş Mikro Cihazlar)
ASE	: Accelerometer Signal Enhancement
AWGN	: Additive White Gaussian Noise (Beyaz Gauss Gürültüsü)
Bps	: Bit Per Second (Saniyedeki Bit Sayısı)
BFSK	: Binary Frequency Shift Keying (İkili Frekans Kaydırmalı Anahtarlama)
Bi-LSTM	: Bidirectional Long Short-Term Memory
BPSK	: Binary Phase Shift Keying (İkili Faz Kaydırmalı Anahtarlama)
CBS	: Coğrafi Bilgi Sistemi
CCES	: Cyclic Correntropy Spectrum (Döngüsel Korrentropi Spektrumu)

CGCs	: Grid Radar Cross Section (Grid Radar Kesiti)
CL	: Classification Layers (Sınıflandırma Katmanı)
CMWT	: Complex Morlet Wavelet Transform (Karmaşık Morlet Dalgacık Dönüşümü)
CNN	: Convolutional Neural Network (Evrışimli Sinir Ağı)
CPFSK	: Continuous-Phase Frequency Shift Keying (Sürekli Frekans Faz Kaydırma)
CWD	: Choi-Williams Distribution (Choi-Williams Dağılımı)
DAE	: Denoising Autoencoder (Gürültü Giderici Otomatik Kodlayıcı)
DBN	: Deep Belief Network (Derin İnanç Ağları)
DNN	: Deep Neural Network (Derin Sinir Ağı)
EQFM	: Even Quadratic Frequency Modulation (Çift Karesel Frekans Modülasyonu)
ESM	: Electronic Support Measurement (Elektronik Destek Ölçüm)
EVT	: Extreme Value Theory (Uç Değer Teorisi)
FMCW	: Frequency Modulated Continuous Wave (Frekans Modülasyonlu Sürekli Dalga)
FD	: Fall Detection (Düşük Çözürlüklü)
GMSK	: Gaussian Minimum Shift Keying (Gauss Minimum Kaydırmalı Anahtarlama)
GA	: Genetik Algoritmalar
GAN	: Generative Adversarial Networks (Üretken Ağ)
GB	: Gigabayt
GD	: Gradient-Descent
GDA	: Gradient-Descent-Adaptive
GDM	: Gradient-Descent-Momentum
GHz	: Gigahertz
GNA	: Gauss-Newton Algoritması
GSM	: Global System For Mobile (Mobil İletişim Küresel Sistemi)

HF	: High Frekans (Yüksek Frekans)
HH	: Hilbert Huang Dönüşümü
HR	: High Resolution (Yüksek Çözünürlük)
Hz	: Hertz
ICRN	: Industrial Cognitive Radio Networks (Endüstriyel Bilişsel Radyo Ağları)
İHA	: İnsansız Hava Aracı
JAMMER	: Sinyal Bozucu
JMRPE	: Joint Inter Pulse Automatic Modulation Recognition and Parameter Estimation
KHz	: KiloHertz
K-Means	: K-Ortalama Kümeleme
KNN	: K-Nearest Neighbors (K-En Yakın Komşuluk)
LeNet	: Evrişimli Sinir Ağları
LFM	: Linear Frequency Modulated (Doğrusal Frekans Modülasyonlu)
LM	: Levenberg-Marquardt
LR	: Low Resolution (Düşük Çözünürlüklü)
LOFM	: Linear Optical Field Modulator (Doğrusal Optik Alan Modülatörü)
LSTM	: Long Short-Term Memory (Uzun Kısa Süreli Bellek)
LTE	: Long-Term Evolution (Yüksek Hızlı Ağ Teknolojisi)
MATLAB	: Matrix Laboratory (Matrix Laboratuvarı)
MFHN	: Multi-Scale Feature Hybrid Network (Çok Boyutlu Özellik Hibrit Ağı)
MFR	: Multifunctional Radar (Çok Fonksiyonlu Radar)
MJMN	: Multi-Feature Common Transition Network (Çok Özellikli Ortak Geçiş Ağı)
MHz	: Megahertz
ML	: Maximum Likelihood (Maksimum Olabilirlik)

MLP	: Multi-Layer Perceptron (Çok Katmanlı Algılayıcılar)
MO	: Mutlak Ortalama
NOMA	: Non-Orthogonal Frequency Multiple Access (Dik Olmayan Frekans Çoklu Erişim)
OQPSK	: Offset Quadrature Phase-Shift Keying (Sapma Dörtlü Faz Kaydırmalı Anahtarlama)
OFDM	: Orthogonal Frequency Division Multiplexing
OKH	: Ortalama Karesel Hata
QAM	: Quadrature Amplitude Modulation (Dördül Genlik Modülasyonu)
QPSK	: Quadrature Phase Shift Keying (Dörtlü Faz Kaydırmalı Anahtarlama)
PAM4	: Pulse Amplitude Modulation 4-Level (Darbe Genlik Modülasyonu (4 Seviyeli))
PRI	: Pulse Repetition Interval (Darbe Tekrarlama Aralığı)
PSD	: Power Spectral Density (Güç Spektral Yoğunluğu)
PSK	: Phase Shift Keying (Faz Kaydırmalı Anahtarlama)
QAM	: Quadrature Amplitude Modulation (Dördün Genlik Modülasyonu)
QPSK	: Quadrature Phase Shift Keying (Dördün Faz Kaydırmalı Anahtarlama)
RAM	: Random Access Memory (Rastgele Erişimli Hafıza)
RBFN	: Radial Basis Function Networks (Radyal Temelli Fonksiyon Ağları)
RCs	: Radar Cross Section (Radar Kesiti)
ResNet	: Residual Network (Artık Ağ)
RF	: Radyo Frekansı
RMSE	: Root Mean Square Error (Ortalama Karekök Hata)
RNN	: Recurrent Neural Networks (Tekrarlayan Sinir Ağları)
RP	: Resilient Propagation (Esnek Yayılma)
RRCNN	: Recursive Residual Convolutional Neural Network (Artık Evrişimli Sinir Ağı)

SAR	: Sentetik Açıklıklı Radar
SFM	: Sinusoidal Frequency Modulation (Sinüzoidal Frekans Modülasyonu)
SF	: Spreading Factor (Yayımla Faktörü)
SNR	: Signal to Noise Ratio (Sinyal Gürültü Oranı)
SPWVD	: Smoothed Pseudo Wigner-Ville Distribution (Düzleştirilmiş Sözde Wigner-Ville Dağılımı)
SVM	: Support Vector Machine (Standart İkili Destek Vektör Makinesi)
TCN	: Temporal Convolutional Neural Network (Geçici Evrişimsel Sinir Ağı)
TFI	: Time-Frequency Image (Zaman-Frekans Görüntüsü)
UHF	: Ultra High Frequency (Ultra Yüksek Frekans)
UNet	: U Network (U Ağı)
VHF	: Very High Frequency (Çok Yüksek Frekans)
W	: Watt
WBFM	: Wideband Frequency Modulation (Geniş Bant Frekans Modülasyonu)
YD	: Yıldız Diyagram
YSA	: Yapay Sinir Ağları

1. GİRİŞ

Günümüzde RF (Radio Frequency) yayını yapan cihazların giderek yaygınlaşması bazı olumsuz durumları ortaya çıkarabilmekte ve ülkelerin güvenliği açısından büyük bir tehdit oluşturabilmektedir. Özellikle askeri/sivil havacılık sektöründe uçuş güvenliğini tehlikeye atacak herhangi bir korsan yayın ya da sinyal karıştırma işlemi dönüşü olmayan kötü sonuçlara yol açabilir. Örneğin son yıllarda sinyal kesici ya da bastırıcı yayınlar nedeniyle uzaktan kontrol edilebilir şekilde uçan İnsansız Hava Araçları (İHA)'nın kaybedilmesi durumu sık karşılaşılan bir problem olarak gündeme gelmektedir. Havacılık sektörünün ve savunma sanayinin hızlı gelişimi ve değişimi göz önüne alındığında günümüzde sinyal takibi ve analizinin hızlı bir şekilde yapılabilmesi gerek istihbarat, gerekse güvenlik önlemleri açısından önemli bir konu başlığı haline gelmektedir.

Dünya genelinde yayınlanan RF sinyallerinin toplanması için birçok endüstriyel ve askeri ürün kullanılmaktadır. Sistemdeki anten dizileri ile çok kanallı dijital alıcılar, darbe tabanlı yön bulma yeteneği sağlar. Sinyallere göre yayın yapan RF kaynağının koordinat bilgileri, sinyal genlikleri, bant genişlikleri, dalga boyları, güçleri ve modülasyon tipleri belirlenerek kayıt altına alınır. Toplanan sinyal verileri bir veri tabanında tutulur ve yedeklenir. Veri tabanında tutulan birçok sinyalin sınıflandırılarak ait oldukları kaynaklarının tespit edilmesi gerekmektedir. Genel olarak toplanan sinyallerin çok fazla olması ve özellikle havacılık gibi dinamik sektörlerde zamanın çok değerli olması gibi nedenler dikkate alındığında, bu sinyallerin klasik yöntemler kullanılarak sınıflandırılması ve kimliklendirilmesi oldukça fazla zaman ve insan iş gücü gerektirmektedir. Bu doğrultuda gelişmiş bilgisayarların kullanılması ile akıllı sistemler tarafından bu gibi işlemlerin yapılması çok daha doğru sonuçlar elde edilmesini sağlayacaktır.

Öncelikle belirli bir bölge içerisinde sinyal verilerini toplayan bir veya birkaç uygun sinyal toplayıcı cihaz olmalıdır. İlk aşamada toplanan veriler analiz edilerek kümelere ayrılır. Bu verilerin özelliklerini tanımlamak ve bunları girdi olarak kullanabilmek için vektörel işlemden geçirilerek bir önışleme uygulamak gerekmektedir. Sınıflandırma işlemi, önışleme sonucunda uygun yöntemler kullanılarak elde edilen görüntülerin girdi olarak kullanılması ile yapılır. Bu doğrultuda tasarlanan model önceki bilgiyi de işleyerek talep edilen isteğe göre sınıflandırma işlemini gerçekleştirir.

Bu çalışmada belirli bir bölge içerisinde yer istasyonlarından toplanmış RF sinyallerinin sınıflandırılması problemine çözüm aranması ve gerek havacılık sektörü, gerekse İHA'ların uçuş güvenliği açısından insan iş yükünü en aza indirgeyecek analitik bir yaklaşım ortaya konulması hedeflenmektedir. Bu doğrultuda toplanan çok sayıda gerçek sinyal verisinin, geliştirilen model yardımıyla en kısa süre içerisinde en doğru şekilde sınıflandırılarak yayın yapan vericilerin tanımlanması amaçlanmaktadır.

Çalışmanın amacı kapsamında tasarlanan sinyal sınıflandırma modelinde verilerin en kısa sürede ve en doğru şekilde kimliklendirilebilmesi amacıyla Makine Öğrenmesi ve Derin Öğrenme mimarilerinden yararlanılmıştır. Günümüzde Makine Öğrenmesi algoritmaları içerisinde yaygın olarak kullanılan K-En Yakın Komşuluk ve K-Ortalama Kümeleme ile seçilen veri kümeleri üzerinde işlem uygulanmış ve doğruluk oranları detaylı olarak incelenmiştir. Ayrıca Derin Öğrenme Mimarileri ile veri kümeleri çalıştırılmış ve doğruluk oranları alınmıştır. Geliştirilen model gerçek verilerden oluşturulan örneklenmiş veri kümeleri ile çalıştırıldığında sinyal sınıflandırma da yüksek başarı oranı elde edilmiştir.

Çalışmanın birinci bölümünde sınıflandırma modelleri ile çalışmanın amacı kapsamında sinyal sınıflandırma modelleri kullanılarak geçmişten günümüze son yıllarda yapılan araştırmalar ortaya konulmuş olup, bu çalışmanın özgünlüğüne ve araştırma yöntemine değinilmiştir.

Çalışmanın ikinci bölümünde günümüzde en sık kullanılan sınıflandırma yöntemleri ile sınıflandırma işleminde kullanılacak verinin içeriği ve sınıflandırma öncesi gerçekleştirilen ön hazırlıklar yer almaktadır.

Çalışmanın üçüncü bölümünde tez çalışmasında geliştirilen sınıflandırma modeli kapsamında veri ön işleme, dönüşümler, veri kümeleri oluşturma aşaması ve modelin geliştirme ortamı verilmiştir.

Çalışmanın dördüncü bölümünde ise geliştirilen modelinin çözümünden elde edilen bulgular, çalışmada kullanılan mimariler ve algoritmaların performans sonuçları ve performanslarının kıyaslanması yer almaktadır.

Elde edilen bulgular ışığında ortaya çıkan sonuç ve geleceğe yönelik öneriler çalışmanın beşinci bölümünde yer almaktadır.

1.1. Tez Çalışmasının Amacı ve Önemi

Dünya nüfusunun her geçen gün artması ile birlikte bazı güvenlik sorunları da hızla artış göstermektedir. Bu güvenlik sorunlarının başında sinyal istihbaratı bulunmaktadır. Günümüzde, dünya üzerindeki herhangi bir alanda bulunan RF yayın yapan cihazların tespit edilmesi ve izlenmesi işlemi yer istasyonları aracılığıyla yapılmaktadır. Mevcut yer istasyonları vasıtasıyla gerçekleştirilen RF sinyal tespit çalışmalarının özellikle uydu teknolojisindeki gelişmelerle birlikte son yıllarda uydular aracılığıyla gerçekleştirilmesi yönünde bir eğilim olduğu görülmektedir. Bu kapsamda gerek yer istasyonu, gerekse uydu aracılığıyla tespit edilmiş olan sinyallerin ne çeşit bir sinyal yayıcısına ait olduğunun belirlenmesi konusu oldukça önemlidir. Zira elde edilmiş olan sinyallerin radar sinyali mi, telsiz sinyali mi ya da GSM sinyali mi olduğunun kısa bir süre içerisinde belirlenebilmesi zaman ve iş gücü kaybının önüne geçecektir. Bu kapsamda sinyallerin sınıflandırılması ile tespit edilen sinyal yayıcısının tanımlanması diğer bir deyişle kimliklendirilmesi oldukça önemlidir.

Bu çalışmada başta da belirtildiği üzere belirli bir bölge içerisinde yer istasyonlarından toplanan çok sayıda RF sinyal verisinin sınıflandırılarak yayın yapan RF kaynaklarının makine yardımıyla tanımlanması için bir sinyal sınıflandırma modeli geliştirilmesi amaçlanmıştır. Bu kapsamda Makine Öğrenme algoritmaları ve Derin Öğrenme mimarileri kullanılarak geliştirilen model ile sinyallerin en kısa süre içerisinde optimum bir şekilde teşhis edilmesini sağlayacak analitik bir yaklaşım ortaya konulması hedeflenmiştir.

Gelişen teknoloji ile birlikte sayıları hızla artan haberleşme teknolojileri göz önünde bulundurulduğunda özellikle haberleşme ve savunma alanlarında sinyal sınıflandırması konusunda çok fazla bir çalışmaya rastlanamamaktadır. Türkiye coğrafi açıdan stratejik bir öneme sahip bir ülkedir. Ülkede bulunan sinyal yayıcılarının sayısı her geçen gün artmaktadır. Bu nedenle bu yayın yapan cihazların sinyallerinin sınıflandırılarak konumlandırılması konusunda akademik bir çalışmanın olmaması araştırmanın önemini arttırmaktadır. Bu kapsamda geliştirilecek bir sinyal sınıflandırma modeli ile gerek havacılık sektörü, gerekse Savunma Sanayii açısından kolaylıklar sağlanacağı öngörülmektedir.

1.2. Tez Çalışmasının Yöntemi

Farklı sinyallerin teşhisi için, kural tabanlı sabit sistemlerin yerine eğitilebilen dinamik teşhis modelinin geliştirilebilmesi büyük önem arz etmektedir. Günümüzde bilgisayar performanslarındaki artış ve gelişmeler neticesinde derin öğrenme ve makine öğrenmesi tabanlı yaklaşımların oldukça iyi sonuçlar verebileceği düşünülmektedir (Gao ve ark., 2019). Bu sebeple derin öğrenme ile yapılan çalışmalar ve teknolojik gelişmeler göz önüne alındığında, sinyal yayını yapan cihazların sınıflandırılmasında ve sinyal kaynaklarının teşhis edilmesinde başarılı sonuçlar elde edileceği öngörülmektedir.

Bu çalışmada Türkiye Cumhuriyeti Savunma Sanayi Kuruluşu'ndan temin edilen ve Türkiye'nin Ege Bölgesi'nde sabit olarak kurulu olan istasyonlar aracılığıyla toplanan 2020-2021 yılları arasında Mayıs-Haziran-Temmuz aylarına ait yaklaşık 900 bin adet sayısal sinyal verisi kullanılmıştır. Etiketli gelen veriler arasında karışık olarak GSM, Radar, Telsiz, Jammer ve farklı tipteki vericilere ait diğer sinyaller yer almaktadır. Etiketlenmiş bir şekilde temin edilen sinyallerin genlik, frekans ve koordinat bilgileri yer almaktadır. Etiketli her bir cihazın sinyal verileri öncelikle ön işleme aşamasında derin öğrenme mimarileri ve makine öğrenmesi ile uyumlu çalışabilmesi için dönüşüm yöntemleri kullanılarak görüntüye dönüştürülmüş ve yeniden etiketlenmiştir.

Tezin içeriğinde sinyal sınıflandırmada en iyi sonucu verecek algoritma veya mimarinin belirlenmesi amacıyla gerçek veri kümesi kullanılarak Makine Öğrenmesi ve Derin Öğrenme ile sınıflandırma yapılmış ve performansların elde edilmesi hedeflenmiştir. Bu kapsamda öncelikle Makine Öğrenmesi yöntemleri kullanılarak çeşitli analizler gerçekleştirilmiştir. Daha sonra Derin Öğrenme Mimarileri ile sınıflandırma gerçekleştirilmiş ve Makine Öğrenmesi ile ulaşılan sonuçların kıyaslanması sağlanmıştır. Sınıflandırma sonucunda tanımlanan ya da kimliklendirilen veriler veri tabanına eklenerek bir kütüphane oluşturulması sağlanmıştır.

Makine Öğrenmesi ile yapılan analizlerde algoritmalar tek tek çalıştırılarak doğruluk oranı ve analiz süreleri gibi performans değerleri elde edilmiştir. Derin Öğrenme Mimarileri ise farklı veri kümeleri ile ayrı ayrı çalıştırılmış ve performans değerleri elde edilmiştir. Performans değerlerinin değişimini gözlemlemek için iki adet farklı veri kümesi kullanılmıştır. İlk veri kümesi; sinyal verilerinin Hilbert Huang Dönüşümü (HH) ile elde edilen örnek görüntülerden oluşan I. Veri Kümesi, diğeri ise hem HH dönüşümü hem de modülasyonlu sinyal verilerinin Yıldızküme Diyagramı (YD)

ile elde edilen örnek görüntüler ile oluşturulan II. Veri Kümesidir. Literatürde bulunan diğer sınıflandırma çalışmaları da dikkate alınarak performans metrikleri belirlenmiş ve bu çalışma kapsamında çözülmesi hedeflenen probleme ve benzer problemlere en uygun yeni bir öneri geliştirilmiştir.

1.3. Literatür Araştırması

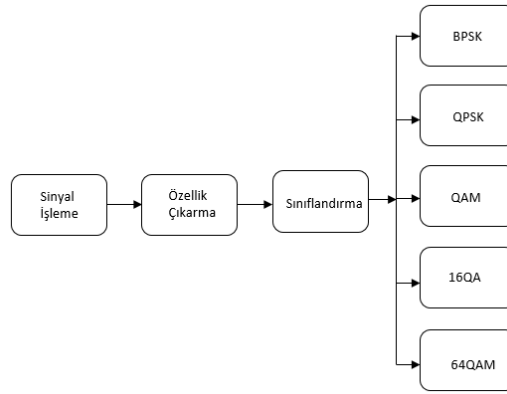
Sınıflandırma konusunda yapılan detaylı literatür araştırmasında farklı uygulama alanları için geçmişten günümüze birçok yöntem kullanıldığı görülmüştür. Günümüzde sınıflandırmada en yaygın kullanılan yöntemler Genetik Algoritmalar (GA), Makine Öğrenmeleri, Optimizasyon Yöntemleri, Yapay Sinir Ağları (YSA) ve Derin Öğrenmedir.

Genetik Algoritmalar genel olarak sağlık vb. gibi pek çok alanda sınıflandırma problemlerinde yaygın bir şekilde tercih edilen yöntemlerden biridir. Genetik Algoritma kullanılarak yapılan sınıflandırma çalışmalarına örnek olarak (Haznedar vd., 2017), (Okyay vd., 2016), (Sachnev vd., 2014) ve (Şeker vd., 2017)'nin yapmış olduğu araştırmalar verilebilir. Bazı çalışmalarda Genetik Algoritmalar ile yapılan sınıflandırmalara ek olarak filtreleme yönteminin de uygulandığı görülmektedir (Karasu ve Saraç, 2020), (Yıldız vd., 2012), (Zhang vd., 2005). Günümüzde sinyal sınıflandırma modellerinde ise birçok mimari, algoritma ve yöntem kullanılmaktadır. Yapılan sinyal sınıflandırma çalışmaları incelendiğinde araştırmaların son dönemde özellikle derin öğrenme mimarileri üzerinde yoğunlaştığı görülmektedir (Simonyan ve Zisserman, 2014), (Szegedy vd., 2015).

Derin Öğrenmede en yaygın ağlar Evrişimli Sinir Ağları (CNN- Convolutional Neural Networks), Tekrarlayan Sinir Ağları (RNN-Recurrent Neural Networks), Çift Yönlü Tekrarlayan Sinir Ağları, Uzun Kısa Dönemli Bellek (LSTM-Long / Short Term Memory), Radyal Tabanlı Fonksiyon Ağı, Çift Yönlü Uzun Kısa Vadeli Hafıza Ağları, Konvolüsyonel Uzun Kısa Vadeli Hafıza Ağları, Derin İnanç Ağları (DBN-Deep Belief Networks), Kapsül Ağı (CN-Capsule Network), Derin Oto Kodlayıcılar (DAE-Denoising Autoencoders)-Oto-Kodlayıcılar (AE-Autoencoders-AE) ve Destek Vektör Makinesi (SVM-Support Vector Machine) olarak tanımlanmaktadır. Derin Öğrenme mimarileri arasında ise günümüzde en yaygın olanlar ResNet, AlexNet, UNet, LeNet, GoogleNet, VGGNet ve ZFNet'dir.


Çalışmanın bu bölümünde birkaç araştırma dışında son yıllarda özellikle derin öğrenme mimarileri kullanılarak yapılan sinyal sınıflandırma çalışmaları tarihsel sıralama ile detaylı olarak incelenmiştir.

Ghauri vd. (2016) çalışmalarında otomatik bir modülasyon sınıflandırma işlemi gerçekleştirmeyi amaçlamışlardır. Bu amaç doğrultusunda BPSK (Binary Phase Shift Keying), QPSK (Quadrature Phase Shift Keying), QAM (Quadrature Amplitude Modulation), 16-QAM (16-Quadrature Amplitude Modulation) ve 64-QAM (64-Quadrature Amplitude Modulation) modülasyonlarının örnek görüntülerini kullanarak 5 farklı sınıf tanımlanmışlardır. K-En Yakın Komşuluk ağı kullanılarak yapılan bu sinyal sınıflandırma çalışmasında % 96 oranında doğruluk elde edildiği vurgulanmıştır. Araştırmacıların çalışmalarında kullandığı sınıflandırma modeli akış şeması Şekil 1.1’de özet olarak gösterilmiştir (Ghauri vd., 2016).



Şekil 1.1. Model akış şeması (Ghauri vd., 2016)


Wei vd. (2018) çalışmalarında sualtı akustik sinyalinin karakteristik spektrogramını sınıflandırmayı amaçlamışlardır. Sınıflandırma işleminde Tekrarlayan Sinir Ağı, Evrişimli Sinir Ağı ve Derin Sinir Ağı modelleri kullanılmıştır. Araştırma genel olarak sınıflandırılacak alan yaratma, özellik çıkarma, sınıflandırma ve tanımlama şeklinde dört adımdan oluşmaktadır. Bu kapsamda ilk olarak sualtı akustik sinyalleri gürültüden ayrıştırılmış ve özellik çıkarma işlemi yapılarak örnek sınıflar oluşturulmuştur. Bu çalışmanın genel akış şeması Şekil 1.2’de özet olarak verilmiştir (Wei vd., 2018).



Şekil 1.2. Çalışmanın genel akış şeması (Wei vd., 2018)

Katyara vd. (2020) çalışmalarında harmoniklerin tahmini ve sınıflandırılması için makine öğrenimi yaklaşımlarını kullanarak Standart İkili Destek Vektör Makinesi (SVM-Support Vector Machine) ve AlexNET mimarisi kullanmışlardır. Yapılan sınıflandırmada doğruluk oranının % 90 olarak ölçüldüğü belirtilmiştir (Katyara vd., 2020).

Saeed vd. (2021) çalışmalarında belirledikleri coğrafi alanlarda radarla tespit edilen insan aktivitelerini derin öğrenme mimarilerinden ResNet, GoogleNet ve AlexNet kullanarak sınıflandırmayı amaçlamışlardır. Şekil 1.3’de verilen 6 örnek sınıfın kullanıldığı bu araştırmada en yüksek doğruluk oranının % 68.5 ile % 81 arasında olduğu ve bunun GoogleNet mimarisi ile elde edildiği ifade edilmiştir (Saeed vd., 2021).




Şekil 1.3. Örnek sınıf görüntüleri (Saeed vd., 2021)

Wang vd. (2017) çalışmalarında BPSK (Binary Phase Shift Keying), QPSK (Quadrature Phase Shift Keying), 8PSK (8 Phase Shift Keying), 16QAM (16 Quadrature Amplitude Modulation) modülasyonlu sinyal verilerini kullanarak otomatik modülasyon


sınıflandırması yapmayı amaçlamışlardır. Bu çalışmada öncelikle belirtilen modülasyon tipleri için yıldızküme diyagramları çıkarılarak örnek görüntü grupları elde edilmiş ve sınıflar oluşturulmuştur. Farklı Sinyal Gürültü Oranı (SNR-Signal to Noise Ratio) değerleri kullanılarak oluşturulan örnek görüntüler, Ortalama Olabilirlik Oranı Testi (ALRT-Average Likelihood Ratio Test), Proposed Algoritma ve Derin Öğrenme Mimarilerinden Derin İnanç Ağları (DBN-Deep Belief Network) olmak üzere üç farklı mimari kullanılarak sınıflandırılmıştır. Araştırmacılar ALRT yöntemi ile yapılan sınıflandırmada 0 dB’de % 95 doğruluk oranına ulaştığını ifade etmişlerdir (Wang vd., 2017).

Tang vd. (2018) çalışmalarında otomatik modülasyon sınıflandırması yapmayı amaçlamışlardır. Araştırmacılar BPSK, 4ASK, QPSK, OQPSK, 8PSK, 16QAM, 32QAM ve 64QAM olmak üzere sekiz farklı modülasyon türünü dikkate almışlardır. Çalışma kapsamında IQ ham sinyal verileri kullanılarak yıldızküme diyagramı ve kontör yıldızı dönüşümü ile elde edilen örnek görüntüler Şekil 1.4’de gösterilmiştir. Üretilen örnek görüntülerin sınıflandırılmasında Derin Öğrenme Mimarilerinden AlexNet’in kullanıldığı bu çalışmada birinci veri seti için elde edilen doğruluk oranının % 82-% 100, üretilen veri seti için % 84-% 100 olduğu vurgulanmıştır. Araştırma kapsamında doğruluk oranının % 0.1~6 arasında arttığı ifade edilmiştir (Tang vd., 2018).



Şekil 1.4. Örnek görüntüler (a) Yıldızküme diyagramı (b) Kontör yıldızı dönüşümü (Tang vd., 2018)

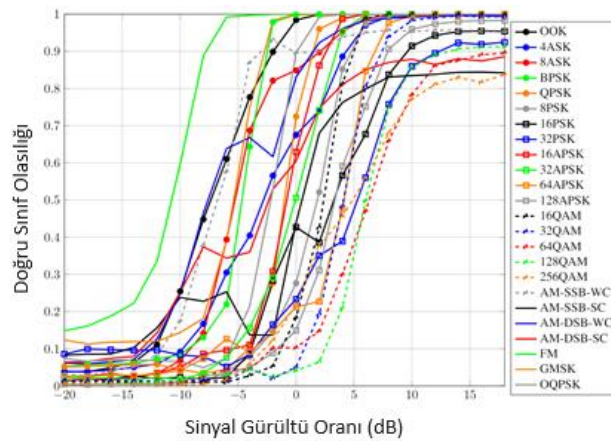
Zhang vd. (2018) çalışmalarında otomatik modülasyon sınıflandırması yapmayı amaçlamışlardır. Bu çalışmada BPSK, QPSK, 8PSK, 16QAM, 64QAM, BFSK, CPFSK ve 4PAM olmak üzere 8 farklı modülasyon türü verisi kullanılmıştır. Öncelikle giriş sinyaline özellik çıkarımı yapılmış olup, sınıflandırma işleminde CNN (Convolutional Neural Network) ve Uzun Kısa-Süreli Bellek (LSTM- Long Short-Term Memory) ağı kullanılmıştır. Modelin yapısı Şekil 1.5’de verilmiştir. Sınıflandırmada LSTM ağının, CNN’e göre daha iyi sonuç verdiği vurgulanmıştır. (Zhang vd., 2018).



Şekil 1.5. Model yapısı (Zhang vd., 2018)

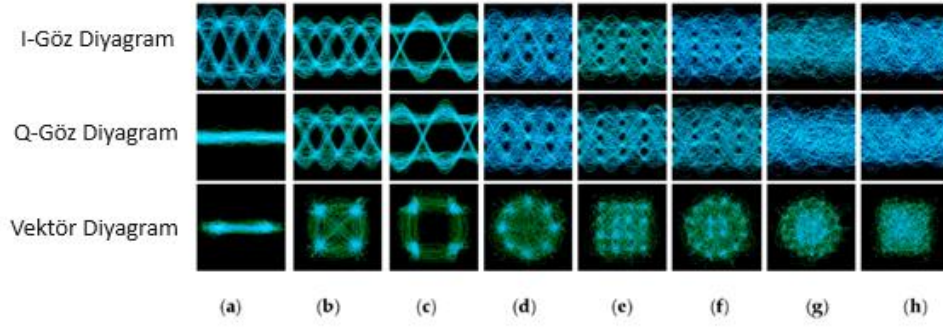
Rajendran vd. (2018) çalışmalarında bir kablosuz ağ için modülasyon sınıflandırma problemini incelemişler ve LSTM'ye dayalı otomatik modülasyon sınıflandırması için yeni bir model önermişlerdir. Araştırmacılar önerdikleri modelin, 0-20 dB arasında değişen sinyal gürültü oranı koşullarında % 90'a yakın ortalama sınıflandırma doğruluk oranı sağladığını vurgulamışlardır (Rajendran Rajenderen vd., 2018).

O'Shea vd. (2018) çalışmada 24 adet farklı sinyal verisi kullanarak, farklı sinyal gürültü oranı (SNR) değerleri ile otomatik modülasyon sınıflandırmayı hedeflemişlerdir. Araştırmacılar sınıflandırma işleminde, CNN ve ResNet Mimarisini kullanmışlardır. Örnek görüntüler ve modelin sonuçları Şekil 1.6'da gösterilmiştir. Araştırmacılar kablosuz iletişimde ideal haberleşmenin 0 SNR değerinde yakalandığını belirtmişlerdir (O'Shea vd., 2018).



Şekil 1.6. Örnek görüntüler ve modelin sonuçları (O'Shea vd. 2018)


Wu vd. (2018) çalışmalarında bir cihazın yaydığı elektromanyetik sinyallerin karakteristiklerini analiz ederek, cihazın tanınmasını sağlayan RF parmak izi probleminin çözümü için sınıflandırma gerçekleştirmeyi amaçlamışlardır. Çalışmada sınıflandırma



Şekil 1.8. Örnek görüntü grubu (Zha vd., 2019)

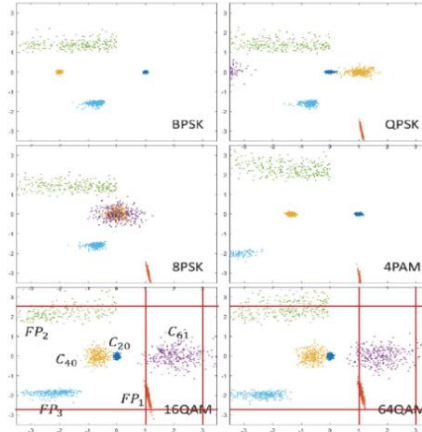
Xiao vd. (2019) çalışmalarında radar sinyallerinin otomatik modülasyon sınıflandırmasını gerçekleştirmeyi hedeflemişlerdir. Bu kapsamda modüle edilmiş radar sinyallerinin Choi-Williams Dağılımı (CWD) ile zaman-frekans dönüşümünü gerçekleştirerek örnek görüntülerini elde etmişlerdir. Çalışmada öğrenmeye ve tasarım deneylerine dayalı bir görüntü sınıflandırma modeli önererek modeli doğrulamak için 1800 örnek görüntü ve 8 tip radar sinyali CWD görüntüsü içeren bir veri tabanı oluşturmuşlardır. Elde edilen simülasyon sonuçları doğrultusunda önerilen modelin düşük bir sinyal gürültü oranında radar sinyallerini etkili bir şekilde tanımak ve sınıflandırmak için kullanılabileceği vurgulanmıştır (Xiao vd., 2019).

Peng vd. (2019) çalışmalarında çeşitli sinyal gürültü oranları altında otomatik modülasyon sınıflandırması gerçekleştirmeyi hedeflemişlerdir. Bu kapsamda öncelikle BPSK, 4ASK, QPSK, OQPSK, 8PSK, 16QAM, 32QAM ve 64QAM modülasyonlu sinyal verilerinin 0, 4 ve 10 dB sinyal gürültü oranında 3 kanallı yıldızküme diyagramı görüntülerini elde etmişlerdir. Elde edilen bu örnek görüntü grupları Şekil 1.9'da gösterilmiştir. Bu örnek görüntü grupları kullanılarak oluşturulan veri kümesinin sınıflandırılmasında Derin Öğrenme Mimarilerinden AlexNet ve GoogLeNet kullanılmış olup, çalışmanın deneysel sonuçlarından elde edilen doğruluk oranlarının 0 dB'de % 69-%74.1, 4 dB'de % 87.1-% 91, 10 dB'de ise % 99 olarak ölçüldüğü vurgulanmıştır. Mimarilerin çalışma süresi ise AlexNet için 6.6 ms iken GoogLeNet için 18 ms olarak açıklanmıştır (Peng vd., 2019).



Şekil 1.9. Yıldızküme diyagramı örnek görüntü grubu (Peng vd., 2019)


Lee vd. (2019) çalışmalarında altı adet modülasyonlu sinyal verisi kullanarak sınıflandırma işlemi gerçekleştirmeyi amaçlamışlardır. Örnek görüntü gruplarının elde edilmesinde özellik çıkarımı, yıldızküme diyagramı ve hiyerarşik olmak üzere üç farklı yöntem kullanmışlardır. Bu çalışmada kullanılan örnek görüntü grubu Şekil 1.13’de gösterilmiştir. CNN (Convolutional Neural Network) ile yapılan sınıflandırma sonucunda elde edilen doğruluk oranlarının özellik çıkarma yöntemi ile oluşturulan görüntü grubu için % 18-% 100, yıldızküme diyagramı ile oluşturulan örnek görüntü grubu için % 27-% 83 ve hiyerarşik ile oluşturulan örnek görüntü grubu için de % 18-% 68 olduğu belirtilmiştir (Lee vd., 2019).



Şekil 1.10. Örnek görüntü grubu (Lee vd., 2019)


Huang vd. (2019) çalışmalarında BPSK, QPSK, 8PSK, 16QAM, 64QAM olmak üzere 5 farklı modülasyon türü için ürettikleri sinyal verilerini kullanarak otomatik modülasyon sınıflandırması yapmayı amaçlamışlardır. Sınıflandırmada kullanılmak üzere belirledikleri modülasyon türleri için 5 dB sinyal gürültü oranında yıldızküme diyagramı (RCs- Radar Cross Section) ve Grid Yıldızküme Diyagramı (CGCs- Grid

Radar Cross Section) ile iki farklı görüntü grubu elde etmişlerdir. Elde ettikleri görüntü grubu örnekleri Şekil 1.11’de gösterilmiştir. Bu örnek görüntüler ile oluşturdukları veri kümelerini Evrişimli Sinir Ağları (CNN-Convolutional Neural Network) ile sınıflandırmışlardır. RCs ile oluşturulan örnek görüntüler kullanılarak yapılan sınıflandırmada elde edilen doğruluk oranlarının % 45- % 100, CGCs ile oluşturulan örnek görüntü grubu için % 47-%100 olduğu belirtilmiştir. Bu kapsamda CGCs kullanılarak elde edilen örnek görüntü grubu ile gerçekleştirilen sınıflandırma sonucunun diğerine göre az da olsa daha iyi sonuç verdiği vurgulanmıştır (Huang vd., 2019).



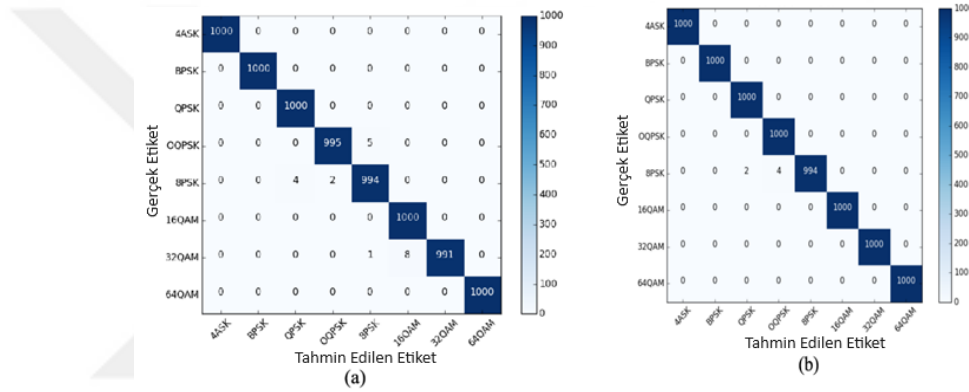
Şekil 1.11. Yıldızküme diyagramı ve Grid Yıldızküme diyagramı ile elde edilen görüntü grupları (Huang vd., 2019)

Xie vd. (2019) çalışmalarında farklı sinyal gürültü oranlarında BPSK, QPSK, OQPSK ve 8PSK olarak belirledikleri modülasyon tiplerinin sınıflandırmasını hedeflemiştir. Belirlenen modülasyon türleri için örnek görüntüler yıldızküme diyagramı ile oluşturulmuştur. Oluşturulan örnek görüntü grubu ile yapılan sınıflandırma işleminde Derin Öğrenme destekli algoritma ve çok etiketli derin öğrenme tabanlı algoritma kullanılmıştır. Araştırmacılar 2 dB’de elde edilen doğruluk oranının % 99.8 olduğunu ifade etmişlerdir (Xie vd., 2019).




Şekil 1.12. Çeşitli gürültü oranlarında yıldızküme görüntüleri (Xie vd., 2019)

Tu ve Lin (2019) çalışmalarında üretikleri 8 farklı modülasyonlu sinyal verisini kullanarak 2 farklı yöntemle otomatik modülasyon sınıflandırma işlemi gerçekleştirmeyi hedeflemişlerdir. Sınıflandırma işleminde kullanılmak üzere öncelikle belirledikleri modülasyon türleri için 0 dB’de yıldızküme diyagram ile örnek görüntüleri elde etmişlerdir. Örnek görüntü grubu kullanılarak yapılan sınıflandırma işleminde derin öğrenme mimarilerinden AlexNet’i kullanan araştırmacılar, zamandan tasarruf sağlamak üzere orijinal mimarinin bazı katmanlarını çıkararak budanmış mimari kullandıkları belirtmişlerdir. Sınıflandırma sonuçları karşılaştırıldığında budanmış mimari kullanıldığında % 1.5 ila % 5 arasında bir değişimle çalışma süresinin % 33 ila % 35 oranında kısaltılabileceğini ortaya koymuşlardır (Şekil 1.13) (Tu ve Lin, 2019).



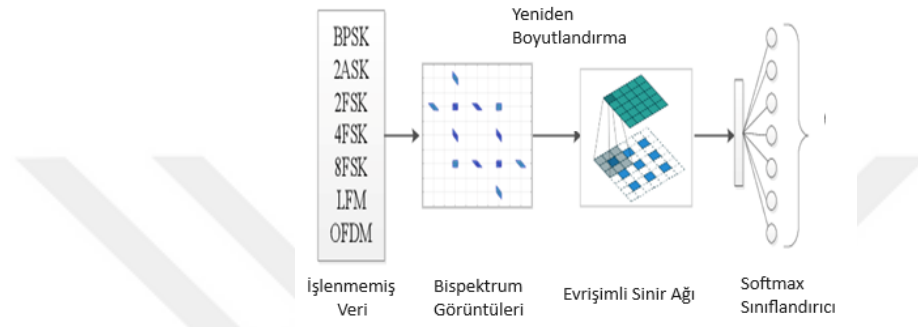
Şekil 1.13. (a) Önerilen model (b) Orijinal model (Tu ve Lin, 2019)

Ma vd. (2019) çalışmalarında çeşitli gürültü oranlarında otomatik modülasyon sınıflandırması yapmayı hedeflemişlerdir. Sınıflandırma örneklemede BPSK, 2ASK, 8ASK, 4QAM ve 16QAM modülasyon sinyal verilerini kullanmışlardır (Şekil 1.14). Gürültü altında sınıflandırma performansını iyileştirmek için Döngüsel Korrentropi Spektrumu (CCES- Cyclic Correntropy Spectrum) ve ResNet mimarisinin kullanıldığı bu çalışmada araştırmacılar, önerdikleri modelin 3 dB ‘de literatürdeki mevcut araştırmalara göre daha iyi sonuç verdiğini vurgulamışlardır (Ma vd., 2019).




Şekil 1.14. Modelin örnek görüntü grupları (Ma vd., 2019)

Li vd. (2019) çalışmalarında BPSK, 2ASK, 2FSK, 4FSK, 8FSK, LFM ve OFDM olmak üzere yedi farklı modülasyonlu sinyal verisi kullanarak otomatik sınıflandırma gerçekleştirmeyi amaçlamışlardır. Çalışmada kullanılmak üzere Bispektrum ile elde edilen örnek sinyal görüntüleri derin öğrenme mimarilerinden AlexNet ile sınıflandırılmıştır. Modelin genel akış şeması Şekil 1.15’de gösterilmiştir. Sınıflandırma işleminde elde edilen doğruluk oranının sinyal gürültü oranı 5 dB’den az olmadığına % 97.7’ye ulaşabileceğini vurgulamışlardır (*Li vd., 2019*).



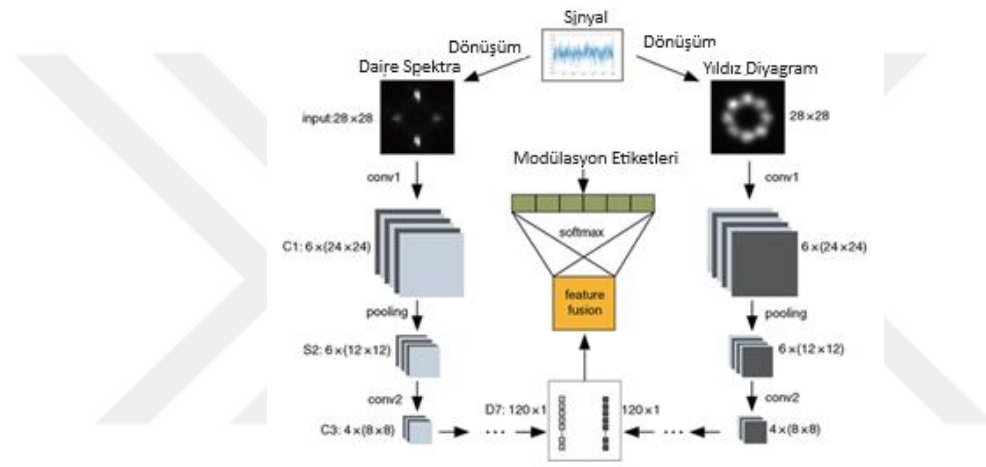
Şekil 1.15. Modelin genel akış şeması (*Li vd., 2019*)

Wang vd. (2019) çalışmalarında çeşitli modülasyonlu sinyallerin otomatik sınıflandırılmasını gerçekleştirmeyi hedeflemişlerdir. Bu kapsamda öncelikle derin öğrenme mimarilerinde kullanılmak üzere BPSK, QPSK, 8PSK, GFSK, CPFSK, 4PAM, 16QAM ve 64QAM modülasyonlu sinyallerin yıldızküme diyagramı ve yoğunluk pencereli yıldız diyagramı ile görüntülerini oluşturmuşlardır (Şekil 1.16). CNN (Convolutional Neural Network), DNN (Deep Neural Network) ve RNN (Recurrent Neural Networks) mimarileri kullanılarak gerçekleştirilen sınıflandırma işleminde 5dB ve daha yüksek gürültü oranlarında doğruluk oranlarının % 96’ya ulaştığı belirtilmiştir (*Wang vd., 2019*).



Şekil 1.16. Yıldızküme diyagramı ile görüntü oluşturma evreleri (*Wang vd., 2019*)

Wu vd. (2019) çalışmalarında iki farklı sinyal görüntüsü kullanarak otomatik modülasyon sınıflandırmasında derin öğrenme mimarilerinin performansını değerlendirmeyi hedeflemişlerdir. Bu kapsamda örnekleme için kullandıkları sinyal verilerinin döngüsel spektrum ve yıldızküme diyagram dönüşümleri ile 28x28 boyutundaki görüntülerini elde etmişlerdir. Sınıflandırma işleminde CNN (Convolutional Neural Network) ile LSTM (Long Short-Term Memory) ağı kullanılmış olup, önerilen modelin genel akış şeması Şekil 1.17’de gösterilmiştir. Araştırmacılar, sınıflandırma doğruluk oranının CNN ile % 18-% 88, LSTM ile % 18-% 90 arasında olduğunu belirtmişlerdir (Wu vd., 2019).

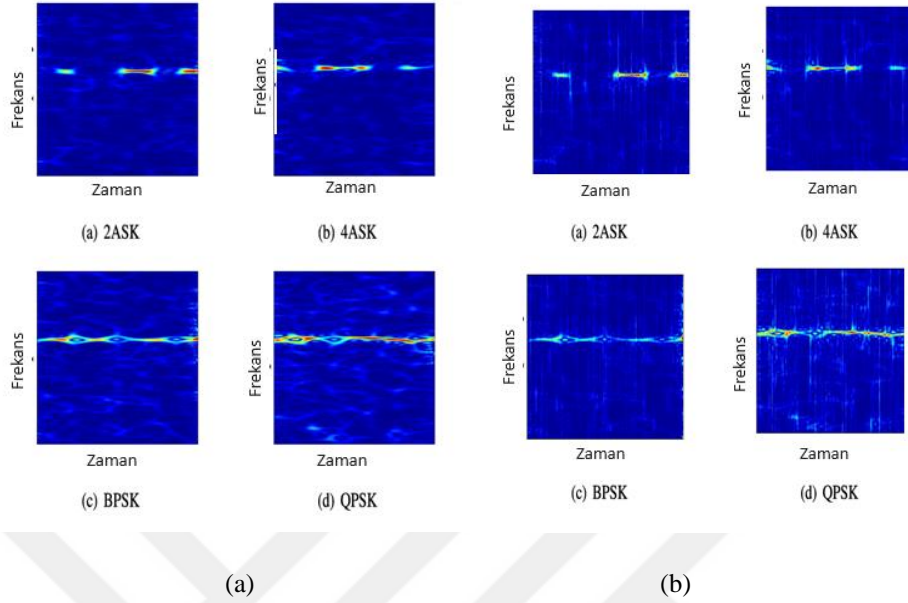


Şekil 1.17. Sinyallerin iki farklı görüntü ile sınıflandırılması (Wu vd., 2019)

Wang vd. (2019) çalışmalarında derin öğrenme mimarileri kullanarak otomatik modülasyon sınıflandırmayı amaçlamışlardır. Sınıflandırma için LFM (Linear Frequency Modulation- Doğrusal Frekans Modülasyonu), SF (Spreading Factor- Yayılma Faktörü), BPSK, QPSK, 2FSK ve 4FSK modülasyonlu sinyal verilerinin görüntüsünün çıkarılması amacıyla özellik haritası yöntemini kullanmışlardır. Özellik haritası çıkarılan modülasyon tipleri ağı giriş verisi olarak sokulmuş ve CNN ile yapılan sınıflandırma sonucunda elde edilen doğruluk oranının % 97-% 99 arasında olduğu vurgulanmıştır (Wang vd., 2019).

Zhang vd. (2019) çalışmalarında modülasyonlu sinyal verilerini derin öğrenme ile sınıflandırmayı amaçlamışlardır. Bu kapsamda CNN (Convolutional Neural Network) ile yapılan sınıflandırma işleminde SPWVD (Smoothed Pseudo Wigner-Ville Distribution) ile elde edilen frekans-zaman görüntüleri ve Born–Jordan yöntemi ile elde edilen örnek görüntüleri kullanmışlardır (Şekil 1.18). 4 dB seviyesindeki sinyal-gürültü oranıyla

gerçekleştirilen sınıflandırmada doğruluk oranının % 92.5'e ulaştığı vurgulanmıştır (Zhang vd., 2019).



Şekil 1.18. (a) SPWVD örnek görüntüsü, (b) Born-Jordan örnek görüntüsü (Zhang vd., 2019)

Yu vd. (2019) çalışmalarında bir cihazın yaydığı elektromanyetik sinyallerin karakteristiklerini analiz ederek, cihazın tanınmasını sağlayan RF parmak izi teknikleri için Derin Öğrenme tabanlı bir Gürültü Giderici Otomatik Kodlayıcı (DAE- Denoising Autoencoder) model tasarlamayı amaçlamışlardır. Araştırmacılar sınıflandırma işlemini -10 dB ile 30 dB arasında 9 farklı sinyal gürültü oranı değeri için gerçekleştirmiş ve 10 dB'lik sinyal gürültü oranında sınıflandırma doğruluk oranının % 97.5'e kadar yükseldiğini vurgulamışlardır (Yu vd., 2019).

Huang vd. (2019) çalışmalarında RadioML2016.10'den elde ettikleri modülasyonlu sinyal verilerinin sınıflandırılmasında doğruluk oranının artırılması için örnek görüntü oluşturma yöntemlerinde farklı alternatifleri ortaya koymayı hedeflemişlerdir. Çalışma kapsamında 11 farklı modülasyonlu sinyal verisi için öncelikle -2 dB ile 18 dB arasında sinyallerin yıldız küme diyagramlarını çıkarmışlardır. Daha sonra elde edilen görüntülere döndürme, çevirme işlemi yapmış ve Gauss gürültüsü ekleyerek farklı tipte örnek görüntüler elde etmişlerdir. Sınıflandırma için derin öğrenme tabanlı LSTM'ye dayalı mimarinin hem eğitim hem de test aşamasında üç farklı yöntemle oluşturulan görüntüler (döndürme, çevirme ve Gauss gürültüsü) dikkate alınmıştır. Deneysel sınıflandırma sonucunda döndürülmüş ve çevrilmiş örnek görüntü ile 10 dB'de doğruluk oranının % 92'ye kadar ulaştığı belirtilmiştir (Huang vd., 2019).

Elmaghub ve Hamdaoui (2020) çalışmalarında kablosuz haberleşme sinyallerini modifiye edilmiş CNN yardımıyla sınıflandırmayı amaçlamışlardır. Kullandıkları derin öğrenme mimarisine ilave bir katman ekleyerek orijinal mimariye göre sınıflandırma sonucunun değişimini gözlemlemişlerdir. Daha sonra bu sinyaller modifiyeli CNN kullanılarak sınıflandırılmış ve doğruluk oranının % 95 olarak ölçüldüğü vurgulanmıştır (Elmaghub ve Hamdaoui, 2020).

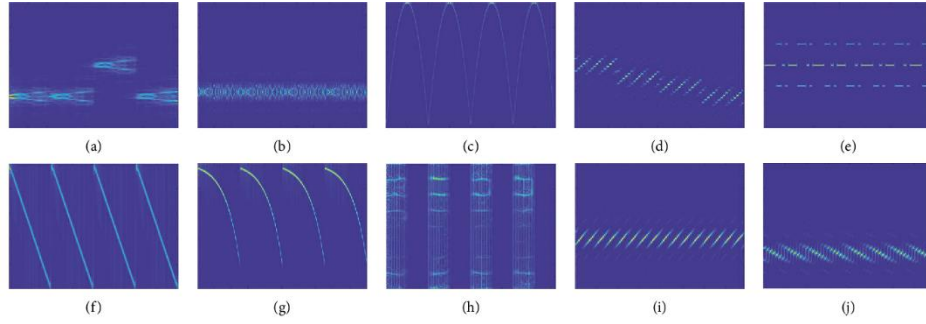
Kumar vd. (2020) çalışmalarında 2ASK, 4ASK, BPSK, QPSK, 8PSK, 8QAM, 16QAM, 32QAM ve 64QAM modülasyonlu sinyal verilerini Derin Öğrenme ile sınıflandırmayı amaçlamışlardır. Bu kapsamda sinyallerin örnek görüntülerini yıldızküme yoğunluk matrisi ile elde etmişlerdir. ResNet 50 ve ResNet V2 mimarileri kullanılarak yapılan sınıflandırma işleminde doğruluk oranları % 18 - % 100 olarak elde edilmiştir (Kumar vd., 2020).

Yang vd. (2020) çalışmalarında derin öğrenme ile otomatik modülasyon sınıflandırmayı amaçlamışlardır. Bu çerçevede BPSK, QPSK, 8PSK, 8QAM, 16QAM, 32QAM ve 64QAM modülasyonlu sinyal verilerini kullanarak yıldızküme diyagramını çıkarmışlardır. Daha sonra gri renkte çıkarılan yıldızküme diyagram görüntüleri işlenerek 3-kanallı, renkli, 4 farklı görüntü çeşidi elde edilmiştir. Araştırmacılar, sıcaklık arttıkça renk belirginliğinin artacağını ve sınıflandırma işleminde daha iyi sonuç alınacağını vurgulamışlardır. CNN ile yapılan sınıflandırma sonucunda -2 dB'de % 91.4 doğruluk oranına ulaşılabildiği açıklanmıştır (Yang vd., 2020).

Liu vd. (2020) çalışmalarında düşük çözünürlüklü FD (Fall Detection) sistemlerin daha iyi algılama performansı elde etmesini sağlamak üzere derin öğrenme tabanlı ASE (Accelerometer Signal Enhancement) mimarisinin kullanıldığı bir sınıflandırma modeli tasarlamayı hedeflemişlerdir. Bu kapsamda önerilen mimari, düşük ve yüksek çözünürlüklü sinyaller arasındaki ilişkiyi öğrenip düşük çözünürlüklü sinyallerden yüksek çözünürlüklü sinyalleri üretmiştir. Deneysel çalışmalar sonucunda veri kümeleri için sırasıyla % 97.34 ve % 90.52 doğruluk elde edildiği ifade edilmiştir. Bunun yanı sıra ASE modellerini kullanmayan SisFall ve FallAllID veri kümeleri için doğruluk oranlarının sırasıyla % 95.92 ve % 87.47 olduğu vurgulanmıştır (Liu vd., 2020).

Li vd. (2021) çalışmalarında ayırt edici özellik çıkarımı modeli tasarlamayı amaçlamışlardır. Bu doğrultuda ürettikleri darbeleri radar sinyallerinin zaman-frekans görüntüsünü (TFI- Time-Frequency Image) elde etmek için CWD (Choi-Williams ile bir

dönüşüm işlemi gerçekleştirmişlerdir. Sinyallerin zaman-frekans örnek görüntüleri Şekil 1.19'da gösterilmiştir. Araştırmacılar tarafından -14 dB ile 4 dB arasında çeşitli sinyal-gürültü oranlarında gerçekleştirilen deneysel çalışmalar sonucunda, -6 dB'de HRFNet'in sınıflandırma doğruluk oranının % 99.58'e, -14 dB altında ise % 97.50'e ulaştığı belirtilmiştir (Li vd., 2021).



Şekil 1.19. On farklı çok darbeli radar sinyalinin TFT'leri ((a) Barker, (b) Chaotic, (c) EQFM, (d) Frank, (e) FSK, (f) LFM, (g) LOFM, (h) OFDM, (i) P1, and (j) P2) (Li vd., 2021)

Liu ve ark. (2021) çalışmalarında endüstriyel kablosuz sensör ağlarının frekans bantlarının diğer sistemlerle paylaşıldığında parazit nedeniyle zarar görebileceğine odaklanmışlardır. Bu kapsamda özellikle şüpheli iletimleri tanımlamak amacıyla etkili spektrum paylaşımı için derin öğrenme ağlarına dayalı yeni bir sinyal sınıflandırma modeli önerilmiştir. Bu çerçevede öncelikle kablosuz 8 farklı modülasyonlu sinyal, CWD (Choi-Williams Distribution) analizi ile ön işleme tabi tutularak iki boyutlu görüntüleri elde edilmiştir. Elde edilen görüntüleri sınıflandırmak için derin öğrenme tabanlı bir sinyal sınıflandırma yöntemi öneren araştırmacılar, yapılan deneysel çalışmalar sonucunda mimarinin doğru bir şekilde öğrenebildiğini ve iyi bir sinyal sınıflandırma performansı elde edilebildiğini ifade etmişlerdir (Liu vd., 2021).

Zhang vd. (2022) çalışmalarında otomatik modülasyon sınıflandırma modelinde sinir ağını eğitmek için modifiye edilmiş bir mimari uygulamayı amaçlamışlardır. Elde ettikleri deneysel sonuçlar doğrultusunda önerdikleri yöntemin, modülasyon sınıflandırmada diğer algoritmalarından daha düşük karmaşıklığa ve daha yüksek verimliliğe ulaştığını vurgulamışlardır (Zhang vd., 2022).

Peng vd. (2022) çalışmalarında modülasyon sınıflandırma konusunda yapılan çalışmalarını detaylı bir şekilde inceleyerek derleme çalışması yapmayı amaçlamışlardır. Derin Öğrenme mimarileri ile yapılacak sınıflandırma işleminde sinyalleri giriş verisi olarak kullanabilmek için öncelikle özellik çıkarma işleminin uygulanması gerektiğini belirtmişler ve bunun için de verilerin kümülan, spektral ve dairesel özelliklerinin

kullanılabileceğini ifade etmişlerdir. Sinyal verilerinin görüntüye dönüştürülmesinde yıldızküme diyagramı, göz diyagramı, özellik noktası görüntüsü, belirsizlik fonksiyonu görüntüsü, spektral korelasyon fonksiyonu görüntüsü, döngüsel korentropi spektrum grafiği ve bispektrum grafiğinin kullanıldığı çalışmalara değinilerek elde edilen doğruluk oranları karşılaştırılmıştır (Peng vd., 2022).

Xu ve Lin (2022) çalışmalarında farklı yöntemler kullanarak otomatik modülasyon sınıflandırması yapmayı amaçlamışlardır. Bu kapsamda CNN, LSTM, ResNet ve Hiyerarşik sınıflandırma kullanılarak gerçekleştirilen deneysel çalışmalar sonucunda elde edilen doğruluk oranının 15 dB ile 20 dB arasında % 99 olduğunu vurgulamışlardır (Xu ve Lin, 2022).

Liu vd. (2022) çalışmalarında kablosuz sinyallerin sınıflandırılması aşamasında kullanılacak olan verilerin işlenmesine yönelik yeni bir yöntem geliştirmeyi hedeflemişlerdir. Bu kapsamda farklı sinyal özelliklerini analiz ederek bilinmeyen sinyalleri tanımlamak için Çok Boyutlu Özellik Hibrit Ağı (MFHN- Multidimensional Feature Hybrid Network) kullanarak küçük örneklili hedefleri belirlemek için Çok Özellikli Ortak Geçiş Ağı (MJMN- Multi-Feature Common Transition Network) tasarladıklarını ifade etmişlerdir. Sınıflandırmada 7 adet modülasyon tipine sahip sinyal verisi kullanılmıştır. CNN ile yapılan sınıflandırma sonucunda MFHN ve MJMN'nin bilinmeyen hedef sinyalleri sınıflandırmada doğruluk oranlarının sırasıyla % 82.7 ve % 93.2 olduğunu ve önerdikleri yöntem ile doğruluk oranında yaklaşık % 11'lik bir iyileşme elde ettiklerini ifade etmişlerdir (Liu vd., 2022).

Wang vd. (2023) çalışmalarında derin öğrenme yardımıyla otomatik sinyal sınıflandırma için özellik çıkarımı kullanmayı ve yüksek doğruluk oranları elde etmeyi amaçlamışlardır. Bu doğrultuda öncelikle özellik çıkarımı yaparak BPSK, AM-DSB (İng açılım), 8PSK, PAM4, QAM16, QAM64, QPSK, WBFM (Wideband Frequency Modulation) ve CPFSK (Continuous-Phase Frequency-Shift Keying) olarak belirledikleri modülasyon türlerinin örnek görüntülerini elde etmişlerdir. Derin Öğrenme mimarilerinden AlexNet, VGG16 (Very Deep Convolutional Networks), CNN ve ResNet kullanılarak yapılan sınıflandırma sonucunda doğruluk oranının % 90'a ulaştığı vurgulanmıştır (Wang vd., 2023).

Chen vd. (2023) çalışmalarında 11 farklı modülasyonlu sinyal verilerini kullanarak otomatik modülasyon sınıflandırması yapmayı amaçlamışlardır. Kendi yöntemleri ile

farklı bir görüntü grubu elde ettiklerini ifade ederek Uç Değer Teorisi (EVT-Extreme Value Theory) ile sınıflandırma gerçekleştirmişler. Önerdikleri modelin sınıflandırma doğruluğunun % 90'a çıktığını ve klasik sınıflandırma mimarilerine kıyasla % 1-2 oranında daha iyi sonuçlar elde edildiğini ifade etmişlerdir (Chen vd., 2023).

Zhang vd. (2023) çalışmalarında otomatik modülasyon sınıflandırması için üç farklı görüntü oluşturma yöntemi kullanmayı amaçlamışlardır. Görüntü oluşturma yöntemleri Açık Küme Tanıma, Bilinen Sınıf Tanımlaması ve Bilinmeyen Sınıf Tanımlaması olarak belirtilmiştir. Araştırmacılar, düşük gürültülü ortamlarda elde edilen görüntüler ile gerçekleştirilen sınıflandırmada önemli bir performans artışı elde edildiğini ve önerdikleri yöntemin etkinliğini doğruladığını ifade etmişlerdir (Zhang vd., 2023).

Fan vd. (2023) çalışmalarında kablosuz ağ sinyallerini kullanarak 27 farklı modülasyonlu sinyal verisi yardımıyla Ortogonal Frekans Bölmeli Çoğullama- (OFDM-Orthogonal Frequency Division Multiplexing) ve Dik Olmayan Çoklu Erişim (NOMA-Non-Orthogonal Multiple Access) yöntemleri ile elde edilen görüntüleri sınıflandırmayı amaçlamışlardır. Ön işleme sonrası yapılan sınıflandırma sonucunda önerdikleri modelin performansının ResNet ve CNN'den daha iyi olduğunu ve 20 dB'de % 96.6 doğruluk oranının elde edildiğini ifade etmişlerdir (Fan vd., 2023).

Hussein vd. (2023) çalışmalarında CNN tabanlı farklı bir otomatik modülasyon sınıflandırma (AMC-Automatic Modulation Classification) tekniği geliştirmeyi amaçlamışlardır. Çalışmada geleneksel AMC'lerin iki türe ayrılabilir olduğu, bunların ML (Maximum Likelihood) tabanlı ve özellik tabanlı şeklinde ayrıldığı belirtilmiştir. Bu çalışmada her biri farklı bir sınıflandırma katmanına (CL- Classification Layers) sahip üç farklı CNN tabanlı AMC geliştirildiği belirtilmiştir. Bu sınıflandırma katmanlarının, ortalama mutlak hataya dayalı CL, hataların karelerinin toplamına dayalı CL ve çapraz entropiye dayalı CL olduğu belirtilmiştir. Önerilen modelin sınıflandırma doğruluk oranının % 99.9'a kadar ulaştığı ifade edilmiştir (Hussein vd., 2023).

Ying vd. (2023) çalışmalarında modülasyonlu sinyallerin iki farklı derin öğrenme mimarisi ile sınıflandırılmasını amaçlamışlardır. Bu kapsamda RadioML2016.10A kullanılarak elde edilen 11 adet modülasyonlu sinyal verisinin ± 20 dB arasında yıldızküme diyagramı ile örnek görüntüleri oluşturulmuştur. Araştırmacılar, derin öğrenme mimarilerinden CNN (Convolutional Neural Network) ve DNN (Deep

Neural Network) kullanarak yaptıkları sınıflandırma sonucunda 0 dB’de % 91 doğruluk oranına ulaştıklarını ifade etmişlerdir (Ying vd., 2023).

Cao vd. (2023) çalışmalarında radyo sinyallerinin otomatik modülasyon sınıflandırmasında klasik yöntemlerden farklı olarak derin öğrenme mimarilerini ile sınıflandırma yapmayı amaçladıklarını belirtmişlerdir. Çalışmada 11 farklı modülasyonlu sinyal verisi kullanılmış olup, üretilen 1.000 adetlik veri seti yardımıyla sınıflandırma işleminin gerçekleştirildiği belirtilmiştir. Bu çalışmada sınıflandırma işlemi için basit hesaplama karmaşıklığına sahip bir mimari olduğu öngörülen MobileNet ile tasarım gerçekleştirilmiştir. Elde edilen sonuçlar derin öğrenme mimarilerinden VGG (Very Deep Convolutional Networks) ve ResNet kullanarak yapmış oldukları sınıflandırma sonuçları ile karşılaştırılmış ve MobileNet mimarisinin % 88 doğruluk oranına ulaştığını vurgulamışlardır (Cao vd., 2023).

Talha vd. (2023) çalışmalarında M-QAM ve M-PSK modülasyonlu sinyalleri sınıflandırmak için derin öğrenme mimarilerinden CNN (Evrışimli Sinir Ağı) kullanmışlardır. Eğitilen ağın performansını analiz etmek için farklı deneysel çalışmalar yapılmış olup, sınıflandırıcı ile güncel teknikler arasında performans değerlendirilerek belirli bir senaryoda sınıflandırıcının doğruluğunun % 100'e yaklaştığını ifade etmişlerdir (Talha vd., 2023).

Gao vd. (2023) çalışmalarında klasik derin öğrenme modellerinde yüksek dereceli modülasyonlarda sınıflar arası karışıklık sorunuyla karşı karşıya kaldığını belirterek bu sorunu çözmek için CrossTLNet adında çok görevli öğrenmeyle güçlendirilmiş bir hibrit sinir ağı kullanılarak gerçekleştirilecek bir modülasyon sınıflandırması önermişlerdir. RadioML.2016.10A. ile elde ettikleri sinyalleri, IQ ve Genlik/Faz formunda birlikte kullanarak dönüşüm gerçekleştirmişler ve derin öğrenme mimarilerinin kullanım formuna dönüşmesini sağlayarak görüntü elde etmişlerdir. Elde edilen görüntüleri sınıflandırmak için CrossTLNet, Geçici Evrışimsel Sinir Ağı (TCN- Temporal Convolutional Neural Network) ve LSTM ağının birlikte kullanıldığı, bir yöntem kullandıklarını ifade etmişlerdir. Sınıflandırma sonucunda elde ettikleri doğruluk oranının % 63 ila % 96.55 arasında olduğunu ve SNR \geq 0 dB olduğunda % 96.55 ile en yüksek sınıflandırma doğruluğuna ulaştıklarını vurgulamışlardır (Gao vd., 2023).

Zhang vd. (2023) çalışmalarında ürettikleri radar sinyallerini, radarın çalışma moduna göre Darbe Tekrarlama Aralığı (PRI-Pulse Repetition Interval) dizilerini

kullanarak, Çok çıkışlı çoklu yapı ortak darbeler arası otomatik modülasyon tanıma ve Parametre Tahmini (JMRPE-MOMS: Joint Inter Pulse Automatic Modulation Recognition and Parameter Estimation) için öğrenmeye dayalı bir model geliştirmeyi hedeflemişlerdir. Sınıflandırma işleminde LSTM kullanılmış olup, araştırmacılar % 98 doğruluk oranına ulaştıklarını belirtmişlerdir. Çalışmada önerilen yöntemin özellikle ideal olmayan elektromanyetik ortamlarda etkinliğini ve üstünlüğünü doğruladığını vurgulamışlardır (Zhang vd., 2023).

Fang vd. (2023) çalışmalarında Elektronik Destek Ölçüm (ESM- Electronic Support Measurement) sistemleri için Çok Fonksiyonlu Radar (MFR- Multifunctional Radar)'ın çalışma modlarındaki değişikliklerin tespitinin Derin Öğrenme mimarileri ile gerçekleştirilmesi amacıyla bir model önermişlerdir. Bu kapsamda Çift Yönlü Uzun Kısa Süreli Bellek Ağı (Bi-LSTM: Bidirectional Long Short-Term Memory) kullanılmış olup, önerilen modelin sonuçlarının mevcut klasik yöntemlerle elde edilen sonuçlara göre çok daha iyi olduğu vurgulanmıştır. Ayrıca ideal olmayan koşullar altında doğruluk oranının % 4.15 oranında arttığı belirtilmiştir (Fang vd., 2023).

Neves vd. (2023) çalışmalarında Amazon ormanlarındaki ormansızlaşmanın izlenmesi ve ormansız alanların tespiti için Sentetik Açıklıklı Radar (SAR) görüntülerini kullanarak özel olarak tasarlanmış üç derin öğrenme modeli (RRCNN-1(Recursive Residual Convolutional Neural Network-1), RRCNN-2 ve RRCNN-3 ile sınıflandırma yapmayı amaçlamışlardır. Elde edilen deneysel sonuçlar ışığında önerdikleri model ile doğruluk oranında yaklaşık % 5'lik bir artış sağlandığını ve özellikle RRCNN-1 ile en yüksek doğruluğu elde ederek işlem süresinin de azaldığını vurgulamışlardır (Neves vd., 2023).

Çalışmanın amacı kapsamında yukarıda detaylı bir şekilde incelenen literatür araştırması, araştırmacıların çalışmalarında kullandıkları sınıflandırma yöntemleri, sinyal gösterimi/önişleme aşamaları, ele aldıkları sınıfları, veri kümeleri ve elde ettikleri sonuçları dikkate alınarak Tablo 1.1'de özet olarak verilmiştir.

Tablo 1.1. Literatürde yer alan sinyal sınıflandırma çalışmaları

<i>Araştırmacı</i>	<i>Algoritma/Mimari</i>	<i>Sinyal Gösterimi/Önişleme</i>	<i>Sınıflar</i>	<i>Sonuçlar</i>	<i>Veri Kümesi</i>
<i>Wang vd., 2017</i>	ALRT, DBN	Grafik Yıldız Diyagramı	BPSK, QPSK, 8PSK, 16QAM	%95.14-%99	RadioML201 6.10b
<i>Tang vd., 2018</i>	AlexNet	Kontur Yıldız Görüntüsü ve Yıldız Diyagramı	BPSK,4ASK, QPSK, OQPSK, 8PSK, 16QAM, 32QAM, 64QAM	%83.5-%100	ACGAN ile üretilen yapay veri
<i>Zhang vd., 2018</i>	CNN ve LSTM	Özellik Çıkarımı	BPSK, QPSK, 8PSK, 16QAM, 64QAM, BFSK, CPFSK, 4PAM, WB-FM, AM-SSB, AM-DSB	%12-%88	RadioML201 6.10a
<i>Rajenderen vd., 2018</i>	CNN, LSTM	IQ ham veri grafiği	8PSK, AM-DSB, AM-SSB, BPSK, CPFSK, GFSK, PAM4, QAM16, QAM64, QPSK, WBFM	%90	RadioML201 6.10a

Tablo 1.1. (Devam) Literatürde yer alan sinyal sınıflandırma çalışmaları

<i>Araştırmacı</i>	<i>Algoritma/Mimari</i>	<i>Sinyal Gösterimi/Önişleme</i>	<i>Sınıflar</i>	<i>Sonuçlar</i>	<i>Veri Kümesi</i>
<i>O'Shea vd., 2018</i>	CNN, ResNet	Güç Sönümlenme Detay Görüntüsü	OOK, 4ASK, 8ASK, BPSK, QPSK, 8PSK, 16PSK, 32PSK, 16APSK, 32APSK, 64APSK, 128APSK, 16QAM,32QAM,64QAM,128QAM, 256QAM,AM-SSB-WC,AM-SSB-SC, AM-DSB-WC,AM-DSB-SC,FM,GMSK,OQPSK	ResNet: %4-%100	RadioML20 16.10a
<i>Wu vd., 2018</i>	RNN (LSTM)	IQ ham veri grafiği	3 farklı sınıf ile sınıflandırma (I, Q ve IQ)	%95-%100	Yapay veri
<i>Rajenderen vd., 2019</i>	LSTM	PSD Vektör görüntüleri	4 Farklı Sınıf (Single_cont, single_rshort, mult_cont, det_hop)	%92.8-%100	Sentetik veri
<i>Zha vd., 2019</i>	CNN	I-Göz Diyagram, Q-Göz Diyagram ve Vektör Diyagramı	BPSK; QPSK; OQPSK; 8PSK; 16QAM; 16APSK; 32APSK; 64QAM.	% 94-%99	Yapay Veri

Tablo 1.1. (Devam) Literatürde yer alan sinyal sınıflandırma çalışmaları

<i>Araştırmacı</i>	<i>Algoritma/Mimari</i>	<i>Sinyal Gösterimi/Önişleme</i>	<i>Sınıflar</i>	<i>Sonuçlar</i>	<i>Veri Kümesi</i>
<i>Xiao vd., 2019</i>	CNN	Choi-Williams Dağılımı (CWD)	8 Farklı Sınıf	% 90	
<i>Peng vd. 2019</i>	AlexNet GoogleNet	Yıldızküme Diyagramı	BPSK, QPSK, OQPSK, 8PSK, 16QAM, 32QAM, 32QAM, 64QAM, 4ASK	0dB %74.1-%100 4dB %87.1-%91 10dB %99	RadioML2016.10a
<i>Lee vd., 2019</i>	CNN	Özellik Çıkarımı, Yıldız Diyagramı ve Hiyerarşik	BPSK, QPSK, 8PSK, 4PAM, 16QAM, 64QAM	Özellik Ç. %17-%100 Yıldız Diyagramı %27-%83 Hiyerarşik %18-%68	Yapay Veri
<i>Huang vd., 2019</i>	CNN	Yıldız diyagramı (RCS) ve Grid Yıldız Diyagram (CGCs)	BPSK, QPSK, 8PSK, 16QAM, 64QAM	RCS: %45-%100 CGCs: %46-%100	RadioML2016.10b

Tablo 1.1. (Devam) Literatürde yer alan sinyal sınıflandırma çalışmaları

<i>Araştırmacı</i>	<i>Algoritma/Mimari</i>	<i>Sinyal Gösterimi/Önişleme</i>	<i>Sınıflar</i>	<i>Sonuçlar</i>	<i>Veri Kümesi</i>
<i>Xie vd., 2019</i>	CNN (M2M4)	Yıldız Diyagramı	BPSK, QPSK, OQPSK, 8PSK	%58-%99,8	RadioML2016.10a
<i>Tu vd., 2019</i>	AlexNet	Yıldız Diyagramı	BPSK, 4ASK, QPSK, OQPSK, 8PSK, 16QAM, 32QAM, 64QAM	%82-%95	RadioML2016.10a
<i>Ma vd., 2019</i>	ResNet	Döngüsel Korelasyon Spektrumu (CCES)	BPSK, 2ASK, 8ASK, 4QAM, 16QAM,	%39-%98	-
<i>Li vd., 2019</i>	AlexNet	Bispektrum Grafiği	BPSK, 2ASK, 2FSK, 4FSK, 8FSK, LFM, OFDM	%15-%97,7	RadioML2016.10a
<i>Wang vd., 2019</i>	DNN CNN RNN	Yıldız Diyagram ile oluşturulan 2 farklı görüntü grubu	BPSK, QPSK, 8PSK, GFSK, CPFSK, 4PAM, 16QAM, 64QAM	%43-%96	RadioML2016.10a

Tablo 1.1. (Devam) Literatürde yer alan sinyal sınıflandırma çalışmaları

<i>Araştırmacı</i>	<i>Algoritma/Mimari</i>	<i>Sinyal Gösterimi/Önişleme</i>	<i>Sınıflar</i>	<i>Sonuçlar</i>	<i>Veri Kümesi</i>
<i>Wu vd., 2019</i>	CNN LSTM	Döngüsel Spektrum ve Yıldız Diyagram	BPSK, QPSK, 8PSK, 16QAM, 64QAM, CPFSK, GFSK, 4PAM, WB-FM, AM-SSB, AM-DSB	CNN: %18-%88 LSTM: %18-%90	RadioML2016.10b
<i>Wang vd., 2019</i>	CNN	Zaman-Frekans Görüntüsü ve Korelasyon Görüntüsü	LFM, SF, BPSK, QPSK, 2FSK, 4FSK	%97.1-%99,8	RadioML2016.10a
<i>Zhang vd., 2019</i>	ResNET	SPWVD ve Born-Jordan ile T-F Görüntüsü	BPSK, QPSK, 2FSK, 4FSK, 2ASK, 4ASK, 16QAM, 64QAM, OFDM	%90-%92,5	RadioML2016.10a
<i>Yu vd., 2019</i>	CNN	IQ verisi	-10dB ile 30dB arası 9 farklı SNR değeri için sınıflandırma yapılmıştır.	10dB: %97,5	27 Tİ CC2530 semboller

Tablo 1.1. (Devam) Literatürde yer alan sinyal sınıflandırma çalışmaları

<i>Araştırmacı</i>	<i>Algoritma/Mimari</i>	<i>Sinyal Gösterimi/Önişleme</i>	<i>Sınıflar</i>	<i>Sonuçlar</i>	<i>Veri Kümesi</i>
<i>Huang vd., 2019</i>	LSTM RNN	Yıldız Diyagramı	BPSK, AM-DSB, AM-SSB, BPSK, CPFSK, GFSK, PAM4, QAM16, QAM64, QPSK, WBFM	%12,5-%92	RadioML2016.10a
<i>Elmaghub ve Hamdaoui, 2020</i>	CNN	IQ verisi	8PSK 16QAM	%95	RadioML2016.10a
<i>Kumar vd., 2020</i>	ResNet	Yıldız Yoğunluğu Matrisi	2ASK,4ASK,BPSK, QPSK, 8PSK, 8QAM,16QAM,32 QAM,64QAM	%18-%95,2	RadioML2016.10b
<i>Yang vd., 2020</i>	CNN	Yıldız Diyagram	BPSK, QPSK, 8PSK, 8QAM, 16QAM, 32QAM, 64QAM	%76-%91,4	Yapay veri
<i>Chun-Liu vd., 2020</i>	SVM	ASE(Accelerometer Signal Enhancement)	SisFall ve FallAIID	%97,34 %90,52 %95,92 %87,47	RadioML2016.10a

Tablo 1.1. (Devam) Literatürde yer alan sinyal sınıflandırma çalışmaları

<i>Araştırmacı</i>	<i>Algoritma/Mimari</i>	<i>Sinyal Gösterimi/Önişleme</i>	<i>Sınıflar</i>	<i>Sonuçlar</i>	<i>Veri Kümesi</i>
<i>Li vd., 2021</i>	HRFNet	Choi-Williams Dağılımına (CWD)	Barker, Chaotic, EQFM, Frank, FSK, LFM, LOFM, OFDM, P1 ve P2 olmak üzere 10 sınıf	-6dB: %99,5 14dB: %97,5	GNU Radyo ve Evrensel Yazılım Radyo Çevre Birimlerini ile üretilmiş
<i>Liu vd., 2021</i>	CNN	Choi-Williams (CWD)	BPSK, CW, FSK, FSK-BPSK, LFM LFM-BPSK, NLFM, QPSK	%90	
<i>Zhang vd., 2022</i>	GE2E	IQ verisi	BPSK, QPSK, 8PSK, 8QAM, 16QAM, 32QAM, 64QAM	%95	
<i>Ma vd., 2021</i>	ResNet	Karmaşık Morlet Dalgacık Dönüşümü (Complex Morlet Wavelet Transform-CMWT)	NS, LFM, NLFM, 2PSK, 2FSK, 4PSK, 4FSK	%96,57	

Tablo 1.1. (Devam) Literatürde yer alan sinyal sınıflandırma çalışmaları

<i>Araştırmacı</i>	<i>Algoritma/Mimari</i>	<i>Sinyal Gösterimi/Önişleme</i>	<i>Sınıflar</i>	<i>Sonuçlar</i>	<i>Veri Kümesi</i>
<i>Peng vd., 2022</i>	Derin Öğrenme Mimarileri	Özellik Çıkarımı ve Görüntü Diyagramları	BPSK, QPSK, 8PSK, GFSK, CPFSK, 4PAM, 16QAM, 64QAM	%14-%98	
<i>Xu ve Lin, 2022</i>	CNN, LSTM, ResNet, Hiyerarşik	Frekans-Zaman Dönüşümü	{BPSK + 4QAM, BPSK + 8PSK, BPSK + 16QAM, 4QAM + 8PSK, 4QAM + 16QAM, 8PSK + 16QAM} 6 Sınıf	%17.2-%98,9	RadioML2016.10a
<i>Liu vd., 2022</i>	CNN	Frekans-Zaman Dönüşümü	2FSK, 16QAM, 64QAM, BPSK, MSK, QPSK, 2ASK	%82,7-%93,2	Yapay Veri
<i>Wang vd., 2023</i>	AlexNet, VGG16, CNN, ResNet	Özellik Çıkarımı	BPSK, AM-DSB, 8PSK, PAM4, QAM16, QAM64, QPSK, WBFM, CPFSK	%90	Yapay Veri

Tablo 1.1. (Devam) Literatürde yer alan sinyal sınıflandırma çalışmaları

<i>Araştırmacı</i>	<i>Algoritma/Mimari</i>	<i>Sinyal Gösterimi/Önişleme</i>	<i>Sınıflar</i>	<i>Sonuçlar</i>	<i>Veri Kümesi</i>
<i>Chen vd., 2023</i>	Uç Değer Teorisi- Extreme Value Theory (EVT)	ICS	11 Farklı Sınıf	%90	
<i>Zhang vd., 2023</i>	Açık Küme Tanıma (AMOSR), Bilinen Sınıf Tanımlaması (KCC) ve Bilinmeyen Sınıf Tanımlaması (UCI)	IQ ham sinyal verisi	4 farklı sınıf	%77-%98	RadioML2016.10a
<i>Fan vd., 2023</i>	STFAN, ResNet ve CNN	Ortogonal Frekans Bölmeli Çoğullama- Orthogonal Frequency Division Multiplexing (OFDM) ve Dik Olmayan Çoklu Erişim- Non-Orthogonal Multiple Access (NOMA)	27 farklı sınıfta modülasyon tipi	20dB: %96,6	RadioML2016.10a
<i>Hussein vd., 2023</i>	CNN	Özellik Çıkarımı	11 farklı modülasyon tipi	%99	

Tablo 1.1. (Devam) Literatürde yer alan sinyal sınıflandırma çalışmaları

<i>Araştırmacı</i>	<i>Algoritma/Mimari</i>	<i>Sinyal Gösterimi/Önişleme</i>	<i>Sınıflar</i>	<i>Sonuçlar</i>	<i>Veri Kümesi</i>
<i>Ying vd., 2023</i>	CNN DNN	Yıldız Diyagram	11 farklı modülasyon tipi	0dB: DNN %91	RadioML2016.10a
<i>Cao vd., 2023</i>	MobileNet, VGG ve ResNet	IQ Ham Sinyal Verisi	11 farklı modülasyon tipi	%88	
<i>Talha vd., 2023</i>	Derin Evrişimli sinir ağı (VB-DCNN)	IQ Ham Sinyal Verisi	M-QAM ve M-PSK	%99	
<i>Ying vd., 2023</i>	CNN DNN	Yıldız Diyagram	11 farklı modülasyon tipi	0dB: DNN %91	RadioML2016.10a
<i>Cao vd., 2023</i>	MobileNet, VGG ve ResNet	IQ Ham Sinyal Verisi	11 farklı modülasyon tipi	%88	
<i>Talha vd., 2023</i>	Derin Evrişimli sinir ağı (VB-DCNN)	IQ Ham Sinyal Verisi	M-QAM ve M-PSK	%99	
<i>Gao vd., 2023</i>	CrossTLNet, Geçici Evrişimsel Ağı (TCN) ve LSTM	IQ ve Genlik/Faz formunda birlikte kullanarak dönüşüm	4 farklı modülasyon tipi	SNR \geq 0dB olduğunda %96,55	RadioML.2016.10a.

Tablo 1.1. (Devam) Literatürde yer alan sinyal sınıflandırma çalışmaları

<i>Araştırmacı</i>	<i>Algoritma/Mimari</i>	<i>Sinyal Gösterimi/Önişleme</i>	<i>Sınıflar</i>	<i>Sonuçlar</i>	<i>Veri Kümesi</i>
<i>Zhang vd., 2023</i>	LSTM	PRI Sinyal Dönüşümü	4 farklı modülasyon tipi	%98	
<i>Fang vd., 2023</i>	Çift yönlü Uzun Kısa Süreli Bellek Ağı (Bi-LSTM)	PRI Sinyal Dönüşümü ve Etiket Dönüşümü	4 Farklı Sınıf	+% 4,15	
<i>Neves vd., 2023</i>	UNet, ResNet, RRCNN-1, RRCNN-2 ve RRCNN-3	SAR (Sentetik Açıklıklı Radar) görüntüleri	2 farklı sınıf	%92	

1.4. Tez Çalışmasının Özgünlüğü

RF sinyal verilerinin en kısa süre içerisinde ve en doğru şekilde sınıflandırılarak yayın yapan vericilerin tanımlanması amacıyla gerçekleştirilen bu çalışmada Türkiye Cumhuriyeti Savunma Sanayi Firmasından resmi yazı ile temin edilen çok sayıda gerçek sinyal verileri ile çalışılmıştır. Literatürde yer alan sinyal sınıflandırma çalışmalarında genel olarak tek bir veri kümesi ve tek bir veri seti kullanıldığı tespit edilmiş olup, bu çalışmada diğer çalışmalardan farklı olarak gerek veri sayısı arttıkça mimarilerin performans değerlerinin tepkisini ölçmek, gerekse yanlış sınıflandırılan verilerin sayısını en aza indirmek amacıyla iki farklı veri kümesi kullanılmıştır. Deneysel çalışmalar her bir veri kümesi için dört farklı veri seti (600'lük, 2.000'lik, 20.000'lik ve 120.000'lik) oluşturularak gerçekleştirilmiştir. Yapılan çalışmalar incelendiğinde sinyal sınıflandırma aşamasında genellikle dalga formları kullanılarak oluşturulan görüntüler ile giriş verisi oluşturulduğu tespit edilmiştir. Bu çalışmada ise sinyal sınıflandırma aşamasında algoritmaların/mimarilerin bazılarında hem IQ ham sinyal verileri, hem de dalga formları ile birlikte iki farklı dönüşüm yöntemi uygulanarak (Hilbert Huang Dönüşümü ve Yıldızküme Diyagramı) elde edilen görüntülerin kullanıldığı kombine bir model oluşturulmuştur.

Makine Öğrenmesi ile yapılan çalışmalar incelendiğinde, denetimli öğrenme algoritmalarıyla oluşturulan modellerde ezberleme sorunları ile karşılaşıldığı görülmüştür. Bunun nedeni oluşturulan modelin eğitim veri kümesini ezberlemesi ve bu modelin yeni verileri sınıflandırmadaki başarı oranlarının düşük olmasıdır. Bu gibi dezavantajları göz önünde bulundurularak özellikle de ezberleme sorununun önüne geçebilmek amacıyla geliştirilen modelde denetimsiz öğrenme ile denetimli öğrenme yöntemleri karşılaştırmalı olarak incelenmiştir.

Literatürde yapılmış olan çalışmalarda sınırlı sayıda (1 ya da 2 adet) derin öğrenme mimarisi çeşidi kullanılırken, yapılan tez çalışmasında sınıflandırma işleminde mimarilerin performanslarını ve doğruluk oranlarını kıyaslayarak daha iyi tartışabilmek için son yıllarda yaygın olarak kullanıldığı tespit edilen 3 farklı Derin Öğrenme Mimarisi (AlexNet, ResNet, UNet) dikkate alınmıştır.

Yapılan detaylı araştırma sonucunda Makine Öğrenmesi ve Derin Öğrenme Mimarileri kullanılarak havacılık alanında veri örnekleme yöntemi ile ilgili RF sinyal

sınıflandırmasına yönelik bir çalışmaya rastlanmamıştır. Yapılan bu tez çalışmasının bu alanda yapılacak çalışmalara katkı sağlanacağı öngörülmektedir.



2. MATERYAL VE YÖNTEM

Çalışmanın bu bölümünde sinyal sınıflandırma modelinin geliştirilmesinde kullanılan Makine Öğrenmesi ve Derin Öğrenme materyalleri detaylı bir şekilde açıklanmıştır. Tez çalışmasının amacı kapsamında kullanılan algoritma ve mimariler karşılaştırılarak gerek literatürde, gerekse bu çalışmada kullanılan veri kümeleri hakkında detaylı bilgi verilmiştir.

2.1. Makine Öğrenmesi

Makine Öğrenmesi, karşılaşılan bir problem karşısında makinenin belirli görevleri yerine getirebilmesini sağlayan bilgisayar biliminin bir alt dalıdır. Makine Öğrenmesi algoritmaları, veriler üzerinde eğitilerek tahminde bulunabilen ve verilerden öğrenen sistemlerdir. Makine öğrenmesinde denetimli öğrenme, denetimsiz öğrenme ve pekiştirmeli öğrenme şeklinde tanımlanan üç farklı yaklaşım mevcuttur.

Denetimli öğrenmede ağ ya da algoritma eğitim aşamasında öğrendiklerini test aşamasında tahmin etmek için etiketli verileri kullanır. Eğitimde kullanılacak olan veriler ve sınıflar önceden bilinir. Eğitim sonrası eğitilen ağ, öğrenir ve parametreleri oluşur. Test aşamasında ise oluşan bu parametreler kullanılır.

Denetimsiz öğrenme algoritmalarında, denetimli öğrenme yönteminin aksine, herhangi bir etiketli, sınıflandırılmış veya isimlendirilmiş veri kullanılmaz. Bu tip öğrenme yönteminde algoritma etiketlenmemiş veriler üzerinde çalışarak ve birbirlerine yakın mesafedeki verileri kümeleyerek veriler arasındaki mesafeden ya da özelliklerden ilişkileri tespit eder. Buna ek olarak, denetimsiz öğrenmede hangi giriş verilerinin hangi sınıftan olduğu önceden bilinmez. Denetimsiz öğrenmede, kümeleme, olasılık yoğunluğu tahmini, boyutsallık azaltma gibi birçok teknik bulunmaktadır (Karataş, 2020).

2.1.1. K-En Yakın Komşuluk algoritması

K-En Yakın Komşuluk (KNN: K-Nearest Neighbors) algoritması, denetimli bir öğrenme algoritmasıdır. Diğer Makine Denetimli Öğrenme algoritmalarının aksine, bir eğitim süreci bulunmamaktadır (Zhang vd., 2017). Öncelikle belirlenen bir K değerine göre komşuluk belirlenir. Algoritmada örnek sınıflara en yakın komşu olma özelliği gösteren yeni veriye göre K adet veri seçilir. Etiketli sınıflardan herhangi birine ilave edilecek yeni verilerin birbirlerine uzaklığı, en yakın komşu özelliği gösteren verilerden

alınır ve mesafe hesaplamaları için kullanılır. KNN algoritmasının hiperparametre değerleri sınıf sayısı 6, ağırlık sabit ve uzaklık ölçütü Minkowski'dir.

Mesafe hesaplamasında çeşitli yaklaşımlar kullanılmakla birlikte algoritmanın işlem basamakları aşağıda maddeler halinde özet olarak verilmiştir (Ardila Rey vd., 2013).

1. Veriler girilir.
2. Komşu sayısı K seçilir ve o sayıda komşuyla ilişkilendirilir.
3. Verilerdeki her değer için,
 - a. Sorgu örneği ile mevcut örnek arasındaki mesafe hesaplanır.
 - b. Mesafe ve örnek indeksi sıralı bir koleksiyona eklenir.
4. Sıralı uzaklık ve endeks koleksiyonu mesafelere göre en küçükten en büyüğe doğru artan sırada sıralanır.
5. Sıralanan koleksiyondan ilk K girişi seçilir.
6. Seçili K girişlerinin değerleri alınır.
7. Sınıflandırma sırasında K değerlerinin ortalaması bulunur.
8. K etiketlerinin modu döndürülür.

2.1.2. K-Ortalama Kümeleme algoritması

K-Ortalama Kümeleme, denetimsiz bir öğrenme algoritmasıdır ve günümüzde en yaygın kullanılan kümeleme yöntemlerinden biridir. Makine Öğrenimi alanındaki denetimsiz öğrenme bölümünde kümelemeyi ifade eder. K-Ortalama Kümeleme'nin temel amacı, verilen bir popülasyonu benzer nesnelere aynı grupta toplanıncaya kadar, gruplara veya kümelere parçalamaktır.

K-Ortalama Kümeleme, bir dizi N veri noktasını K gruplarına bölme işlemidir. K-Ortalama Kümeleme algoritmasında öncelikle her bir kümenin merkez noktasını veya ortalamasını göstermek üzere K adet nokta rastgele seçilir. Diğer tüm veri noktaları, bu merkezlere olan uzaklıkları dikkate alınarak en yakın oldukları kümelere atanır. Her bir kümenin ortalama değeri hesaplanır ve yeni küme merkezleri belirlenir. Sonrasında, veri noktalarının yeni merkezlere olan uzaklıkları tekrar hesaplanır. Küme merkezlerinde değişim olmayıncaya kadar algoritma bu işlemi iteratif olarak tekrar eder. Bu çerçevede K-Ortalama Kümeleme, bir veri seti üzerinden belirli sayıda kümeyi (K adet) gruplamak için geliştirilmiş en sade ve basit yöntemdir (Ardila Rey vd., 2013). Bu yöntemin işlem basamakları aşağıda maddeler halinde özet olarak verilmiştir:

- i. Veriler alınarak küme sayısı ve başlangıç kütle merkezleri belirlenir.
- ii. Her veri en uygun gruba atanır ve her atama işleminden sonra atama yapılan K kütle merkezi hesaplanır.
- iii. Yeni oluşan grup geçmişteki grup ile kıyaslanır ve grupta değişim yoksa algoritma sonlandırılır. Aksi takdirde 2. adıma geri dönlür.

Her bir veri kümesi $\{x_1, x_2, x_3, x_4 \dots x_N\}$ olmak üzere, K adet küme sayısı ile N tane verinin $m = m_1, m_2, m_3 \dots m_N$ olacak şekilde kümeye parçalanmasıdır. En yakın noktaların sayısı (β), (2.1) eşitliği ile hesaplanmaktadır (Ardila Rey vd., 2013).

$$\beta_i = \left(\frac{1}{S_j}\right) * \sum_{\pi_i \in S_j} \pi_i \quad (2.1)$$

m_i, s_j 'de bulunan noktaların ortalaması, eşitlik (2.2) ile hesaplanmaktadır.

$$\arg \min s = \sum_{j=1}^K * \sum_{\pi_i \in S_j} \|X_i - m_j\|^2 \quad (2.2)$$

2.2. Derin Öğrenme

Derin Öğrenme, makinelerin özellik çıkarımı, algılama ve öğrenme işlevini yerine getirmesine yönelik geliştirilmiş olan bir tür makine öğrenmesi tekniğidir. Derin Öğrenme, işlem basamaklarını ardışık olarak bir veya birden fazla katman kullanarak gerçekleştirir. Bu süreçte bir katmandan sonra üretilen çıktı bir sonraki katmanın girdisi olur (Karataş, 2020).

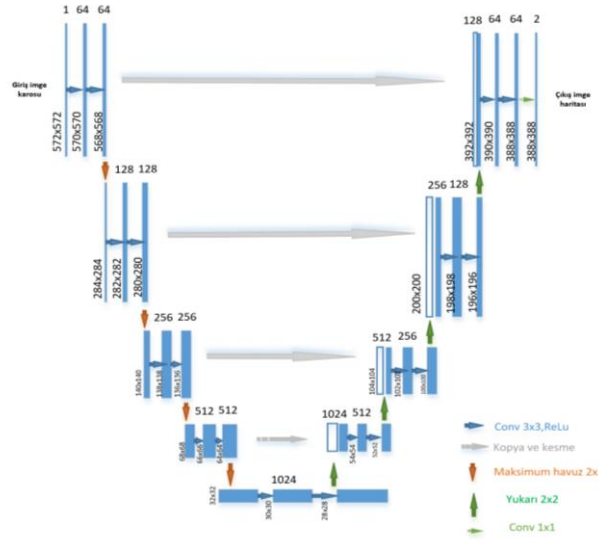
Derin öğrenme ifadesi ilk defa 2000 yılında Igor Aizenberg ve arkadaşları tarafından ifade edilmiştir (Aizenberg vd., 2000). Makinelerin grafik işlem birimi (GPU) hızlarının artmasıyla derin öğrenmede eğitim aşamasının hızlanması mümkün olmuştur. Krizhevsky, Sutskever ve Hinton yaptıkları çalışma ile yeni mimariler tasarlamışlardır (Krizhevsky vd., 2012).

Çalışmanın bu bölümünde yapılan detaylı literatür incelemesi neticesinde son yıllarda yaygın olarak kullanıldığı tespit edilen U-Net, Alex-Net ve ResNet mimarileri ayrı başlıklar altında verilmiştir.

2.2.1. UNet mimarisi

U-Net mimarisi ilk defa Long, Shelhamer ve Darrell tarafından önerilen "tam evrişimli mimari" sözü ile ortaya çıkmış ve günümüzde yaygın olarak kullanılan derin öğrenme mimarilerinden biri olmuştur. U-Net'in diğer mimarilerden farkı, üst örnekleme bölümünde mimarinin içerik bilgisini daha yüksek çözünürlüklü katmanlara dağıtmasına izin veren çok sayıda kanala sahip olmasıdır (Şekil 2.1). Bunun sonucunda, açılan koridor, daralma yoluna simetrik olup U şeklinde bir mimari sağlar. Mimari, tamamen bağlantılı katmanlar olmadan her katmanın yalnızca geçerli kısmını kullanır. (Ronneberger vd., 2015).

U-Net'in yapısı genel olarak sol tarafta bir daralma yolu ve sağ tarafta bir genişleme yolundan oluşmaktadır. Bu mimaride toplamda 23 tane katman bulunmaktadır (Russakovsky vd., 2015).



Şekil 2.1. U-Net mimarisi (Ronneberger vd., 2015)

U-Net mimarisinin eğitimi aşamasında kıvrımlar nedeniyle çıktı görüntüsü, girdiden daha küçük olarak karşımıza çıkmaktadır. İlave yükü en aza indirmek ve bellekten maksimum düzeyde yararlanmak için, toplu resimler yerine tek boyutlu girdiler kullanılmaktadır. Dolayısıyla toplu resimler tek bir görüntüye indirilmektedir. (Ronneberger vd., 2015). Maksimum fonksiyonun hesaplanmasında (2.3) numaralı denklem kullanılır.

$$p_k(x) = \exp(a_k(x)) / \left(\sum_{k'=1}^K \exp(a_{k'}(x)) \right) \quad (2.3)$$

Burada $a_k(x)$ piksel konumunda özellik kanalı 'k' aktivasyonu belirtir. K sınıf sayısıdır ve $p_k(x)$ yaklaşık maksimum fonksiyondur. Ağırlık haritası (2.4) numaralı denklem ile çıkarılır.

$$E = \sum_{x \in \Omega} w(x) \log(pl_x(x)) \quad (2.4)$$

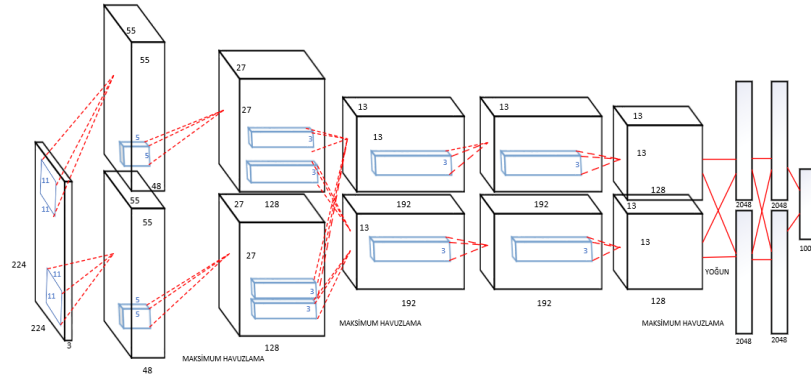
Burada $l : \Omega \rightarrow \{1, \dots, K\}$ olmak üzere w , eğitimde bazı piksellere daha fazla önem vermek için tanımlanan bir ağırlık haritasıdır. Ağırlık haritası hesaplaması denklem (2.5)'de gösterilmiştir.

$$w(x) = w_c(x) + w_0 \cdot \exp\left(-\frac{(d_1(x) + d_2(x))^2}{2\sigma^2}\right) \quad (2.5)$$

Burada $w_c(x)$ sınıf frekanslarını dengelemek için kullanılan ağırlık haritasını, $d_1(x)$ en yakın hücrenin sınırına olan mesafeyi, $d_2(x)$ ise ikinci en yakın hücrenin sınırına olan mesafeyi temsil etmektedir.

2.2.2. AlexNet mimarisi

AlexNet mimarisi yirmibeş katmandan oluşan bir derin öğrenme mimarisidir. AlexNet'in katman yapısı incelendiğinde yatay olarak giriş, normalizasyon, havuzlama (pooling), bırakma (dropout), tam bağlı (full-connected), yumuşak bağlı (SoftMax) ve çıkış şeklinde tanımlanan 7 adet katmandan oluştuğu görülmektedir (Şekil 2.2). Alex Krizhevsky tarafından 2012 yılında geliştirilen bu mimari ile örüntü hata oranının % 26'lardan % 5'lere indiği görülmüştür. Bu mimari genel olarak doğrusal olmayan fonksiyonlar için kullanılmakta olup, eğitim süresi diğer derin öğrenme mimarilerine göre çok daha kısadır. Yapılan çeşitli araştırmalarda bu mimari yapısı içerisindeki bırakma katmanı sayesinde eğitim aşamasında yer alan öğrenme sırasında gecikmelerin engellendiği vurgulanmaktadır (Krizhevsky vd., 2012).



Şekil 2.2. AlexNet mimarisi (Krizhevsky vd., 2012).

AlexNet imgenin her bir pikseli katmanlara aktarılarak hafızaya alınmakta ve bir sonraki aşamaya geçilmektedir. Bu şekilde mimari en yakın değerleri, eski hafıza değerleri ile kontrol ederek öğrenme işlemini gerçekleştirir (Krizhevsky vd., 2012).


2.2.3. ResNet mimarisi

ResNet, önemli ölçüde daha derin olan mimarinin eğitimini kolaylaştırmak için örüntü tanıma ve görüntü sınıflandırma gibi problemlerde son teknoloji sonuçlar elde etmeye yarayan bir sinir ağı türüdür. ResNet ağında daha az filtre ve daha düşük karmaşıklığa sahip 34 katmanlı düz bir ağ mimarisi kullanılmaktadır. ResNet mimarisinin formülasyonu (2.6) ve (2.7) eşitliklerinde gösterilmiştir.

$$H(x) = f(wx + b) \quad (2.6)$$

$$H(x) = f(x) + x \quad (2.7)$$

Burada w , katmana özgü ağırlık katsayısını b , eklenen ön yargı terimini ve H çıktıları temsil etmektedir. Eşitlikten de anlaşılacağı üzere ResNet mimarisinde ‘ x ’ adet girdi katmanının ağırlık katsayıları ile çarpılır ve daha sonra bir ön yargı terimi eklenir. Ardından $f(...)$ aktivasyon fonksiyonundan geçer ve çıktı $H(x)$ olarak alınır. ResNet mimarisinin blok şeması Şekil 2.3’de verilmiştir (Russakovsky vd., 2015).



Şekil 2.3. ResNet Mimarisi (Russakovsky vd., 2015).

2.3. RF Sinyal Verileri

Sınıflandırma çalışmalarının en önemli aşamalarından birisi verilerin temini ve veri kümelerini elde edilmesi ve oluşturulmasıdır. Bu kapsamda çalışmanın amacına uygun ve yeterli sayıda gerçek veri temin etmek genellikle bilimsel araştırmalarda zorlu bir aşama olarak değerlendirilebilir. Bu nedenle genellikle pek çok araştırmada araştırmacılar tarafından deneysel ortamda üretilen verilerin tercih edildiği görülmektedir. Temin edilen verilerin boyutlarının büyük olması uzun işlem sürelerine ve işlem kalabalığına yol açmaktadır. Ayrıca heterojen dağılmamış bir veri kümesi ile yapılan deneyler ve analizlerde elde edilen sonuçlar düşük doğruluk oranı vermektedir (Karataş, 2020).

Tez çalışmasında geliştirilen bir modelin doğruluk değerinin düzgün bir şekilde hesaplanabilmesi için veri kümesinde yer alan verilerin heterojen yapısının formüle dayalı bir hesapla sağlanması gerekmektedir. Bu çerçevede homojen dağılım oranı hesaplama denklemi (2.8)'de verilen eşitlik bulunur (Karataş, 2020).

$$\beta = \left(\frac{\max_i[w]}{\min_i[w]} \right) \quad (2.8)$$

Burada β homojen dağılım oranını w , i sınıfındaki veri boyutunu, maksimum sınıf örnek sayısı ile minimum sınıf örnek sayısı arasındaki oran ise homojen dağılım oranını verir.

Normalizasyon işlem süresini kısaltarak hesapsal maliyeti en aza indirmek amacıyla çok büyük sayısal değerlerin 0 ile 1 arasında sıralanması işlemidir. Normalizasyon işlemi için kullanılan eşitlik aşağıda verilmiştir (Karataş, 2020).

$$\text{Normalizasyon} = x_n = \left(\frac{x - x_{\min}}{\max - \min} \right) * 0,8 + 0,1 \quad (2.9)$$

Burada x_n normalizasyon uygulanmış değeri, x gerçek değeri, x_{min} değerler arasında en küçük olanı, x_{max} ise değerler arasında en büyük olanı temsil etmektedir.

2.4. Zaman-Frekans Dönüşümleri ve Öznitelik Çıkarma

Sınıflandırma işleminin genel yapısı içerisinde bahsedildiği üzere öncelikle verilerin algoritma veya mimariler tarafından tanınabilmesi için haritalarının veya görüntülerinin çıkarılması ve bu kapsamda da bir takım dönüşüm işlemlerinin uygulanması gerekmektedir. Gerek Makine Öğrenmesi, gerekse Derin Öğrenme ile gerçekleştirilecek olan sınıflandırma işlemlerinde, toplanan ya da üretilen sinyal verilerinin giriş verisi olarak kullanılması için son yıllarda zaman-frekans dönüşümlerinden Hilbert-Huang (HH) Dönüşümünün, modülasyonlu sinyallerin görüntülerinin oluşturulması için ise Yıldızküme Diyagramının (YD) ve sinyallerin diyagram görüntülerinden öznitelik çıkarımı için de Mutlak Ortalama (MO) yönteminin yaygın bir şekilde kullanıldığı görülmektedir. Dönüşüm işlemlerinde kullanılan bu yöntemler ayrı başlıklar altında incelenmiştir.

2.4.1. Hilbert-Huang dönüşümü

Hilbert-Huang Dönüşümü, Alman matematikçi David Hilbert'in matematik, fizik ve felsefe alanlarında yapmış olduğu çalışmalarla ortaya konan bir yöntemdir. David Hilbert, Hilbert uzayı formüllerini geliştirerek fonksiyonel analizin temel taşlarından birini oluşturmuştur. Değişmezlik teorisi ve geometrinin aksiyomları adlı çalışmalarıyla modern matematik ve matematiksel fizik konularına çok ciddi gelişmeler sağlamıştır. Hilbert aynı zamanda ispat teorisi ve matematiksel mantığın mucitlerinden biri olarak tanınmaktadır (Weyl, 1944).

Günümüzde yaygın olarak tercih edilen yöntemlerden biri olan HH dönüşümü, Riemann – Hilbert probleminin çalışmaları sırasında ortaya çıkmıştır. Daha sonra 1948 yılında Titchmarsh tarafından Cauchy yaklaşımı ile integral formuna dönüştürülmüş ve konvolüsyon teoremine eklenerek işaret işleme biliminde önemli bir konuma gelmiştir. 1962 yılında Bedrossian teoremi ile HH dönüşümü, çarpım formuna getirilerek haberleşme biliminde yaygın olarak kullanılmaya başlamıştır.

HH dönüşümü orijinal bir sinyal $x(t)$ için $-\infty < t < \infty$ aralığında tanımlanan gerçek değerli $x'(t)$ ile Denklem (2.10)'daki gibi ifade edilmektedir.

$$x'(t) = H \{x(t)\} = \int_{-\infty}^{\infty} \frac{x(\tau)}{\pi(t-\tau)} dt \quad (2.10)$$

Bu eşitlikte $H \{.\}$ HH Dönüşümüne, τ kaydırma operatörüne karşı gelmektedir. Bir sinyalin HH dönüşümü yapılırken, orijinal sinyalden 90° faz kaydırılmış bir ortogonal sinyal üretilmektedir (Manjula vd., 2013), (Ktonas ve Papp, 1980).

$x(t)$ sinyali için Picibono tarafından tanımlanan analitik form Denklem (2.11)'de verilmiştir (Karasu ve Saraç, 2020).

$$z_x(t) = x(t) + jx'(t) dt \quad (2.11)$$

HH dönüşümü yapısının uygun olduğu şekilde uygulandığı işarete 90° faz farkı ile karmaşık bir bileşen ekleyerek, işaretin faz bilgisinin kestirilmesini sağlamaktadır.

2.4.2. Yıldızküme diyagramı

Yıldızküme Diyagramı, sinyal örneklerini karmaşık bir düzlemde saçılma noktalarına eşleyen ve yaygın olarak kullanılan 2 boyutlu bir görüntüdür. Sinyal modeli denklem (2.12)'de gösterilmiştir.

$$r(n) = s(n) + y(n) \quad (2.12)$$

Burada $r(n)$ temel sinyali, $y(n)$ gürültü eklenmiş sinyali, $s(n)$ ise toplanmış sinyali temsil etmektedir.

$$s(n) = K e^{i(2\pi f_0 nT + \theta_n)} \sum_{j=-\infty}^{\infty} s(j) h(nT - jT + \epsilon_T T) \quad (2.13)$$

Burada $s(j)$ giriş sembolünü, M yıldız değerini, K sinyal genliğini, f_0 frekansı, T ara uzaklığı, θ_n sembolden sembole değişen faz titreşimini, $h(...)$ kanal etkisini ve ϵ_T zamana karşı faz titreşimini göstermektedir.

Modülasyonlu sinyaller gönderildiği alanlarda gürültü altında bulunurlar. Çevrede bulunan sinyal toplayıcıları, modülasyonlu sinyali gürültülü hali ile toplarlar. Bu kapsamda sinyali gürültüden arındırmak için demodülasyon işlemi gerçekleştirilmeli ve sinyale eklenecek AWGN'yi (Additive White Gaussian noise) araştırmak gerekir. Bu belirtilen yapıda bulunan kanal sadece geçen sinyale gürültü ekleme işlemi yerine getirmektedir (Güner ve Kaya, 2013).

2.4.3. Mutlak ortalama öznitelik çıkarımı

Sinyalde öznitelik çıkarımı, belirtilen sinyali en iyi şekilde anlatan sayısal bir değerdir. Literatürde öznitelik çıkarma işlemi için çok farklı yöntemler bulunmaktadır. Bir öznitelik çıkarımı çeşidi olan mutlak ortalama, sinyalin sayısal değerinin mutlak ortalaması alınarak bulunur. S_k ($k=1,2,\dots,N$), N sayıdaki örneğe sahip bir sinyalin Mutlak Ortalama değeri denklem (2.14)'de ki eşitlik ile tespit edilir (Abbasoğlu 2019).

$$MO = \frac{1}{N} \sum_{k=1}^N |s_k| \quad (2.14)$$

2.5. Makine Öğrenmesi ve Derin Öğrenme Mimarisinin Karşılaştırılması

Günümüzde sınıflandırma çalışmalarında gerek Makine Öğrenmesi, gerekse Derin Öğrenme yaygın bir şekilde kullanılmakta olup, aralarındaki en temel fark algoritma performansları olarak görülmektedir. Bu kapsamda literatürde yapılan sınıflandırma çalışmalarından elde edilen bulgular ışığında iki yöntem arasındaki farklar aşağıda maddeler halinde verilmiştir.

- Makine öğrenmesi az veri ile de iyi sonuçlar verirken, Derin Öğrenme için büyük miktarda eğitim verisine ihtiyaç duyulmaktadır. Dolayısıyla veri sayısı arttıkça elde edilen sonuçlarda iyileşme oranı da artar.
- Derin Öğrenme ile daha hızlı sonuç elde edilebilirken, Makine Öğrenmesinde çalışma süresi bir miktar uzun olabilir.
- Makine Öğrenmesinde veri boyutu çok önemli değildir. Fakat Derin Öğrenmede veri boyutu önemlidir.
- Makine Öğrenmesinde çözülmek istenen problem parçalara bölünür ve bu parçalar çözülerek, elde edilen çözümler sonucunda genel problemin çözümü oluşturulurken, Derin Öğrenmede problem baştan uca doğru çözülür.
- Makine Öğrenmesinde özellikler kullanıcı tarafından belirlenirken, Derin Öğrenmede kullanılan verilerden özellikler çıkarmaya çalışır.
- Makine Öğrenme algoritmaları sıradan bilgisayarlar ile çalışabilirken, Derin Öğrenme mimarileri ise yüksek performanslı sunuculara ya da iş istasyonlarında çalışmaktadır.

- Makine Öğrenmesinde eğitimler birkaç saniye ile birkaç saat arasında değişen kısa zamanlarda tamamlanırken, Derin Öğrenme mimarileri birçok katman içerdiği için eğitim aşaması daha uzundur.
- Makine Öğrenmesinde çıkış verisi sınıflandırma ya da sayısal değer olabilirken, Derin Öğrenmede sınıflandırma, görüntü, ses vb. gibi birçok yapıda olabilir (Karataş, 2020).

2.6. Sınıflandırmada Kullanılan Performans Metrikleri

Makine Öğrenmesi ve Derin Öğrenmede mimarilerin/algorithmaların performans ölçümü, oluşturulan modelin doğruluğunu ve veri uyumunu belirleyerek, mimarilerin/algorithmaların ne kadar etkili olduğunun anlaşılmasına yardımcı olur. Bununla birlikte performans ölçümü çalışılan modellerin gerçek dünya şartlarında ne kadar yüksek performans gösterdiğini belirler. Performans ölçümleri bazı metrikler ile gerçekleştirilir. Bu kapsamda Doğruluk (Accuracy), Hassasiyet (Precision), Geri Çağırma (Recall/Sensitivity), F1-Skoru (F1-Score), ROC Eğrisi ve AUC (Receiver Operating Characteristic Curve and Area Under the Curve), Karmaşıklık Matrisi (Confusion Matrix), ROC-AUC eğrisi ve Matthews Correlation Coefficient (MCC) bu metriklere örnek olarak verilebilir (Karataş, 2020). Performans ölçümünde kullanılan bu metriklerden bazıları aşağıda açıklanmıştır.

Doğruluk; veri kümelerinde kullanılan test verilerinin, mimarinin/algorithmanın eğitimi sonucunda elde edilen doğru tahminler ile oranlanması sonucu ortaya çıkan değerdir. Elde edilen doğruluk değerinin, kümede bulunan toplam veri sayısına oranı ise ortalama doğruluk değerini verir. Doğruluk değerinin hesaplanmasında kullanılan eşitlik (2.15) aşağıda verilmiştir (Sokolova ve Lapalme, 2009).

$$\text{Doğruluk} = \left(\frac{RP_j + RN_j}{RP_j + FN_j + FP_j + RN_j} \right) \quad (2.15)$$

Burada RP_j doğru pozitif sayısını, RN_j doğru negatif sayısını, FN_j yanlış negatif sayısını ve FP_j 'de yanlış pozitif sayısını temsil etmektedir.

Hassasiyet; sınıflandırmada kullanılan mimarinin/algorithmanın veri kümeleri ile yapılan deneysel işlemlerde ne kadar sınıfı doğru bir şekilde tahmin ettiği hassasiyet denklemi ile bulunur. Hassasiyetin değerinin hesaplanmasında kullanılan Eşitlik (2.16)'da verilmiştir (Vakilli vd. 2020).

$$Hassasiyet = \sum_{j=1}^M \left(\frac{RP_j}{RP_j + FP_j} \right) \quad (2.16)$$

Geri Çağırma; sınıflandırma işleminde mimarinin/algorithmının pozitif sınıflarından kaç adetini doğru bir şekilde tahmin ettiği, geri çağırma denklemi ile hesaplanmaktadır. Geri çağırma metriğinde hesaplanmasında kullanılan Eşitlik (2.17) verilmiştir (Vakilli vd. 2020).

$$Geri \text{ Çağırma} = \sum_{j=1}^M \left(\frac{RP_j}{RP_j + FN_j} \right) \quad (2.17)$$

F1-Skor; sınıflandırma işleminde F1-Skor değeri, hassasiyet ve geri çağırma metriğinin ortalaması alınarak hesaplanır. F1-Skor ölçüsü Eşitlik (2.18) ile hesaplanmaktadır. Hesapta kullanılan α , dengelleyci faktördür (Vakilli vd. 2020).

$$F1 - Skor = \frac{(\alpha^2 + 1) \text{ Hassasiyet} \times \text{Geri Çağırma}}{(\alpha^2) \text{ Hassasiyet} \times \text{Geri Çağırma}} \quad (2.18)$$

Karmaşıklık Matrisi; modelin/mimarinin performansını değerlendirmek için kullanılan ve görsel olarak sunulan hesaplamalar gerçekleştirilir ve ölçüm sonuçları elde edilir. Bu ölçümler doğruluk, hassasiyet, geri çağırma (Recall) ve F1-Score formülleriyle sağlanır. Ölçümler sonucunda elde edilen değerler ile mimari/algorithmının performans ölçümleri daha sağlıklı yapılmaktadır. İkili sınıflandırma için oluşturulan örnek karmaşıklık matrisi Şekil 2.4’de gösterilmiştir (Vakilli vd. 2020).

		<u>Gerçek</u>	
		Pozitif	Negatif
<u>Tahmin</u>	Pozitif	RP _j	FP _j
	Negatif	FN _j	RN _j

Şekil 2.4. İkili sınıflandırma için karmaşıklık matrisi (Vakilli vd. 2020).

Burada RP_j doğru pozitif sayısını, RN_j doğru negatif sayısını, FN_j yanlış negatif sayısını ve FP_j 'de yanlış pozitif sayısını temsil etmektedir (Vakilli vd. 2020).



3. GELİŞTİRİLEN SİNYAL SINIFLANDIRMA MODELİ

Bu çalışmada belirli bir bölge içerisinde yer istasyonlarından toplanan çok sayıda RF sinyallerinin gözle takibinin çok zor olması nedeniyle, bir makine yardımıyla en kısa süre içerisinde ve en doğru bir şekilde sınıflandırılarak yayın yapan RF kaynaklarının kimliklendirilmesi için derin öğrenme ve makine öğrenmesi tabanlı bir model geliştirilmesi amaçlanmıştır. Çalışma kapsamında geliştirilen sinyal sınıflandırma modeli ile veriler ön işlemden geçirilmiş ve çeşitli dönüşümler uygulanarak sınıflandırma aşamasına gelinmiştir.

Veri kümelerinin işlenmesi, sayısal ifadelerin görüntüye çevrilmesi, Makine Öğrenmesi ve Derin Öğrenme yardımıyla sınıflandırma işlemlerinin uygulanması için MATLAB programı ve araç kutusu kütüphanesinden yararlanılmıştır. Literatürde yer alan çalışmalardan elde edilen bulgular ışığında gerek makine öğrenmesi, gerekse derin öğrenme algoritmaları ile ayrı ayrı yapılan sınıflandırmada doğruluk oranlarının düşük kalabildiği görülmektedir. Bu sebeple çalışmada Makine öğrenmesine (K-Ortalama Kümeleme ve K-En Yakın Komşuluk) alternatif olarak son yıllarda çalışmalarda yaygın bir şekilde kullanılan 3 farklı derin öğrenme mimarisi (UNet, AlexNet ve ResNet) kullanılarak elde edilen sonuçların kendi aralarında karşılaştırılması gerçekleştirilmiştir.

Yapılmış olan Makine ve Derin Öğrenme çalışmaları incelenip, bu tez kapsamında çözülmesi hedeflenen probleme ve benzer problem tiplerine en uygun yeni bir model tasarlanmıştır. Çalışmanın bu bölümünde geliştirilen modelin veri ön işleme, modelin geliştirme ortamı ve kullanılan veri kümelerinin hazırlanması detaylı bir şekilde açıklanmıştır.

3.1. Veri Ön İşleme

Çalışmada kullanılan veri, Türkiye Cumhuriyeti Savunma Sanayi Kuruluşu'ndan temin edilen ve Türkiye'nin Ege Bölgesi'nde sabit olarak kurulu olan istasyonlar aracılığıyla toplanan 2020-2021 yılları Mayıs-Haziran-Temmuz aylarına ait verilerdir. Elde edilen veriler incelendiğinde verilerin hangi tip cihazlardan toplandığı bilgisinin etiketli bir şekilde olduğu görülmüştür. Bu kapsamda veri paketinde yer alan veri tanımlaması Tablo 3.1'de gösterilmiştir.

Tablo 3.1. Veri paketinde yer alan veriler

Veri	Etiket Bilgisi	Frekansı	Gücü
GSM	Tip-1	811 MHz	
	Tip-2	791 MHz	
	Tip-3	801 MHz	
	Tip-4	832 MHz	
Radar	Tip-1	8000-12000 MHz (X Bandı)	
	Tip-2	2000-4000 MHz (S Bandı)	
	Tip-3	3.7-4.2 GHz (CBandı)	
	Tip-4	1-2 GHz (L Bandı)	
Jammer	Tip-1	950-960 MHz	10 W
	Tip-2	1880-1890 MHz	20 W
	Tip-3	3210-3300 MHz	30 W
	Tip-4	4187-4500 MHz	40 W
Telsiz	Tip-1	30-300 MHz (VHF Bandı)	
	Tip-2	3-30 MHz (HF Bandı)	
	Tip-3	300-3000 MHz (UHF Bandı)	
	Tip-4	30-300 KHz (LF Bandı)	
Diğer	Tip-1	Radyolar	
	Tip-2	Wmax	
	Tip-3	TV	
	Tip-4	Uydu	


Bir veri tabanında tutulan bu verilerin Makine Öğrenmesi Algoritmaları ve Derin Öğrenme Mimarileri ile uyumlu bir şekilde çalışabilmesi için öncelikle birtakım ön işlemlerden geçirilmeleri gerekmektedir. Bu kapsamda tasarlanan Hilbert-Huang Dönüşümü ve Yıldızküme Diyagramı işlemleri alt başlıklarda detaylı bir şekilde açıklanmıştır.

3.1.1. Hilbert-Huang dönüşümü ile veri ön işleme

RF kaynaklarından toplanan sinyallerin giriş verisi olarak kullanılabilmesi dolayısıyla mimari ve algoritmalar tarafından tanımlanabilmeleri için öncelikle uygun görüntü örneklerinin oluşturulması gerekmektedir. Bu kapsamda kullanılan Hilbert Huang Dönüşümü ile zaman-frekans görüntülerinin elde edilebilmesi için uygulanan işlem adımları aşağıda sırasıyla verilmiştir.

- Sinyallerin örnek görüntülerini elde edebilmek için gerçek sayısal veriler kullanılarak öncelikle tek boyutlu IQ sinyal ham verileri ile 28x28 formatında dalga formları oluşturulmuştur.
- Oluşturulan formlar, durağan olduğu varsayılan 128 msn'lik parçalara bölünmüştür. Sinyal üzerinde 25 msn'lik zaman dilimleriyle kaydırma yapılarak bölümler alınmıştır.
- Radar, GSM, Telsiz, Jammer ve Diğer cihazların Tip-1, Tip-2, Tip-3 ve Tip-4 olarak tanımlanan dörder tipi için toplamda 20 farklı görüntü elde edilmiştir.
- Algoritma ve mimarilerin performanslarının veri sayısı ile değişimini gözlemlemek için 600, 2000, 20.000 ve 120.000'lik veri setleri oluşturulması amaçlanmıştır. Bu doğrultuda belirlenen 4 veri seti elde edilen 20 farklı görüntü üzerinde 1 msn aralıklarla kaydırma yapılarak (600'lük veri seti için 30'ar, 2.000'lik veri seti için 100'er, 20.000'lik veri seti için 1.000'er ve 120.000'lik veri seti için 6.000'er) oluşturulmuştur.

Hilbert Huang Dönüşümü ile elde edilen GSM Tip-1 görüntüsü Şekil 3.1'de örnek olarak gösterilmiştir. Frekans zaman ekseninde verilen grafikte maviden sarıya doğru renk geçişleri görülmektedir. Bu renk geçişi maviden sarıya doğru gittikçe frekansın arttığını simgelemektedir. Elde edilen görüntülerdeki renk kontrastları mimarinin eğitim aşamasında görüntüyü ayırt etmesinde, test aşamasında ise sınıflandırma başarısının artmasında oldukça önemli bir etkidir.



Şekil 3.1. HH dönüşümü ile oluşturulmuş GSM Tip-1 örnek görüntüsü

Verilerde bulunan orijinal etiketlerin çok uzun olması sebebiyle deneysel çalışmalar esnasında mimaride karışıklığa yol açmamak için her bir sınıfa etiket olarak yeni bir rakam atanmıştır. Yeni etiket bilgileri Tablo 3.2’de gösterilmiştir.


Tablo 3.2. Cihaz tiplerine göre sınıflara atanan rakamlar

<i>Cihaz Tipi</i>	<i>Etiket</i>	<i>Cihaz Tipi</i>	<i>Etiket</i>	<i>Cihaz Tipi</i>	<i>Etiket</i>	<i>Cihaz Tipi</i>	<i>Etiket</i>
Radar Tip-1	0	GSM Tip-2	5	Telsiz Tip-3	10	Jammer Tip-4	15
Radar Tip-2	1	GSM Tip-3	6	Telsiz Tip-4	11	Diğer Tip-1	16
Radar Tip-3	2	GSM Tip-4	7	Jammer Tip-1	12	Diğer Tip-2	17
Radar Tip-4	3	Telsiz Tip-1	8	Jammer Tip-2	13	Diğer Tip-3	18
GSM Tip-1	4	Telsiz Tip-2	9	Jammer Tip-3	14	Diğer Tip-4	19

3.1.2. Yıldızküme diyagramı ile veri önileme

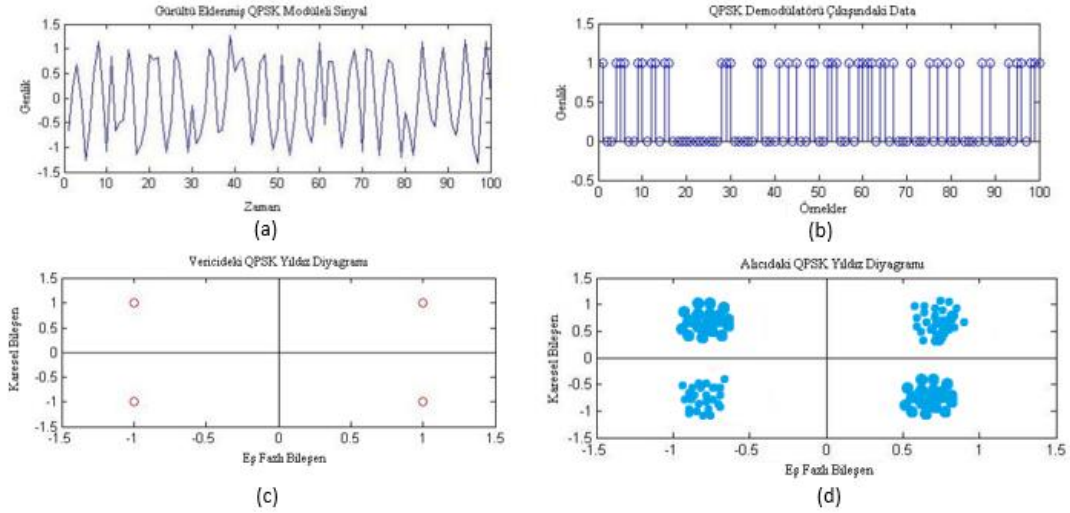
Çalışmada kullanılmak üzere temin edilen sinyal verileri incelendiğinde içerisinde BPSK, QPSK, 4-QAM, 16-QAM16 ve 32-QAM olarak tanımlanan beş çeşit modülasyonlu sinyallerin yer aldığı tespit edilmiştir. Makine Öğrenmesi Algoritmalarının ve Derin Öğrenme Mimarilerinin görüntü tabanlı olması nedeniyle etiketli olarak gelen modülasyonlu verilerin görüntüsünü elde edebilmek için yıldızküme diyagramı kullanılarak ön işleme uygulanması gerekmektedir. Bu kapsamda QPSK modülasyonu için yıldızküme diyagramının oluşturulması örnek olarak ele alınmıştır.

Ham olan sinyale QPSK Modülasyonu işlemi gerçekleştirmek için öncelikle 2 bitlik sinyaller kullanılmaktadır. Giriş sinyali, QPSK modülatörüne gönderilmektedir. İlave olarak da 2 bitlik giriş sinyali, ayırıcıya gönderilmekte, biri I kanalına, diğeri ise Q kanalına yönlendirilmektedir. I kanalı gelen biti, referans olarak aldığı osilatörün fazına göre modüle etmektedir. Diğer tarafta Q kanalına giden biti taşıyıcıyla karesel formda veya fazı açısının 90° döndürülmesi sonucu taşıyıcı sinyali modüle etmiş olur. Sinyalin üstüne gürültü bindirilmekte ve demodülasyon işlemine tutulmaktadır. I ve Q kanalı için farklı olarak demodülasyon işlemi uygulanmaktadır (Türkyılmaz vd., 2012) (Zorlu vd., 2012).



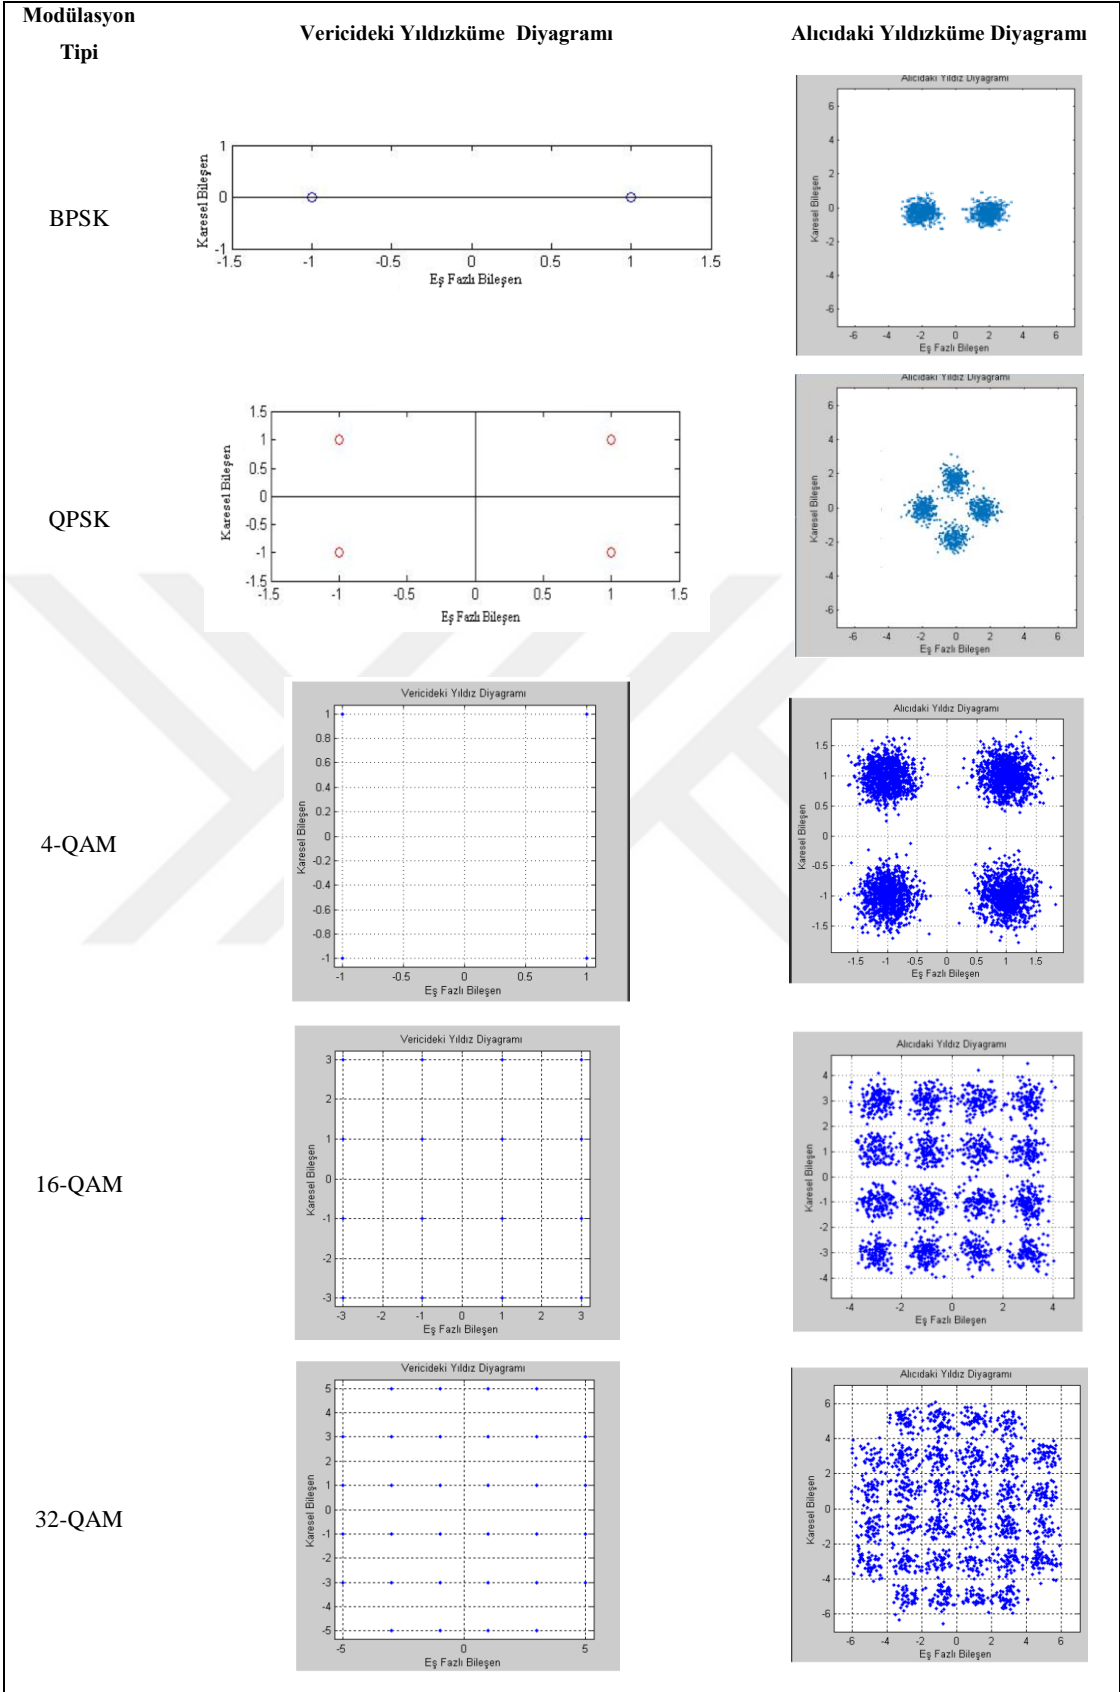
Şekil 3.2. İkili giriş sinyali gösterimi (Türkyılmaz vd.,2012)

Gerçekleştirilmekte olan QPSK demodülasyonunda orjin noktası 0 olarak alınmaktadır. 0'dan büyük olan değerler için çıkış 1, küçük olan değerler için ise çıkış 0 olarak baz alınır. Bu işlem I ve Q kanalları için tek tek yapılarak elde edilen çıkış birleştirilir ve alıcıya gönderilmektedir. Sürecin detaylı gösterimi Şekil 3.3'te verilmiştir (Zorlu vd., 2012).



Şekil 3.3. QPSK Yıldızküme diyagramı gösterimi süreçleri ((a) QPSK tekniği ile modüle edilmiş ve gürültü eklenmiş sinyal, (b) Demodülasyon sonucu elde edilen sinyal, (c) Vericideki QPSK yıldızküme diyagramı, (d) Alıcıdaki QPSK yıldızküme diyagramı) (Türkyılmaz vd.,2012)

Temin edilen veriler içerisinde etiketli olarak yer alan BPSK, 4-QAM, 16-QAM ve 32-QAM modülasyonlu sinyaller içinde benzer süreçler yürütülerek yıldızküme diyagramları oluşturulmuştur. Tüm modülasyonlu sinyal verileri için elde edilen yıldızküme diyagramı görüntüleri Şekil 3.4'te verilmiştir.



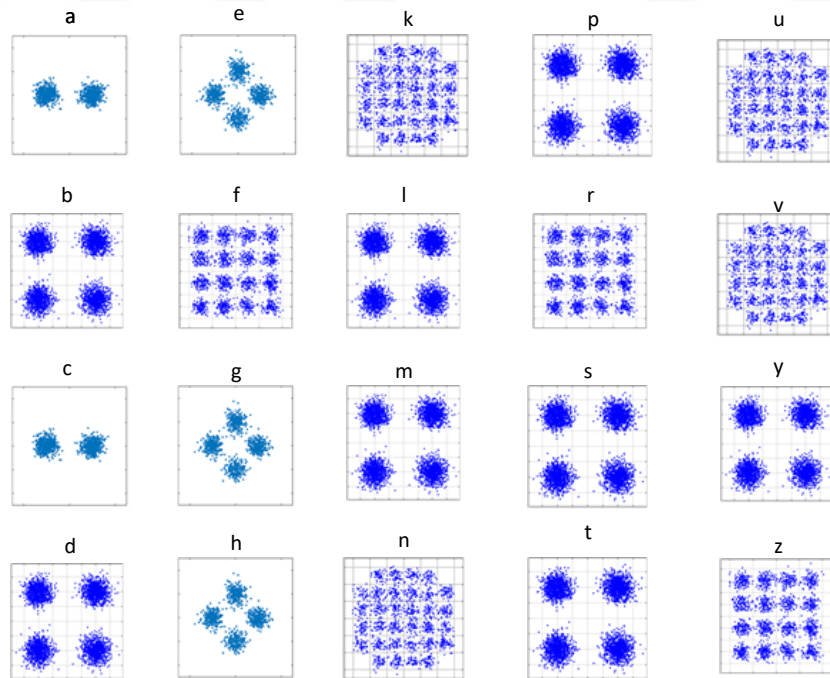
Şekil 3.4. BPSK, QPSK, 4-QAM, 16-QAM ve 32-QAM modülasyonlu sinyal verileri için Yıldızküme diyagramı görüntü örnekleri (Türkyılmaz vd.,2012)

Verilerde bulunan orijinal etiketlerin çok uzun olması sebebiyle deneysel çalışmalar esnasında hem mimaride karışıklığa yol açmamak hem de işlem süresinin uzamasını engellemek amacıyla Radar, GSM, Telsiz, Jammer ve Diğer olarak tanımlanan cihaz tipleri daha kısa etiketlerle yeniden etiketlenmiştir. Harf ataması şeklinde gerçekleştirilen etiketleme işlemi Tablo 3.3’de gösterilmiştir.

Tablo 3.3. Cihaz tiplerine göre sınıflara atanan harfler

Cihaz Tipi	Etiket	Cihaz Tipi	Etiket	Cihaz Tipi	Etiket	Cihaz Tipi	Etiket
Radar Tip-1	a	GSM Tip-2	f	Telsiz Tip-3	m	Jammer Tip-4	t
Radar Tip-2	b	GSM Tip-3	g	Telsiz Tip-4	n	Diğer Tip-1	u
Radar Tip-3	c	GSM Tip-4	h	Jammer Tip-1	p	Diğer Tip-2	v
Radar Tip-4	d	Telsiz Tip-1	k	Jammer Tip-2	r	Diğer Tip-3	y
GSM Tip-1	e	Telsiz Tip-2	l	Jammer Tip-3	s	Diğer Tip-4	z

Her bir cihaz tipi için oluşturulan Yıldızküme diyagramları Şekil 3.5’te gösterilmiştir.



Şekil 3.5. Yıldızküme diyagramı kullanılarak oluşturulan sınıfların etiketleri

3.2. Veri Kümeleri Oluşturma

Çalışmanın bu bölümünde önerilen sinyal sınıflandırma modelinin analizinde kullanılan iki farklı veri kümesi detaylı bir şekilde anlatılmıştır. Herbir veri kümesi hazırlık aşamasında öncelikle 600, 2000, 20.000 ve 120.000 olacak şekilde dört farklı veri setine ayrılmıştır. Daha sonra da oluşturulan veri setleri kendi içerisinde rastgele karıştırılmıştır.

3.2.1. Hilbert-Huang dönüşümü ile oluşturulan I. veri kümesi

Hilbert Huang Dönüşümü ile veri ön işleme aşamasında açıklandığı üzere algoritma ve mimarilerin performanslarının veri sayısı ile değişimini gözlemlemek için 600, 2000, 20.000 ve 120.000'lik veri setleri oluşturulması amaçlanmıştır. Bu doğrultuda belirlenen 4 veri seti elde edilen 20 farklı görüntü üzerinde 1 msn aralıklarla kaydırma yapılarak oluşturulmuştur. Her bir veri setinde kullanılan verilerin % 70'i eğitim, % 30'u ise test verisi olarak atanmıştır. I. Veri kümesinde bulunan 600, 2.000, 20.000 ve 120.000 adetlik veri setleri için eğitim ve test aşamasında kullanılan örnek sayıları sırasıyla Tablo 3.4, Tablo 3.5, Tablo 3.6 ve Tablo 3.7'de gösterilmiştir.

Tablo 3.4. I. Veri kümesi için etiket bilgileri ve 600'lük veri setinde yer alan toplam örnek sayıları

<i>Etiket</i>	<i>Eğitim Aşaması Örnek Sayısı</i>	<i>Test Aşaması Örnek Sayısı</i>	<i>Toplam Örnek Sayısı</i>
<i>0</i>	21	9	30
<i>1</i>	21	9	30
<i>2</i>	21	9	30
<i>3</i>	21	9	30
<i>4</i>	21	9	30
<i>5</i>	21	9	30
<i>6</i>	21	9	30
<i>7</i>	21	9	30
<i>8</i>	21	9	30
<i>9</i>	21	9	30
<i>10</i>	21	9	30
<i>11</i>	21	9	30
<i>12</i>	21	9	30
<i>13</i>	21	9	30
<i>14</i>	21	9	30
<i>15</i>	21	9	30
<i>16</i>	21	9	30
<i>17</i>	21	9	30
<i>18</i>	21	9	30
<i>19</i>	21	9	30

Tablo 3.5. I. Veri kümesi için etiket bilgileri ve 2000'lik veri setinde yer alan toplam örnek sayıları

<i>Etiket</i>	<i>Eğitim Aşaması Örnek Sayısı</i>	<i>Test Aşaması Örnek Sayısı</i>	<i>Toplam Örnek Sayısı</i>
<i>0</i>	70	30	100
<i>1</i>	70	30	100
<i>2</i>	70	30	100
<i>3</i>	70	30	100
<i>4</i>	70	30	100
<i>5</i>	70	30	100
<i>6</i>	70	30	100
<i>7</i>	70	30	100
<i>8</i>	70	30	100
<i>9</i>	70	30	100
<i>10</i>	70	30	100
<i>11</i>	70	30	100
<i>12</i>	70	30	100
<i>13</i>	70	30	100
<i>14</i>	70	30	100
<i>15</i>	70	30	100
<i>16</i>	70	30	100
<i>17</i>	70	30	100
<i>18</i>	70	30	100
<i>19</i>	70	30	100

Tablo 3.6. I. Veri kümesi için etiket bilgileri ve 20000'lik veri setinde yer alan toplam örnek sayıları

<i>Etiket</i>	<i>Eğitim Aşaması Örnek Sayısı</i>	<i>Test Aşaması Örnek Sayısı</i>	<i>Toplam Örnek Sayısı</i>
<i>0</i>	700	300	1000
<i>1</i>	700	300	1000
<i>2</i>	700	300	1000
<i>3</i>	700	300	1000
<i>4</i>	700	300	1000
<i>5</i>	700	300	1000
<i>6</i>	700	300	1000
<i>7</i>	700	300	1000
<i>8</i>	700	300	1000
<i>9</i>	700	300	1000
<i>10</i>	700	300	1000
<i>11</i>	700	300	1000
<i>12</i>	700	300	1000
<i>13</i>	700	300	1000
<i>14</i>	700	300	1000
<i>15</i>	700	300	1000
<i>16</i>	700	300	1000
<i>17</i>	700	300	1000
<i>18</i>	700	300	1000
<i>19</i>	700	300	1000

Tablo 3.7. I. Veri kümesi için etiket bilgileri ve 120000'lik veri setinde yer alan toplam örnek sayıları

<i>Etiket</i>	<i>Eğitim Aşaması Örnek Sayısı</i>	<i>Test Aşaması Örnek Sayısı</i>	<i>Toplam Örnek Sayısı</i>
<i>0</i>	4200	1800	6000
<i>1</i>	4200	1800	6000
<i>2</i>	4200	1800	6000
<i>3</i>	4200	1800	6000
<i>4</i>	4200	1800	6000
<i>5</i>	4200	1800	6000
<i>6</i>	4200	1800	6000
<i>7</i>	4200	1800	6000
<i>8</i>	4200	1800	6000
<i>9</i>	4200	1800	6000
<i>10</i>	4200	1800	6000
<i>11</i>	4200	1800	6000
<i>12</i>	4200	1800	6000
<i>13</i>	4200	1800	6000
<i>14</i>	4200	1800	6000
<i>15</i>	4200	1800	6000
<i>16</i>	4200	1800	6000
<i>17</i>	4200	1800	6000
<i>18</i>	4200	1800	6000
<i>19</i>	4200	1800	6000

3.2.2. HH dönüşümü ve YD ile oluşturulan II. veri kümesi

Sınıflandırma için ikinci bir veri kümesinin oluşturulmasındaki ana amaç, algoritma ve mimarilerin performanslarını farklı veri kümeleri ile değerlendirmektir. Bu kapsamda II. Veri Kümesinde veri ön işleme aşamasında Hilbert Huang Dönüşümü ile elde edilen 20 adet görüntü ve Yıldızküme Diyagramı ile elde edilen 20 adet görüntü bulunmaktadır. Bu sayede algoritma/mimarinin eğitim aşamasında kullanılacak görüntü çeşitliliğinin artırılması sağlanmıştır. Oluşturulan 600'lük, 2000'lik, 20.000'lik ve 120.000'lik veri setleri için eğitim ve test aşamasında kullanılan örnek sayıları sırasıyla Tablo 3.8, Tablo 3.9, Tablo 3.10 ve Tablo 3.11'de gösterilmiştir.

Tablo 3.8. II. Veri kümesi için etiket bilgileri ve 600'lük veri setinde yer alan toplam örnek sayıları

<i>Etiket</i>	<i>Eğitim Aşaması Örnek Sayısı</i>	<i>Test Aşaması Örnek Sayısı</i>	<i>Toplam Örnek Sayısı</i>
<i>0</i>	10	5	15
<i>1</i>	11	4	15
<i>2</i>	11	4	15
<i>3</i>	11	4	15
<i>4</i>	11	4	15
<i>5</i>	10	5	15
<i>6</i>	10	5	15
<i>7</i>	11	4	15
<i>8</i>	11	4	15
<i>9</i>	10	5	15
<i>10</i>	10	5	15
<i>11</i>	11	4	15
<i>12</i>	11	4	15
<i>13</i>	10	5	15
<i>14</i>	10	5	15
<i>15</i>	10	5	15
<i>16</i>	10	5	15
<i>17</i>	10	5	15
<i>18</i>	11	4	15
<i>19</i>	11	4	15
<i>a</i>	11	4	15
<i>b</i>	10	5	15
<i>c</i>	10	5	15
<i>d</i>	10	5	15
<i>e</i>	10	5	15
<i>f</i>	11	4	15
<i>g</i>	11	4	15
<i>h</i>	10	5	15
<i>k</i>	10	5	15
<i>l</i>	11	4	15
<i>m</i>	11	4	15
<i>n</i>	10	5	15
<i>p</i>	10	5	15
<i>r</i>	11	4	15
<i>s</i>	11	4	15
<i>t</i>	11	4	15
<i>u</i>	11	4	15
<i>v</i>	11	4	15
<i>y</i>	10	5	15
<i>z</i>	10	5	15

Tablo 3.9. II. Veri kümesi için etiket bilgileri ve 2000'lik veri setinde yer alan toplam örnek sayıları

<i>Etiket</i>	<i>Eğitim Aşaması Örnek Sayısı</i>	<i>Test Aşaması Örnek Sayısı</i>	<i>Toplam Örnek Sayısı</i>
<i>0</i>	35	15	50
<i>1</i>	35	15	50
<i>2</i>	35	15	50
<i>3</i>	35	15	50
<i>4</i>	35	15	50
<i>5</i>	35	15	50
<i>6</i>	35	15	50
<i>7</i>	35	15	50
<i>8</i>	35	15	50
<i>9</i>	35	15	50
<i>10</i>	35	15	50
<i>11</i>	35	15	50
<i>12</i>	35	15	50
<i>13</i>	35	15	50
<i>14</i>	35	15	50
<i>15</i>	35	15	50
<i>16</i>	35	15	50
<i>17</i>	35	15	50
<i>18</i>	35	15	50
<i>19</i>	35	15	50
<i>a</i>	35	15	50
<i>b</i>	35	15	50
<i>c</i>	35	15	50
<i>d</i>	35	15	50
<i>e</i>	35	15	50
<i>f</i>	35	15	50
<i>g</i>	35	15	50
<i>h</i>	35	15	50
<i>k</i>	35	15	50
<i>l</i>	35	15	50
<i>m</i>	35	15	50
<i>n</i>	35	15	50
<i>p</i>	35	15	50
<i>r</i>	35	15	50
<i>s</i>	35	15	50
<i>t</i>	35	15	50
<i>u</i>	35	15	50
<i>v</i>	35	15	50
<i>y</i>	35	15	50
<i>z</i>	35	15	50

Tablo 3.10. II. Veri kümesi için etiket bilgileri ve 20.000'lik veri setinde yer alan toplam örnek sayıları

<i>Etiket</i>	<i>Eğitim Aşaması Örnek Sayısı</i>	<i>Test Aşaması Örnek Sayısı</i>	<i>Toplam Örnek Sayısı</i>
<i>0</i>	350	150	500
<i>1</i>	350	150	500
<i>2</i>	350	150	500
<i>3</i>	350	150	500
<i>4</i>	350	150	500
<i>5</i>	350	150	500
<i>6</i>	350	150	500
<i>7</i>	350	150	500
<i>8</i>	350	150	500
<i>9</i>	350	150	500
<i>10</i>	350	150	500
<i>11</i>	350	150	500
<i>12</i>	350	150	500
<i>13</i>	350	150	500
<i>14</i>	350	150	500
<i>15</i>	350	150	500
<i>16</i>	350	150	500
<i>17</i>	350	150	500
<i>18</i>	350	150	500
<i>19</i>	350	150	500
<i>a</i>	350	150	500
<i>b</i>	350	150	500
<i>c</i>	350	150	500
<i>d</i>	350	150	500
<i>e</i>	350	150	500
<i>f</i>	350	150	500
<i>g</i>	350	150	500
<i>h</i>	350	150	500
<i>k</i>	350	150	500
<i>l</i>	350	150	500
<i>m</i>	350	150	500
<i>n</i>	350	150	500
<i>p</i>	350	150	500
<i>r</i>	350	150	500
<i>s</i>	350	150	500
<i>t</i>	350	150	500
<i>u</i>	350	150	500
<i>v</i>	350	150	500
<i>y</i>	350	150	500
<i>z</i>	350	150	500

Tablo 3.11. II. Veri kümesi için etiket bilgileri ve 120.000'lik veri setinde yer alan toplam örnek sayıları

<i>Etiket</i>	<i>Eğitim Aşaması Örnek Sayısı</i>	<i>Test Aşaması Örnek Sayısı</i>	<i>Toplam Örnek Sayısı</i>
<i>0</i>	2100	900	3000
<i>1</i>	2100	900	3000
<i>2</i>	2100	900	3000
<i>3</i>	2100	900	3000
<i>4</i>	2100	900	3000
<i>5</i>	2100	900	3000
<i>6</i>	2100	900	3000
<i>7</i>	2100	900	3000
<i>8</i>	2100	900	3000
<i>9</i>	2100	900	3000
<i>10</i>	2100	900	3000
<i>11</i>	2100	900	3000
<i>12</i>	2100	900	3000
<i>13</i>	2100	900	3000
<i>14</i>	2100	900	3000
<i>15</i>	2100	900	3000
<i>16</i>	2100	900	3000
<i>17</i>	2100	900	3000
<i>18</i>	2100	900	3000
<i>19</i>	2100	900	3000
<i>a</i>	2100	900	3000
<i>b</i>	2100	900	3000
<i>c</i>	2100	900	3000
<i>d</i>	2100	900	3000
<i>e</i>	2100	900	3000
<i>f</i>	2100	900	3000
<i>g</i>	2100	900	3000
<i>h</i>	2100	900	3000
<i>k</i>	2100	900	3000
<i>l</i>	2100	900	3000
<i>m</i>	2100	900	3000
<i>n</i>	2100	900	3000
<i>p</i>	2100	900	3000
<i>r</i>	2100	900	3000
<i>s</i>	2100	900	3000
<i>t</i>	2100	900	3000
<i>u</i>	2100	900	3000
<i>v</i>	2100	900	3000
<i>y</i>	2100	900	3000
<i>z</i>	2100	900	3000

4. BULGULAR VE TARTIŞMA

Çalışmanın bu bölümünde belirli bir bölge içerisinde yer istasyonlarından toplanan RF sinyallerinin 3. Bölümde detaylı bir şekilde açıklandığı üzere gerekli veri ön işleme aşamaları gerçekleştirildikten sonra iki farklı Makine Öğrenme algoritması (K-Ortalama Kümeleme ve K-En Yakın Komşuluk) ve üç farklı Derin Öğrenme Mimarisi (U-Net, AlexNet ve ResNet) kullanılarak sınıflandırılması sonucunda elde edilen deneysel sonuçlar değerlendirilmiştir.

4.1. Deneysel Çalışma Ortamı

Bu çalışmada deneysel uygulamalarda kullanılan bilgisayar, Intel Core i7 işlemci, 2 GB ekran kartı hafızası, RX 640 ekran kartı, 16 GB ram, 8 MB işlemci cache teknik özelliklere sahiptir. Mimarilerin performanslarını ölçmek için MATLAB R2020a yazılımı araç kutusu ve Tablo 4.1’de özellikleri belirtilen iş istasyonu kullanılmıştır.

Tablo 4.1. Çalışma ortamı

Donanım	Özellikler
İşletim Sistemi	64 bit, Windows 10
Ekran Kartı	RX 640
Ram	16 GB
CPU	Intel(R) Core (TM) I7-8700 CPU, 8 Cores

4.2. Makine Öğrenmesi Analiz Sonuçları

Çalışmanın bu bölümde Makine Öğrenmesi algoritmalarının 5 farklı cihaz tipi özelinde sınıflandırma performansı incelenmiştir. Veriler K-Ortalama Kümeleme ve K-En Yakın Komşuluk olmak üzere iki farklı Makine Öğrenme algoritması ile analiz edilmiştir. K-Ortalama Kümelemede IQ ham sinyal verileri kullanılmış olup, öncelikle sinyal veri kümesi üzerinde (2.9) eşitliği ile normalizasyon işlemi uygulanarak sayısal dönüşüm gerçekleştirilmiştir. Daha sonra da modelde beş adet farklı cihaz sinyali olması sebebiyle K değeri beş olarak belirlenmiştir. K-En Yakın Komşuluk algoritmasında ise veri ön işleme aşamasında sinyallerin Hilbert Huang Dönüşümü ve Yıldızküme Diyagramı ile oluşturulan örnek görüntüleri kullanılmıştır. Eğitim ile test verileri % 70 ile % 30 olacak şekilde bölünmüştür. K-Ortalama Kümeleme Algoritması için I. ve II. Veri kümesi kullanılarak gerçekleştirilen sınıflandırma işlemi performansı Tablo 4.2’de

verilmiştir. Tablodan da görüldüğü üzere her iki veri kümesi ile yapılan analizlerde veri sayısı arttıkça doğruluk oranı artmaktadır. Algoritmanın çalışma süresi ise veri sayısı ile doğru orantılı olarak artmaktadır. İki veri kümesi için ortalama doğruluk oranları karşılaştırıldığında II. Veri Kümesi ile daha iyi sonuçlar elde edildiği görülmüştür.

Tablo 4.2. K-Ortalama Kümeleme Algoritması için sınıflandırma performansları

Veri Seti	I. Veri Kümesi		II. Veri Kümesi	
	Doğruluk (%)	Zaman (Sn)	Doğruluk (%)	Zaman (Sn)
600	91.40	11.23	92.50	12.25
2.000	91.99	15.13	92.60	16.50
20.000	92.99	19.43	94.30	20.25
120.000	94.00	23.47	95.50	24.50
	Ortalama Doğruluk Oranı: 92.59		Ortalama Doğruluk Oranı: 93.72	

K-Ortalama Kümeleme ile I. ve II. Veri kümesi için elde edilen sınıflandırma sonuçları ise sırasıyla Tablo 4.3 ve Tablo 4.4'te verilmiştir. Bu kapsamda Tablolardan da görüleceği üzere II. Veri Kümesi ile yapılan sınıflandırma sonrası yanlış sınıflandırılan sinyal sayısının daha az olduğu tespit edilmiştir.

Tablo 4.3. K-Ortalama Kümeleme ile yapılan analizlerde I. Veri kümesi için sınıflandırma sonuçları

Cihaz Tipi/ Veri Kümesi	600	2000	20000	120000
Radar	113	354	3622	23989
GSM	119	352	3545	22079
Telsiz	117	399	3765	23357
Jammer	79	383	3953	21263
Diğer	120	352	3710	22101
Yanlış Sınıflandırılmış Sinyal	52	160	1405	7211
Yanlış Sınıflandırılmış Sinyal Oranı (%)	8.6	8.0	7.0	6.0

Tablo 4.4. K-Ortalama Kümeleme ile yapılan analizlerde II. Veri kümesi için sınıflandırma sonuçları

Cihaz Tipi/ Veri Kümesi	600	2000	20000	120000
Radar	116	354	3632	23989
GSM	112	352	3545	23079
Telsiz	117	391	3970	23357
Jammer	109	383	3953	22063
Diğer	101	372	3760	22112
Yanlış Sınıflandırılmış Sinyal	45	148	1140	5400
Yanlış Sınıflandırılmış Sinyal Oranı (%)	7.5	7.4	5.7	4.5

K-En Yakın Komşuluk Algoritması için I. ve II. Veri kümesi kullanılarak gerçekleştirilen sınıflandırma işlemi performansı, Tablo 4.5'te verilmiştir. Tablodan da görüldüğü üzere her iki veri kümesi ile yapılan analizlerde veri sayısı arttıkça doğruluk oranı artmaktadır. Algoritmanın çalışma süresinin ise I. Veri kümesi ile yapılan analizlerde veri sayısı arttıkça artarken, II. Veri kümesi için azaldığı görülmektedir. İki veri kümesi için ortalama doğruluk oranları karşılaştırıldığında ise II. Veri Kümesi ile daha iyi sonuçlar elde edildiği görülmüştür.

Tablo 4.5. K-En Yakın Komşuluk Algoritması için sınıflandırma performansı

Veri Seti	I. Veri Kümesi		II. Veri Kümesi	
	Doğruluk (%)	Zaman (Sn)	Doğruluk (%)	Zaman (Sn)
600	83.20	5.21	85.50	14.25
2.000	92.10	7.03	93.60	6.50
20.000	94.00	9.36	95.30	5.20
120.000	96.20	13.26	96.50	2.50
	Ortalama Doğruluk Oranı: 91.37		Ortalama Doğruluk Oranı: 92.72	

K-En Yakın Kümeleme ile I. ve II. Veri kümesi için elde edilen sınıflandırma sonuçları ise sırasıyla Tablo 4.6 ve Tablo 4.7'de verilmiştir.

Tablo 4.6. K-En Yakın Komşuluk ile yapılan analizlerde I. Veri Kümesi için sınıflandırma sonuçları

Cihaz Tipi/ Veri Kümesi	600	2000	20000	120000
	Eğitim: 420	Eğitim: 1400	Eğitim: 14000	Eğitim: 84000
	Test: 180	Test: 600	Test: 6000	Test: 36000
Radar	30	110	1130	6962
GSM	31	109	1142	6961
Telsiz	29	108	1120	6904
Jammer	30	115	1088	6905
Diğer	30	111	1160	6900
Yanlış Sınıflandırılmış Sinyal	30	47	360	1368
Yanlış Sınıflandırılmış Sinyal Oranı (%)	16.8	7.9	6.0	3.8

Tablo 4.7. K-En Yakın Komşuluk ile yapılan analizlerde II. Veri Kümesi için sınıflandırma sonuçları

Cihaz Tipi/ Veri Kümesi	600	2000	20000	120000
	Eğitim: 420	Eğitim: 1400	Eğitim: 14000	Eğitim: 84000
	Test: 180	Test: 600	Test: 6000	Test: 36000
Radar	30	111	1144	6970
GSM	31	109	1142	6931
Telsiz	32	118	1120	6984
Jammer	31	117	1152	6947
Diğer	30	119	1160	6908
Yanlış Sınıflandırılmış Sinyal	26	26	282	1260
Yanlış Sınıflandırılmış Sinyal Oranı (%)	14.5	6.4	4.7	3.5

Elde edilen bulgular ışığında Tablolardan da görüleceği üzere II. Veri Kümesi ile yapılan sınıflandırma sonrası yanlış sınıflandırılan sinyal sayısının daha az olduğu tespit edilmiştir. Bu kapsamda örnek görüntü sayısı arttıkça algoritmanın eğitiminin daha başarılı olduğu ve eğitim ne kadar başarılı olursa test sonuçları doğruluk oranlarının da o kadar yüksek çıktığı tespit edilmiştir.

4.3. Derin Öğrenme Mimarileri Analiz Sonuçları

Derin Öğrenme Mimarilerinin çalıştırılmasında kullanılan veri kümelerinin hazırlanması ile ilgili adımlar çalışmanın 3. Bölümünde veri ön işleme başlığı altında detaylı olarak açıklanmıştır. Bu çalışmada veri sayısının oldukça fazla ve çalışma ortamının basit bir iş istasyonu olması sebebiyle U-Net, AlexNet ve ResNet mimarileri için tek katmanlı bir yapı kullanılmıştır.

Derin Öğrenme ile sınıflandırma işlemi yapılırken öncelikle hazırlanan veri seti sisteme yüklenir. Ardından, yüklenen veri seti, % 70 eğitim ve % 30 test verisi olarak bölünür. Sınıflandırma için kullanılacak olan *train* veri seti; *trainOpt* ve *validationOpt* olarak iki yeni alt veri setine bölünür. Kullanılan optimizasyon algoritması tarafından üretilen her bir çözüm vektörü, optimize edilecek olası hiperparametre değerlerinden oluşur. Kullanılan mimari tarafından üretilen hiperparametre degerleri seti için uygunluk değeri ve çıktı fonksiyonu hesaplanır. Hafızada tutulan en ideal parametre seti çıktı olarak verilir. Son aşamada ise sinyal sınıflandırma modeli test verileri üzerinde test edilir ve mimarinin performansı Eşitlik (2.15) ile ölçülür (Özcan, 2020).

4.3.1. UNet mimarisi analiz sonuçları

Derin Öğrenme mimarilerinden UNet mimarisi ile gerçekleştirilen sınıflandırma işleminde I. ve II. veri kümesi kullanılmıştır. I. ve II. Veri Kümesi ile 4 farklı veri seti için çalıştırılan UNet mimarisi sinyal sınıflandırma performansı, Tablo 4.8’de verilmiştir. Tablodan da görüleceği üzere her iki veri kümesi için de veri sayısı arttıkça doğruluk oranlarında çok ufak değişiklikler olduğu gözlemlenirken, analiz sürelerinin veri sayısı ile doğru orantılı olarak arttığı tespit edilmiştir.

Tablo 4.8. UNet mimarisi için sınıflandırma performansı

Veri Seti	I. Veri Kümesi		II. Veri Kümesi	
	Doğruluk (%)	Zaman (Sn)	Doğruluk (%)	Zaman (Sn)
600	98.40	13.08	98.60	14.10
2.000	99.40	45.19	99.60	46.50
20.000	99.20	44.24	99.30	45.20
120.000	99.50	52.04	99.50	52.50
	Ortalama Doğruluk Oranı: 99.12		Ortalama Doğruluk Oranı: 99.25	

Ağın eğitimi sonrası, test verisi kullanılarak elde edilen sinyal sınıflandırma sonuçları Tablo 4.9-Tablo 4.10’da gösterilmiştir. Tablolardan da görüleceği üzere II. Veri Kümesi ile yapılan sınıflandırma sonrası yanlış sınıflandırılan sinyal sayısının daha az olduğu tespit edilmiştir. Bu kapsamda örnek görüntü sayısı arttıkça algoritmanın eğitiminin daha başarılı olduğu ve elde edilen doğruluk oranlarının daha yüksek çıktığı görülmektedir.

Tablo 4.9. U-Net mimarisi ile yapılan analizlerde I. Veri Kümesi için sınıflandırma sonuçları

Cihaz Tipi/ Veri Seti	600	2000	20000	120000
	Eğitim: 420	Eğitim: 1400	Eğitim: 14000	Eğitim: 84000
	Test: 180	Test: 600	Test: 6000	Test: 36000
Radar	34	120	1190	7170
GSM	36	119	1192	7181
Telsiz	35	118	1200	7144
Jammer	36	120	1188	7158
Diğer	36	119	1182	7167
Yanlış Sınıflandırılmış Sinyal	3	4	48	180
Yanlış Sınıflandırılmış Sinyal Oranı (%)	1.6	0.6	0.8	0.5

Tablo 4.10. U-Net mimarisi ile yapılan analizlerde II. Veri Kümesi için sınıflandırma sonuçları

Cihaz Tipi/ Veri Seti	600	2000	20000	120000
	Eğitim: 420	Eğitim: 1400	Eğitim: 14000	Eğitim: 84000
	Test: 180	Test: 600	Test: 6000	Test: 36000
Radar	36	119	1195	7184
GSM	34	120	1194	7178
Telsiz	36	119	1199	7147
Jammer	35	119	1178	7161
Diğer	36	120	1192	7150
Yanlış Sınıflandırılmış Sinyal	3	3	42	180
Yanlış Sınıflandırılmış Sinyal Oranı (%)	1.4	0.4	0.7	0.5

Sınıflandırma sonucunda elde edilen U-Net Mimarisinin karmaşıklık matrisleri sırasıyla Şekil 4.1 ve Şekil 4.2’de verilmiştir. Şekil 4.1(a)’da görüldüğü üzere I. Veri Kümesi içerisinde yer alan 600’lük veri seti ile gerçekleştirilen sınıflandırma işleminde radar sınıfında olması gereken 2 adet verinin, telsiz ve diğer sınıfı içerisinde, telsiz sınıfında olması gereken bir adet verinin de jammer sınıfında yer aldığı ve bu sinyallerin yanlış sınıflandırıldıkları görülmektedir. Benzer şekilde Şekil 4.2 (a)’da da görüldüğü gibi II. Veri Kümesi içersinde yer alan 600’lük veri seti ile gerçekleştirilen sınıflandırma işleminde de GSM sınıfına gitmesi gereken 2 adet verinin telsiz ve radar sınıfında, jammer sınıfında olması gereken bir adet verinin de, GSM sınıfına giderek yanlış sınıflandırıldıkları görülmektedir. Her iki veri kümesi için de 20.000’lik ve 120.000’lik veri seti ile yapılan sınıflandırma işlemlerinde yanlış sınıflandırılan sinyal sayısında artış olduğu gözlenmektedir.

Sınıflandırılan Değer/Gerçek Değer	RADAR	GSM	TELSİZ	JAMMER	DİĞER	
RADAR	34		1		1	%64,44 %5,56
GSM		36				%100 %5,56
TELSİZ			35	1		%97,22 %2,78
JAMMER				36		%100 %0
DİĞER					36	%100 %0
	%100 %0	%100 %0	%97,22 %2,78	%97,29 %2,71	%97,29 %2,71	%98,33 %1,67

(a) 600'lük Veri Seti

Sınıflandırılan Değer/Gerçek Değer	RADAR	GSM	TELSİZ	JAMMER	DİĞER	
RADAR	120					%100 %0
GSM		119			1	%99,16 %0,84
TELSİZ			118	1	1	%98,33 %1,67
JAMMER				120		%100 %0
DİĞER			1		119	%99,16 %0,84
	%100 %0	%100 %0	%99,16 %0,84	%99,17 %0,83	%98,34 %1,66	%99,33 %0,66

(b) 2.000'lik Veri Seti

Sınıflandırılan Değer/Gerçek Değer	RADAR	GSM	TELSİZ	JAMMER	DİĞER	
RADAR	1190	3	3	2	2	%99,16 %0,84
GSM	3	1192	1	1	3	%99,33 %0,67
TELSİZ			1200			%100 %0
JAMMER	3	1	3	1188	5	%99,00 %1,00
DİĞER	1	4	6	7	1182	%98,50 %1,50
	%99,41 %0,59	%99,33 %0,67	%98,92 %1,08	%99,16 %0,84	%99,16 %0,84	%99,20 %0,80

(c) 20.000'lik Veri Seti

Sınıflandırılan Değer/Gerçek Değer	RADAR	GSM	TELSİZ	JAMMER	DİĞER	
RADAR	7170	7	4	11	8	%99,58 %0,42
GSM	3	7181	5	4	7	%99,73 %0,27
TELSİZ	13	17	7144	14	12	%99,22 %0,78
JAMMER	10	11	13	7158	8	%99,41 %0,59
DİĞER	11	4	11	7	7167	%99,54 %0,46
	%99,48 %0,52	%99,45 %0,55	%99,54 %0,46	%99,49 %0,51	%99,51 %0,49	%99,50 %0,50

(d) 120.000'lik Veri Seti

Şekil 4.1. I. Veri Kümesi için UNet Karmaşıklık Matrisi

Sınıflandırılan Değer/Gerçek Değer	RADAR	GSM	TELSİZ	JAMMER	DİĞER	
RADAR	36					%100 %0
GSM	1	34	1			%94,44 %5,56
TELSİZ			36			%100 %0
JAMMER		1		35		%97,22 %2,78
DİĞER					36	%100 %0
	%97,29 %2,71	%97,14 %2,86	%97,29 %2,71	%100 %0	%100 %0	%98,33 %1,67

(a) 600'lük Veri Seti

Sınıflandırılan Değer/Gerçek Değer	RADAR	GSM	TELSİZ	JAMMER	DİĞER	
RADAR	119			1		%99,16 %0,84
GSM		120				%100 %0
TELSİZ			119		1	%99,16 %0,84
JAMMER			1	119		%99,16 %0,84
DİĞER					120	%100 %0
	%100 %0	%100 %0	%99,16 %0,84	%99,16 %0,84	%98,17 %0,83	%99,50 %0,50

(b) 2.000'lik Veri Seti

Sınıflandırılan Değer/Gerçek Değer	RADAR	GSM	TELSİZ	JAMMER	DİĞER	
RADAR	1195	2	1	1	1	%99,58 %0,42
GSM	3	1194	1	1	1	%99,50 %0,50
TELSİZ			1199	1		%99,91 %0,09
JAMMER	6	6	5	1178	5	%98,16 %1,84
DİĞER	1	4	1	2	1192	%99,33 %0,67
	%99,17 %0,83	%99,00 %1,00	%99,33 %0,67	%99,57 %0,43	%99,41 %0,59	%99,30 %0,70

(c) 20.000'lik Veri Seti

Sınıflandırılan Değer/Gerçek Değer	RADAR	GSM	TELSİZ	JAMMER	DİĞER	
RADAR	7184	7	4	3	2	%99,77 %0,23
GSM	6	7178	5	4	7	%99,69 %0,31
TELSİZ	10	17	7147	14	12	%99,26 %0,74
JAMMER	10	11	10	7161	8	%99,45 %0,55
DİĞER	21	11	11	7	7150	%99,30 %0,70
	%99,35 %0,65	%99,36 %0,64	%99,58 %0,42	%99,61 %0,39	%99,59 %0,41	%99,50 %0,50

(d) 120.000'lik Veri Seti

Şekil 4.2. II. Veri Kümesi için UNet Karmaşıklık Matrisi

4.3.2. AlexNet mimarisi analiz sonuçları

I. ve II. Veri Kümesi ile 4 farklı veri seti için çalıştırılan AlexNet mimarisi sinyal sınıflandırma performansı Tablo 4.11'de verilmiştir. Tablodan da görüleceği üzere I. Veri Kümesi ile yapılan sınıflandırma işleminde veri sayısı arttıkça doğruluk oranının az da olsa olumlu anlamda değiştiği gözlenirken, II. Veri Kümesi ile yapılan analizlerde veri

sayısı ile orantılı olarak arttığı görülmektedir. Her iki veri kümesi ile yapılan analizlerde veri sayısı artarken analiz sürelerinde veri sayısı ile orantılı artış gözlenmektedir.

Tablo 4.11. AlexNet mimarisi için sınıflandırma performansı

Veri Seti	I. Veri Kümesi		II. Veri Kümesi	
	Doğruluk (%)	Zaman (Sn)	Doğruluk (%)	Zaman (Sn)
600	98.90	47.21	99.10	48.10
2.000	99.00	48.22	99.12	49.50
20.000	99.20	54.24	99.31	55.20
120.000	99.40	59.01	99.56	59.50
	Ortalama Doğruluk Oranı: 99.05		Ortalama Doğruluk Oranı: 99.27	

AlexNet mimarisi için test verileri ile gerçekleştirilen sınıflandırma işlemi sonuçları her iki veri kümesi dikkate alınarak sırasıyla Tablo 4.12’de ve Tablo 4.13’de verilmiştir. Her iki tablodan da görüleceği üzere II. Veri Kümesi ile yapılan sınıflandırma sonrası yanlış sınıflandırılan sinyal sayısı daha azdır. Dolayısıyla örnek görüntü sayısı arttıkça mimarinin eğitiminin daha başarılı olduğu görülmektedir.

Tablo 4.12. I. Veri kümesi için AlexNet mimarisi ile yapılan analizlerde sınıflandırma sonuçları

Cihaz Tipi/ Veri Seti	600	2000	20000	120000
	Eğitim: 420	Eğitim: 1400	Eğitim: 14000	Eğitim: 84000
	Test: 180	Test: 600	Test: 6000	Test: 36000
Radar	36	119	1191	7150
GSM	36	120	1190	7171
Telsiz	35	118	1191	7172
Jammer	36	120	1189	7150
Diğer	35	117	1191	7141
Yanlış Sınıflandırılmış Sinyal	2	6	48	216
Yanlış Sınıflandırılmış Sinyal Oranı (%)	1.1	1.0	0.8	0.6

Tablo 4.13. II. Veri kümesi için AlexNet mimarisi ile yapılan analizlerde sınıflandırma sonuçları

Cihaz Tipi/ Veri Kümesi	600	2000	20000	120000
	Eğitim: 420	Eğitim: 1400	Eğitim: 14000	Eğitim: 84000
	Test: 180	Test: 600	Test: 6000	Test: 36000
Radar	36	119	1194	7160
GSM	36	120	1191	7181
Telsiz	35	119	1193	7170
Jammer	35	118	1190	7180
Diğer	36	119	1196	7165
Yanlış Sınıflandırılmış Sinyal	2	5	36	144
Yanlış Sınıflandırılmış Sinyal Oranı (%)	0.9	0.8	0.6	0.4

I. ve II. Veri kümeleri için AlexNet Mimarisi karmaşıklık matrisleri sırasıyla Şekil 4.3 ve Şekil 4.4'te verilmiştir. Şekil 4.3 (a) ve Şekil 4.4 (a)'dan görüleceği üzere her iki veri kümesi için 600'lük veri seti ile gerçekleştirilen sınıflandırma işlemlerinde telsiz sınıfında yer alması gereken bir adet verinin GSM, diğer sınıfında olması gereken bir adet verinin telsiz, telsiz sınıfında olması gereken 1 adet verinin Jammer ve jammer sınıfında olması gereken bir adet verinin de telsiz sınıfında yer alarak yanlış sınıflandırıldığı görülmektedir. Diğer veri setleri ile yapılan sınıflandırma işlemleri için de aynı durum söz konusu olmakla birlikte, veri sayısı arttıkça yanlış sınıflandırılan sinyallerin dağılımları değişim göstermektedir.

Sınıflandırılan Değer/ Gerçek Değer	RADAR	GSM	TELSİZ	JAMMER	DİĞER	
RADAR	36					%100 %0
GSM		36				%100 %0
TELSİZ		1	35			%97,22 %2,78
JAMMER				36		%100 %0
DİĞER			1		35	%97,22 %2,78
	%100 %0	%97,29 %2,71	%97,22 %2,78	%100 %0	%100 %0	%98,88 %1,12

(a) 600'lük Veri Seti

Sınıflandırılan Değer/ Gerçek Değer	RADAR	GSM	TELSİZ	JAMMER	DİĞER	
RADAR	119		1			%99,16 %0,84
GSM		120				%100 %0
TELSİZ	1	1	118			%98,33 %1,67
JAMMER				120		%100 %0
DİĞER	1			2	117	%97,50 %2,50
	%98,34 %1,66	%99,17 %0,83	%99,16 %0,84	%98,36 %1,64	%100 %0	%99,00 %1,00

(b) 2.000'lük Veri Seti

Sınıflandırılan Değer/ Gerçek Değer	RADAR	GSM	TELSİZ	JAMMER	DİĞER	
RADAR	1190	2	2	2	4	%99,16 %0,84
GSM	3	1192	1	2	2	%99,33 %0,67
TELSİZ			1200			%100 %0
JAMMER	7	5	3	1188	3	%99,00 %1,00
DİĞER	3	6	6	3	1182	%98,50 %1,50
	%98,91 %1,09	%98,92 %1,08	%99,00 %1,00	%99,41 %0,59	%99,24 %0,76	%99,20 %0,80

(a) 20.000'lük Veri Seti

Sınıflandırılan Değer/ Gerçek Değer	RADAR	GSM	TELSİZ	JAMMER	DİĞER	
RADAR	7170	12	8	4	6	%99,58 %0,42
GSM	3	7181	7	3	6	%99,73 %0,27
TELSİZ	13	17	7144	18	8	%99,22 %0,78
JAMMER	11	3	9	7158	19	%99,41 %0,59
DİĞER	9	7	11	6	7167	%99,54 %0,46
	%99,50 %0,50	%99,45 %0,55	%99,51 %0,49	%99,56 %0,44	%99,45 %0,55	%99,50 %0,50

(b) 120.000'lük Veri Seti

Şekil 4.3. I. Veri kümesi için AlexNet mimarisi karmaşıklık matrisi

Sınıflandırılan Değer/ Gerçek Değer	RADAR	GSM	TELSİZ	JAMMER	DİĞER	
RADAR	36					%100 %0
GSM		36				%100 %0
TELSİZ			35	1		%97,22 %2,78
JAMMER			1	35		%97,22 %2,78
DİĞER					36	%100 %0
	%100 %0	%100 %0	%97,22 %2,78	%97,22 %2,78	%100 %0	%98,88 %1,12

(a) 600'lük Veri Seti

Sınıflandırılan Değer/ Gerçek Değer	RADAR	GSM	TELSİZ	JAMMER	DİĞER	
RADAR	119		1			%99,16 %0,84
GSM		120				%100 %0
TELSİZ		1	119			%99,16 %0,84
JAMMER		1	1	118		%98,33 %1,67
DİĞER		1			119	%99,16 %0,84
	%100 %0	%97,56 %2,44	%98,34 %1,66	%100 %0	%100 %0	%99,16 %0,84

(b) 2.000'lik Veri Seti

Sınıflandırılan Değer/ Gerçek Değer	RADAR	GSM	TELSİZ	JAMMER	DİĞER	
RADAR	1194	2	1	2	1	%99,50 %0,50
GSM	3	1191	1	2	3	%99,25 %0,75
TELSİZ	3		1193	3	1	%99,41 %0,59
JAMMER	1	1	3	1190	5	%99,16 %0,84
DİĞER	1	1		2	1196	%99,66 %0,34
	%99,33 %0,67	%99,66 %0,34	%99,58 %0,42	%99,24 %0,76	%99,17 %0,83	%99,60 %0,40

(a) 20.000'lik Veri Seti

Sınıflandırılan Değer/ Gerçek Değer	RADAR	GSM	TELSİZ	JAMMER	DİĞER	
RADAR	7160	7	14	11	8	%99,44 %0,56
GSM	3	7181	5	4	7	%99,73 %0,27
TELSİZ	3	8	7170	14	5	%99,58 %0,42
JAMMER	3	5	4	7180	8	%99,72 %0,28
DİĞER	11	6	11	7	7165	%99,51 %0,49
	%99,72 %0,28	%99,63 %0,37	%99,52 %0,48	%99,49 %0,51	%99,50 %0,50	%99,60 %0,40

(b) 120.000'lik Veri Seti

Şekil 4.4. II. Veri Kümesi için AlexNet mimarisi karmaşıklık matrisi

4.3.3. ResNet mimarisi analiz sonuçları

I. ve II. Veri Kümesi ile 4 farklı veri seti için çalıştırılan ResNet mimarisi sinyal sınıflandırma performansı Tablo 4.14'de verilmiştir. Mimarinin eğitimi sonrası, test verileri kullanılarak gerçekleştirilen sinyal sınıflandırma işlemi sonuçları sırasıyla Tablo 4.15 ve Tablo 4.16'da gösterilmiştir.

Tablo 4.14. ResNet mimarisi için sınıflandırma performansı

Veri Seti	I. Veri Kümesi		II. Veri Kümesi	
	Doğruluk (%)	Zaman (Sn)	Doğruluk (%)	Zaman (Sn)
600	99.40	31.41	99.50	38.70
2.000	99.80	42.36	99.78	47.50
20.000	99.50	49.28	99.51	54.20
120.000	99.70	50.09	99.71	54.50
	Ortalama Doğruluk Oranı: 99.60		Ortalama Doğruluk Oranı: 99.63	

Tablo 4.16'dan da görüleceği üzere her iki veri kümesi ile yapılan sınıflandırma işleminde veri sayısı arttıkça doğruluk oranının az da olsa olumlu anlamda değiştiği gözlenmiştir. Bununla birlikte her iki veri kümesi için de analiz sürelerinde veri sayısı ile orantılı artış tespit edilmiştir.

Her iki veri kümesi için test verileri ile gerçekleştirilen sinyal sınıflandırma işlemi sonuçları sırasıyla Tablo 4.15 ve Tablo 4.16’da verilmiştir. Her iki tablodan da görüleceği üzere II. Veri Kümesi ile yapılan sınıflandırma sonrası yanlış sınıflandırılan sinyal sayısı daha azdır. Dolayısıyla örnek görüntü sayısı arttıkça mimarinin eğitiminin daha başarılı olduğu görülmektedir.

Tablo 4.15. I. Veri Kümesi için ResNet mimarisi ile yapılan analizlerde sınıflandırma sonuçları

Cihaz Tipi/ Veri Kümesi	600	2000	20000	120000
	Eğitim: 420	Eğitim: 1400	Eğitim: 14000	Eğitim: 84000
	Test: 180	Test: 600	Test: 6000	Test: 36000
Radar	35	120	1192	7165
GSM	36	119	1189	7170
Telsiz	36	120	1194	7185
Jammer	36	120	1198	7189
Diğer	36	120	1197	7183
Yanlış Sınıflandırılmış Sinyal	1	1	30	108
Yanlış Sınıflandırılmış Sinyal Oranı (%)	0.55	0.16	0.5	0.3

Tablo 4.16. II. Veri Kümesi için ResNet mimarisi ile yapılan analizlerde sınıflandırma sonuçları

Cihaz Tipi/ Veri Kümesi	600	2000	20000	120000
	Eğitim: 420	Eğitim: 1400	Eğitim: 14000	Eğitim: 84000
	Test: 180	Test: 600	Test: 6000	Test: 36000
Radar	35	120	1189	7175
GSM	36	119	1192	7160
Telsiz	36	120	1198	7180
Jammer	36	120	1194	7190
Diğer	36	120	1197	7191
Yanlış Sınıflandırılmış Sinyal	1	1	29	104
Yanlış Sınıflandırılmış Sinyal Oranı (%)	0.55	0.16	0.49	0.29

Sınıflandırma sonucunda ResNet Mimarisi karmaşıklık matrisleri sırasıyla Şekil 4.5 ve Şekil 4.6’da verilmiştir. Her iki veri kümesi için 4 farklı veri seti ile yapılan sınıflandırma işlemlerinde matrislerden de görüleceği üzere bazı sinyal verilerinin olması gereken sınıf içerisinde yer almayarak yanlış sınıflandırıldığı tespit edilmiştir. Veri sayısı arttıkça yanlış sınıflandırılan sinyallerin farklı sınıflar içerisinde yer alarak dağılımın çeşitlendiği görülmektedir.

Sınıflandırılan Değer/Gerçek Değer	RADAR	GSM	TELSİZ	JAMMER	BİLNMEYEN	
RADAR	35		1			%97,22 %2,78
GSM		36				%100 %0
TELSİZ			36			%100 %0
JAMMER				36		%100 %0
BİLNMEYEN					36	%100 %0
	%100 %0	%100 %0	%97,22 %2,78	%100 %0	%100 %0	%98,33 %1,67

(a) 600'lük Veri Seti

Sınıflandırılan Değer/Gerçek Değer	RADAR	GSM	TELSİZ	JAMMER	BİLNMEYEN	
RADAR	120	1				%99,17 %0,83
GSM		119				%100 %0
TELSİZ			120			%100 %0
JAMMER				120		%100 %0
BİLNMEYEN					120	%100 %0
	%100 %0	%99,17 %0,83	%100 %0	%100 %0	%100 %0	%99,83 %0,17

(b) 2.000'lik Veri Seti

Sınıflandırılan Değer/Gerçek Değer	RADAR	GSM	TELSİZ	JAMMER	DIĞER	
RADAR	1192	2	3	1	2	%99,33 %0,67
GSM	2	1189	1	5	3	%99,08 %0,92
TELSİZ	1	3	1194		2	%99,50 %0,50
JAMMER			1	1196	1	%99,83 %0,17
DIĞER	1			2	1197	%99,75 %0,25
	%99,66 %0,34	%99,58 %0,42	%99,58 %0,42	%99,33 %0,67	%99,33 %0,67	%99,50 %0,50

(a) 20.000'lik Veri Seti

Sınıflandırılan Değer/Gerçek Değer	RADAR	GSM	TELSİZ	JAMMER	DIĞER	
RADAR	7165	9	18	5	3	%99,51 %0,49
GSM	5	7170	5	7	13	%99,58 %0,42
TELSİZ	6	3	7185	2	4	%99,79 %0,21
JAMMER	2	1	3	7189	5	%99,84 %0,16
DIĞER	7	6	2	2	7183	%99,76 %0,24
	%99,72 %0,28	%99,73 %0,27	%99,61 %0,39	%99,77 %0,23	%99,65 %0,35	%99,70 %0,30

(b) 120.000'lik Veri Seti

Şekil 4.5. I. Veri Kümesi için ResNet mimarisi karmaşıklık matrisi

Sınıflandırılan Değer/Gerçek Değer	RADAR	GSM	TELSİZ	JAMMER	BİLNMEYEN	
RADAR	35		1			%97,22 %2,78
GSM		36				%100 %0
TELSİZ			36			%100 %0
JAMMER				36		%100 %0
BİLNMEYEN					36	%100 %0
	%100 %0	%100 %0	%97,22 %2,78	%100 %0	%100 %0	%98,33 %1,67

(a) 600'lük Veri Seti

Sınıflandırılan Değer/Gerçek Değer	RADAR	GSM	TELSİZ	JAMMER	BİLNMEYEN	
RADAR	120	1				%99,17 %0,83
GSM		119				%100 %0
TELSİZ			120			%100 %0
JAMMER				120		%100 %0
BİLNMEYEN					120	%100 %0
	%100 %0	%99,17 %0,83	%100 %0	%100 %0	%100 %0	%99,83 %0,17

(b) 2.000'lik Veri Seti

Sınıflandırılan Değer/Gerçek Değer	RADAR	GSM	TELSİZ	JAMMER	DIĞER	
RADAR	1189	3	3	2	3	%99,08 %0,92
GSM	3	1192	1	1	3	%99,33 %0,67
TELSİZ	1	1	1198	1		%99,83 %0,17
JAMMER		1	2	1194	3	%99,50 %0,50
DIĞER			1	2	1197	%99,75 %0,25
	%99,74 %0,26	%99,58 %0,42	%99,41 %0,59	%99,50 %0,50	%99,25 %0,75	%99,50 %0,50

(a) 20.000'lik Veri Seti


Sınıflandırılan Değer/Gerçek Değer	RADAR	GSM	TELSİZ	JAMMER	DIĞER	
RADAR	7175	7	4	11	3	%99,65 %0,35
GSM	13	7160	6	14	7	%99,44 %0,56
TELSİZ	3	7	7180	4	6	%99,72 %0,28
JAMMER	1	1	3	7190	5	%99,86 %0,14
DIĞER	3	2	3	1	7191	%99,87 %0,13
	%99,48 %0,52	%99,45 %0,55	%99,54 %0,46	%99,49 %0,51	%99,51 %0,49	%99,71 %0,29

(b) 120.000'lik Veri Seti

Şekil 4.6. II. Veri Kümesi için ResNet mimarisi karmaşıklık matrisi

4.4. Makine Öğrenmesi ve Derin Öğrenme Performans Sonuçları

K-Ortalama Kümeleme ve K-En Yakın Komşuluk Algoritmaları kullanılarak iki farklı veri kümesi ve 4 farklı veri seti ile gerçekleştirilen sinyal sınıflandırma işlemlerinin doğruluk oranları Şekil 4.7'de grafiksel olarak gösterilmiştir. Her iki algoritma için de II. Veri Kümesi ile gerçekleştirilen işlemlerde doğruluk oranları açısından önemli bir artış olduğu saptanmıştır.




(a) K-Ortalama Kümeleme

(b) K-En Yakın Komşuluk

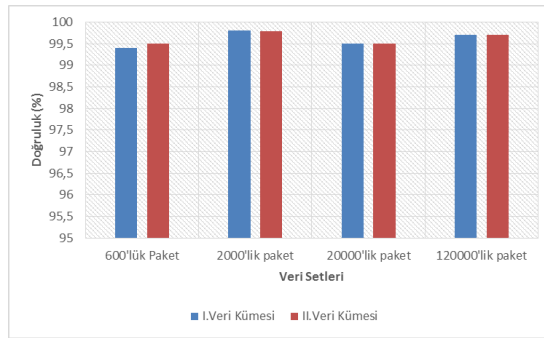
Şekil 4.7. Makine Öğrenmesi sınıflandırma doğruluk oranları

Derin Öğrenme mimarileri kullanılarak iki farklı veri kümesi ve 4 farklı veri seti ile gerçekleştirilen sinyal sınıflandırma işlemlerinin doğruluk oranları, Şekil 4.8'de grafiksel olarak gösterilmiştir. Analizlerden elde edilen bulgular ışığında çalışma kapsamında kullanılan her üç mimari için de II. Veri Kümesi ile gerçekleştirilen sınıflandırma işlemlerinde doğruluk oranları açısından önemli bir artış olduğu tespit edilmiştir.



(a) UNet Mimarisi

(b) AlexNet Mimarisi

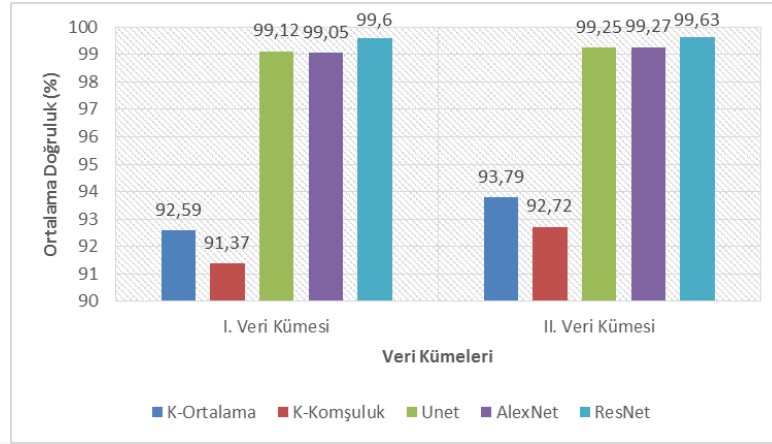


(c) ResNet Mimarisi

Şekil 4.8. Derin Öğrenme mimarileri sınıflandırma doğruluk oranları

İki adet Makine Öğrenme Algoritması ve üç adet Derin Öğrenme Mimarisi kullanılarak iki farklı veri kümesi için dört farklı veri seti ile gerçekleştirilen sinyal sınıflandırma işlemlerinde elde edilen doğruluk oranları Şekil 4.9'da grafiksel olarak

verilmiştir. Bu kapsamda kullanılan derin öğrenme mimarilerinin doğruluk oranlarının makine öğrenmesi algoritmalarına göre daha yüksek olduğu görülmektedir.

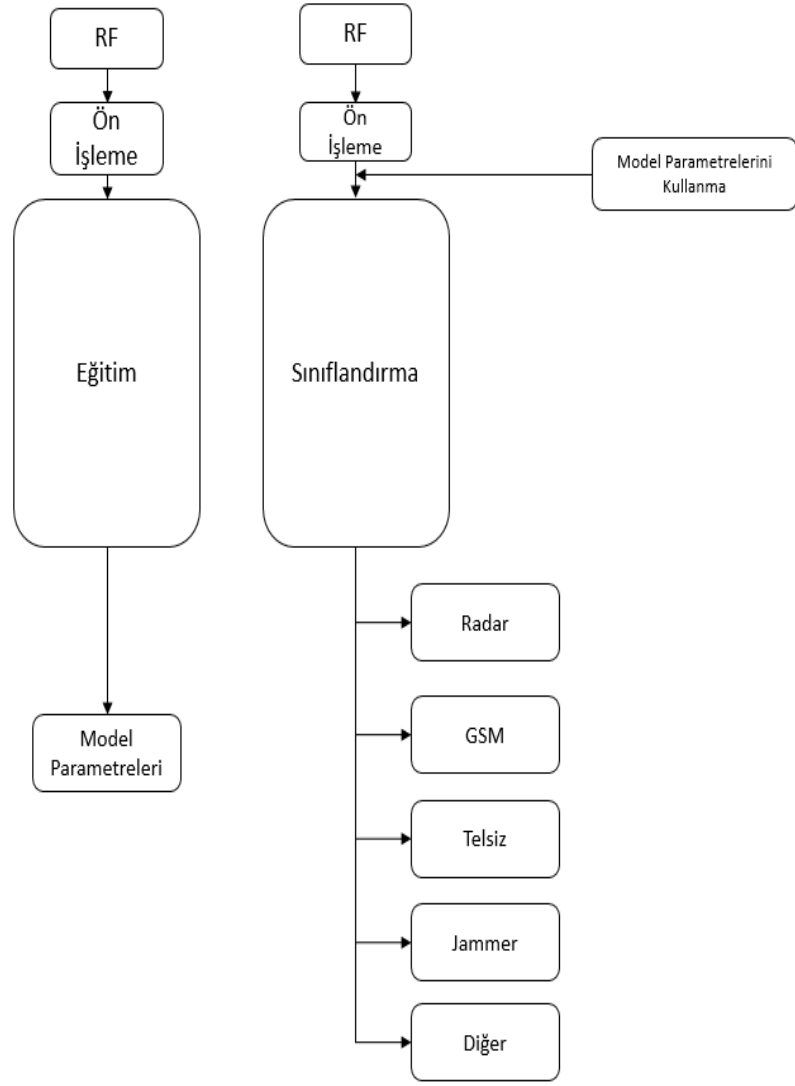


Şekil 4.9. Makine Öğrenmesi algoritmaları ve Derin Öğrenme mimarileri için ortalama doğruluk oranları

Makine Öğrenmesi ile elde edilen sonuçlar incelendiğinde en başarılı algoritmanın II. Veri Kümesi kapsamında 120.000’lik veri seti ile çalıştırılan K-En Yakın Komşuluk olduğu görülmektedir. Bu algoritma için çalışma süresi 250 ms ve doğruluk oranı da % 96.5 olarak hesaplanmıştır. Derin Öğrenme Mimarileri kendi arasında kıyaslandığında I. Veri Kümesi ile yapılan analizlerde en iyi sonuçların ResNet mimarisi ile alındığı görülmektedir. Bu mimari için ortalama çalışma süresi 43285 ms ve doğruluk oranı da % 99.60 olarak hesaplanmıştır. II. Veri Kümesi ile örneklemeden sonra ortalama doğruluk oranının % 99.63’e yükseldiği görülmüştür.

Deneysel çalışmalardan elde edilen sonuçlar incelendiğinde, her iki veri kümesi için veri setlerinin büyüklüğü arttıkça, algoritma ve mimarilerin sınıflandırma doğruluk oranlarının da arttığı görülmektedir. RF kaynağın tanımlanmasına diğer bir deyişle kimliklendirilmesine yönelik olarak geliştirilen bu sinyal sınıflandırma modelinde ResNet Mimarisi ile elde edilen doğruluk oranlarının diğer algoritma ve mimarilere göre daha yüksek olduğu tespit edilmiştir.

Çalışmanın amacı kapsamında gerçekleştirilen deneysel çalışmalardan elde edilen bulgular ışığında problemin çözümüne yönelik olarak önerilen sinyal sınıflandırma modelinin genel akış şeması Şekil 4.10.’da verilmiştir.



Şekil 4.10. Önerilen modelin akış şeması

5. SONUÇ VE ÖNERİLER

Bu çalışmada belirli bir bölge içerisinde yer istasyonlarından toplanmış RF sinyallerinin en kısa süre içerisinde ve en yüksek doğrulukta sınıflandırılması problemine çözüm aranmış olup, insan iş yükünü en aza indirgeyecek analitik bir yaklaşım ortaya konulması hedeflenmiştir.

Çalışmanın amacı kapsamında geliştirilen sınıflandırma modelinde iki farklı veri kümesi için dört farklı veri seti kullanılarak iki farklı Makine Öğrenmesi Algoritmasının (K En Yakın Komşu, K-Kümeleme) ve üç farklı Derin Öğrenme mimarisinin (UNet, AlexNet ve ResNet) sinyal sınıflandırma performansları değerlendirilmiştir.

Geliştirilen sinyal sınıflandırma modelinin çözümünden elde edilen deneysel sonuçlar incelendiğinde ve literatürde yapılan son çalışmalarla karşılaştırıldığında oldukça yüksek bir doğruluk değerinin elde edildiği görülmektedir. Veri Kümelerindeki farklı veri setleri ile yapılan analizlerden elde edilen sonuçlar, örneklenen veri sayısı arttıkça doğruluk oranının da arttığını göstermektedir. Farklı dönüşüm ve örnekleme çeşidi ile oluşturulan II. Veri Kümesi ile yapılan sınıflandırmanın performans değerlerinin I. Veri Kümesi ile gerçekleştirilen sınıflandırma performans değerlerine göre daha yüksek olduğu görülmüştür. Bu sebeple sınıflandırmada değişik örnekleme ile çok farklı görüntüler kullanılarak ne kadar çok veri kümesi oluşturulursa o kadar iyi sonuç elde edilebileceği söylenebilir.

Makine öğrenmesi algoritmaları ile derin öğrenme mimarilerinin sınıflandırma performansları genel olarak değerlendirildiğinde, Derin öğrenme mimarileri çalışma süresi açısından bir miktar kötü sonuç verse de doğruluk oranları dikkate alındığında Makine öğrenmesine göre çok daha iyi sonuçlar elde edilmesini sağlamaktadır. Bununla birlikte Derin Öğrenme Mimarileri kendi aralarında karşılaştırıldığında % 99.63 doğruluk oranı ile ResNet birinci sırada yer alırken, ikinci UNet ve üçüncü de AlexNet mimarisi şeklinde bir sıralama yapılabilir.

Bu çalışma sonrası yapılabilecek ve gelecekteki çalışmalara yol gösterebileceği düşünülen bazı öneriler ve uygulamalar aşağıda sıralanmıştır.

- Bu çalışmada sinyal sınıflandırma modeli sonuçları statik veri kullanılarak elde edilmiş olup, gelecek çalışmalarda dinamik ortamda özellikle sinyalin yayınlanma yerinin tespitine yönelik çalışmalar yapılabilir.

- Modelin çözümünden elde edilen sınıflandırılmış sinyal verileri, sivil ve askeri hava taşımacılığının güvenliğine katkı sağlayabilecek çeşitli analizlerde kullanılabilir.
- Özellikle havacılık alanında Makine Öğrenmesi ve Derin Öğrenme Mimarilerini kullanarak veri örnekleme yöntemi ile ilgili çok az sayıda çalışma bulunmaktadır. Bu kapsamda geliştirilecek uygulamalar ile gerek askeri gerekse sivil havacılık güvenliğinin sağlanmasında kullanılabilir bir ürüne dönüştürülebilir.
- Farklı derin öğrenme mimarileri ya da algoritmalar ile sinyal sınıflandırma modeli performans değerlendirmesi çeşitlendirilebilir. Bunun yanı sıra özellikle sinyal modülasyon sınıflandırmasında farklı dönüşüm yöntemlerinden yararlanılabilir.
- Sınıflandırılmış sinyallerin harita üzerinde görsellenebilmesi amacıyla Coğrafi Bilgi Sistemi (CBS) uygulamalarından yararlanılabilir.
- Özellikle aldatici sinyal yayınının tespit edilmesine yönelik, sistem tarafından üretilen aldatici sinyaller Derin Öğrenme Mimarileri ile analiz edilerek aldaticının etkinliğini azaltmak ve koordinatlarını tespit etmek için kullanılabilir.

KAYNAKÇA

- Abbasoğlu, F. (2019). *Öznitelik çıkarım ve evrimsel öznitelik seçim metotlarının eeg sinyallerinin sınıflandırma başarısına etkileri*. Yayınlanmamış Yüksek Lisans Tezi. İstanbul. Fatih Sultan Mehmet Vakıf Üniversitesi, Lisansüstü Eğitim Enstitüsü.
- Aizenberg, I.N., Aizenberg, N.N. and Vandewalle, J. (2000). Multiple-Valued Threshold Logic and Multi-Valued Neurons. *In Multi-Valued and Universal Binary Neurons*, Springer, Boston, MA, 25-80
- Ardila-Rey, J. A., Martínez-Tarifa, J. M., Mejino, M., Albarracín, R., Rojas-Moreno, M. V. Robles, G. (2013). Chromatic classification of RF signals for partial discharges and noise characterization. *In 2013 IEEE International Conference on Solid Dielectrics (ICSD)* (pp. 67-70). IEEE.
- Cao, J., Zhu, R., Shi, G., Bai, M. (2023, July). Modulation recognition based on deep learning network. *In Proceedings of the 2023 6th International Conference on Signal Processing and Machine Learning* (pp. 357-362).
- Chen, Y., Xu, X., and Qin, X. (2023). An Open-Set Modulation Recognition Scheme With Deep Representation Learning. *IEEE Communications Letters*, 27, 851-855.
- Güner, A. and Kaya, Ismail. (2013). Novel automatic modulation classification method employing higher-order cumulants and constellation histogram in the presence of CFO. 1-4. 10.1109/SIU.2013.6531430.
- Elmaghoub, A., and Hamdaoui, B. (2020). Leveraging Hardware-Impaired Out-of-Band Information Through Deep Neural Networks for Robust Wireless Device Classification. *arXiv preprint arXiv:2004.11126*.
- Fang, Y., Zhai, Q., Zhang, Z., Yang, J. (2023). Change Point Detection for Fine-Grained MFR Work Modes with Multi-Head Attention-Based Bi-LSTM Network. *Sensors* (Basel, Switzerland), 23.
- Fan, J., Wu, L., Zhang, J., Dong, J., Wen, Z., Zhang, Z. (2023). Deep Learning-Aided Modulation Recognition for Non-Orthogonal Signals. *Sensors* (Basel, Switzerland), 23.
- Gao, X., Shan, C., Hu, C., Niu, Z., Liu, Z. (2019). An Adaptive Ensemble Machine Learning Model for Intrusion Detection. *IEEE Access*, 7, 82512-82521.
- Gao, G., Hu, X., Li, B., Wang, W., Ghannouchi, F. M. (2023). CrossTLNet: A Multitask-Learning-Empowered Neural Network with Temporal Convolutional Network–Long Short-Term Memory for Automatic Modulation Classification. *Electronics*, 12(22), 4668.

- Ghauri S.A. (2016) KNN Based Classification of Digital Modulated Signals. *International Islamic University Malaysia Engineering Journal*. 2016;17(2). doi:10.31436/iiumej.v17i2.641
- Haznedar, B., Arslan, M. T. ve Kalınlı, A. (2017). Karaciğer mikrodizi kanser verisinin sınıflandırılması için genetik algoritma kullanarak ANFIS'in eğitilmesi. *Sakarya Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 21(1), 2017, 54-62.
- Huang, S., Chai, L., Li, Z., Zhang, D., Yao, Y., Zhang, Y., Feng, Z. (2019). Automatic Modulation Classification Using Compressive Convolutional Neural Network. *IEEE Access*, 7, 79636-79643.
- Huang, L., Pan, W., Zhang, Y., Qian, L., Gao, N., Wu, Y. (2019). Data augmentation for deep learning-based radio modulation classification. *IEEE access*, 8, 1498-1506.
- Hussein, H.S., Essai Ali, M.H., Ismeil, M.A., Shaaban, M.N., Mohamed, M.L., Atallah, H. (2023). Automatic Modulation Classification: Convolutional Deep Learning Neural Networks Approaches. *IEEE Access*, 11, 98695-98705.
- Karasu, S. ve Saraç, Z. (2020). Güç kalitesi bozulmalarının hilbert-huang dönüşümü, genetik algoritma ve yapay zeka/makine öğrenmesi yöntemleri ile sınıflandırılması. *Politeknik Dergisi*, 23(4), 1219-1229.
- Karatas, G., (2020). *Derin Öğrenme Tabanlı Saldırı Tespit Sistemi*. Yayınlanmamış Doktora Tezi. İstanbul. Marmara Üniversitesi, Fen Bilimleri Enstitüsü.
- Katyara, S., Staszewski, L., and Leonowicz, Z. (2020). Signal parameter estimation and classification using mixed supervised and unsupervised machine learning approaches. *IEEE Access*, 8, 92754-92764.
- Krizhevsky, A., Sutskever, I., and Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. *In Advances in neural information processing systems* (pp. 1097-1105).
- Ktonas, P. Y. and Papp, N. (1980). Instantaneous envelope and phase extraction from real signals: theory, implementation, and an application to EEG analysis. *Signal Processing*, 2(4): 373-385.
- Kumar, Y., Sheoran, M., Jajoo, G., Yadav, S. K. (2020). Automatic modulation classification based on constellation density using deep learning. *IEEE Communications Letters*, 24(6), 1275-1278.
- Lee, J. H., Kim, K. Y., and Shin, Y. (2019). Feature image-based automatic modulation classification method using CNN algorithm. *In 2019 International Conference on Artificial Intelligence in Information and Communication (ICAIIIC)* (pp. 1-4). IEEE.
- Li, J., Zhang, H., Ou, J., and Wang, W. (2021). A Multipulse Radar Signal Recognition Approach via HRF-Net Deep Learning Models. *Computational Intelligence and Neuroscience*, 2021(1), 9955130.

- Li, Y., Shao, G., and Wang, B. (2019). Automatic modulation classification based on bispectrum and CNN. *In 2019 IEEE 8th Joint International Information Technology and Artificial Intelligence Conference (ITAIC)* (pp. 311-316). IEEE.
- Liu, K. C., Hung, K. H., Hsieh, C. Y., Huang, H. Y., Chan, C. T., Tsao, Y. (2020). Deep-Learning-Based Signal Enhancement of Low-Resolution Accelerometer for Fall Detection Systems. *IEEE Transactions on Cognitive and Developmental Systems*, 14(3), 1270-1281.
- Liu, M., Liao, G., Zhao, N., Song, H., Gong, F. (2021). Data-Driven Deep Learning for Signal Classification in Industrial Cognitive Radio Networks. *IEEE Transactions on Industrial Informatics*, 17, 3412-3421.
- Liu, K., Xiang, X., and Yin, L. (2022). Radio Frequency Database Construction and Modulation Recognition in Wireless Sensor Networks. *Sensors*, 22(15), 5715.
- Ma, J., Lin, S. C., Gao, H., Qiu, T. (2019). Automatic modulation classification under non-Gaussian noise: A deep residual learning approach. *In ICC 2019-2019 IEEE International Conference on Communications (ICC)* (pp. 1-6). IEEE.
- Ma, J., ve Jiang, F., (2021). Automatic Modulation Classification Using Fractional Low Order Cyclic Spectrum and Deep Residual Networks in Impulsive Noise. *2021 IEEE MTT-S International Wireless Symposium (IWS)*, Nanjing, China, 2021, pp. 1-3.
- Manjula, M., Mishra, S., and Sarma, A. V. R. S., (2013). Empirical mode decomposition with Hilbert transform for classification of voltage sag causes using probabilistic neural network. *International Journal Of Electrical Power and Energy Systems*, 44(1): 597-603.
- Neves, C.N., Feitosa, R.Q., Adarme, M.O., Giraldo, G.A. (2023). Combining recurrent and residual learning for deforestation monitoring using multitemporal SAR images. *ArXiv*, abs/2310.05697.
- Okyay, S. (2016). *Beyin görüntüleme tekniklerinin alzheimer hastalığı erken tanı tahmininde kullanılması*. Yayınlanmamış Yüksek Lisans Tezi. Eskişehir. Anadolu Üniversitesi Tıp Fakültesi.
- O'Shea, T. J., Roy, T., and Clancy, T. C. (2018). Over-the-air deep learning based radio signal classification. *IEEE Journal of Selected Topics in Signal Processing*, 12(1), 168-179.
- Özcan, T. (2020). *Derin öğrenme ile insan edimlerinin tanınması*. Yayınlanmamış Doktora Tezi. Kayseri. Erciyes Üniversitesi, Fen Bilimleri Enstitüsü.
- Peng, S., Jiang, H., Wang, H., Alwageed, H.S., Zhou, Y., Sebdani, M.M., Yao, Y. (2019). Modulation Classification Based on Signal Constellation Diagrams and Deep Learning. *IEEE Transactions on Neural Networks and Learning Systems*, 30, 718-727.

- Peng, S., Sun, S., and Yao, Y. D. (2021). A survey of modulation classification using deep learning: Signal representation and data preprocessing. *IEEE Transactions on Neural Networks and Learning Systems*, 33(12), 7020-7038.
- Rajendran S., W. Meert, D. Giustiniano, V. Lenders, and S. Pollin, (2018). Deep learning models for wireless signal classification with distributed lowcost spectrum sensors. *IEEE Trans. Cognit. Commun. Netw.*, Vol. 4, No: 3, pp. 433–445.
- Rajendran, S., Meert, W., Lenders, V., Pollin, S. (2019). Unsupervised Wireless Spectrum Anomaly Detection With Interpretable Features. *IEEE Transactions on Cognitive Communications and Networking*, 5, 637-647.
- Ronneberger, O., Fischer, P., and Brox, T. (2015). U-Net: Convolutional Networks for Biomedical Image Segmentation. *ArXiv*, abs/1505.04597.
- Russakovsky, O., Deng, J., Su, H., Krause, J., Satheesh, S., Ma, S., Berg, A. C. (2015). Imagenet large scale visual recognition challenge. *International Journal of Computer Vision*, 115(3), 211-252.
- Sachnev, V. and Kim, H. J. (2014). Parkinson disease classification based on binary coded genetic algorithm and extreme learning machine. In *2014 IEEE Ninth International Conference on Intelligent Sensors, Sensor Networks and Information Processing (ISSNIP)* (pp. 1-6). IEEE.
- Saeed, U., Shah, S. Y., Shah, S. A., Ahmad, J., Alotaibi, A. A., Althobaiti, T., Abbasi, Q. H. (2021). Discrete human activity recognition and fall detection by combining FMCW RADAR data of heterogeneous environments for independent assistive living. *Electronics*, 10(18), 2237.
- Simonyan, K. and Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*.
- Sokolova, M. and Lapalme, G. (2009). A systematic analysis of performance measures for classification tasks. *Information processing & management*, 45(4), 427-437.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Rabinovich, A. (2015). Going deeper with convolutions. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 1-9).
- Şeker, A., Dirı, B., ve Balık, H. H. (2017). Derin Öğrenme Yöntemleri ve Uygulamaları Hakkında Bir İnceleme. *Gazi Mühendislik Bilimleri Dergisi*, 3(3), 47-64.
- Talha, M., Sarfraz, M., Rahman, A., Ghauri, S. A., Mohammad, R. M., Krishnasamy, G., Alkharraa, M. (2023). Voting-based deep convolutional neural networks (VB-DCNNs) for M-QAM and M-PSK signals classification. *Electronics*, 12(8), 1913.
- Tang, B., Tu, Y., Zhang, Z., Lin, Y. (2018). Digital signal modulation classification with data augmentation using generative adversarial nets in cognitive radio networks. *IEEE Access*, 6, 15713-15722.

- Tu, Y. and Lin, Y. (2019). Deep neural network compression technique towards efficient digital signal modulation recognition in edge device. *IEEE Access*, 7, 58113-58119.
- Türkyılmaz, A.H., Burakçın, A.B., Eroğlu, U., Kaplan, E., (2012). Sayısal Modülasyon Tekniklerinin Simülasyonu. Üniversite Proje Raporu. Trabzon. Karadeniz Teknik Üniversitesi.
- Vakili, M., Ghamsari, M., and Rezaei, M. (2020). Performance analysis and comparison of machine and deep learning algorithms for IoT data classification. *arXiv preprint arXiv:2001.09636*.
- Wang, F., Wang, Y., and Chen, X. (2017). Graphic constellations and DBN based automatic modulation classification. In *2017 IEEE 85th vehicular technology conference (VTC Spring)* (pp. 1-5). IEEE.
- Wang, Y., Liu, M., Yang, J., Gui, G. (2019). Data-driven deep learning for automatic modulation recognition in cognitive radios. *IEEE Transactions on Vehicular Technology*, 68(4), 4074-4077.
- Wang, F., Yang, C., Huang, S., Wang, H. (2019). Automatic modulation classification based on joint feature map and convolutional neural network. *IET Radar, Sonar & Navigation*, 13(6), 998-1003.
- Wang, J., Qiao, X., Zhang, J., Sun, C., Liu, F. (2023). Modulated Signal Open-Set Identification of Complex Convolutional Neural Networks Combined with Incremental Learning. *2023 IEEE 16th International Conference on Electronic Measurement & Instruments (ICEMI)*, 314-320.
- Wei, Z., Ju, Y. And Song, M. (2018). A method of underwater acoustic signal classification based on deep neural network. In *2018 5th International Conference on Information Science and Control Engineering (ICISCE)* (pp. 46-50). IEEE.
- Weyl, H. (1944). David Hilbert. *1862-1943, Obituary Notices of Fellows of the Royal Society*, Volume 4, Issue 13, 547 – 553.
- Wu, Q., Feres, C., Kuzmenko, D., Zhi, D., Yu, Z., Liu, X., ‘Leo’Liu, X. (2018). Deep learning based RF fingerprinting for device identification and wireless security. *Electronics Letters*, 54(24), 1405-1407.
- Wu H., Y. Li, L. Zhou, J. Meng (2019). Convolutional neural network and multi-feature fusion for automatic modulation classification, *Electron. Lett.*, vol. 55, no. 16, pp. 895–897.
- Xiao, Y., Liu, W., and Gao, L. (2019). Radar signal recognition based on transfer learning and feature fusion. *Mobile Networks and Applications*, 1-9.
- Xie, X., Ni, Y., Peng, S., and Yao, Y. D. (2019, May). Deep learning based automatic modulation classification for varying SNR environment. In *2019 28th Wireless and Optical Communications Conference (WOCC)* (pp. 1-5). IEEE.

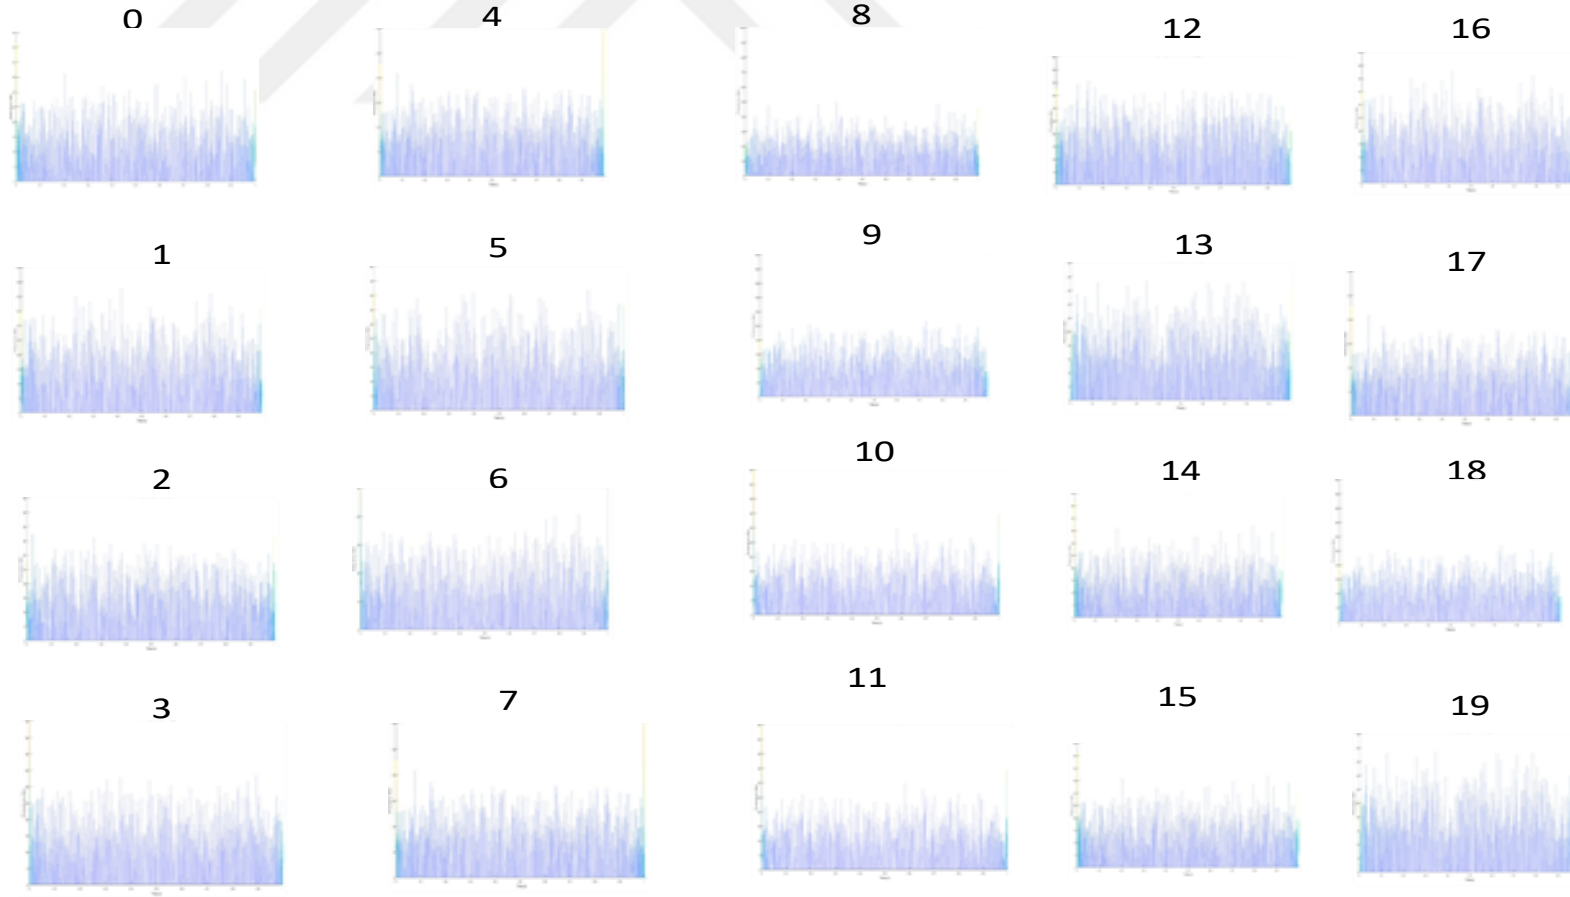
- Xu, J. and Lin, Z. (2022). Modulation and classification of mixed signals based on deep learning. *arXiv preprint arXiv:2205.09916*.
- Yang, Y., Chen, M., Wang, Y., Ma, P. (2020). Digital Signal Modulation Classification using Data Conversion Method based on Convolutional Neural Network. *Journal of Physics: Conference Series*, 1693.
- Ying, S., Huang, S., Chang, S., Yang, Z., Feng, Z., Guo, N. (2023). A convolutional and transformer based deep neural network for automatic modulation classification. *China Communications*, 20, 135-147.
- Yıldız, O., Tez, M., Bilge, H.Ş., Akçayol, M.A., Güler, İ.,(2012). Meme Kanser Sınıflandırması İçin Veri Füzyonu ve Genetik Algoritma Tabanlı Gen Seçimi. *Journal of the Faculty of Engineering and Architecture of Gazi University Cilt 27, No 3, 659-668, 2012 Vol 27, No 3, 659-668, 2012*.
- Yu, J., Hu, A., Zhou, F., Xing, Y., Yu, Y., Li, G., Peng, L. (2019). Radio frequency fingerprint identification based on denoising autoencoders. In *2019 International Conference on Wireless and Mobile Computing, Networking and Communications (WiMob)* (pp. 1-6). IEEE.
- Zhang, J., Jones, G. R., Spencer, J. W., Jarman, P., Kemp, I. J., Wang, Z., Aggarwal, R. K. (2005). Chromatic classification of RF signals produced by electrical discharges in HV transformers. *IEE Proceedings-Generation, Transmission and Distribution*, 152(5), 629-634.
- Zhang, S., Li, X., Zong, M., Zhu, X., Wang, R. (2017). Efficient kNN classification with different numbers of nearest neighbors. *IEEE transactions on neural networks and learning systems*, 29(5), 1774-1785.
- Zhang M., Zeng, Y., Han, Z., Gong, Y., (2018). Automatic modulation recognition using deep learning architectures, in Proc. *IEEE 19th Int. Workshop Signal Process. Adv. Wireless Commun. (SPAWC)* pp. 1–5.
- Zha, X., Peng, H., Qin, X., Li, G., Yang, S. (2019). A Deep Learning Framework for Signal Detection and Modulation Classification. *Sensors* (Basel, Switzerland), 19.
- Zhang Z., C. Wang, C. Gan, S. Sun, M. Wang (2019). Automatic modulation classification using convolutional neural network with features fusion of SPWVD and BJD. *IEEE Trans. Signal Inf. Process. Netw.*, vol. 5, no. 3, pp. 469–478, Sep.
- Zhang, X., Li, T., Gong, P., Liu, R., Zha, X., Tang, W. (2022). Open set recognition of communication signal modulation based on deep learning. *IEEE Communications Letters*, 26(7), 1588-1592.
- Zhang, Z., Zhu, M., Liu, J., Li, Y., Wang, S. (2023). Class Information Guided Reconstruction for Automatic Modulation Open-Set Recognition. *arXiv preprint arXiv:2312.13023*.

Zhang, Z., Zhu, M., Li, Y., Li, Y., Wang, S. (2023). Joint recognition and parameter estimation of cognitive radar work modes with LSTM-transformer. *Digit. Signal Process.* 140, 104081.

Zorlu, H. E., Çeven, M., Taşdöken, S., Özer, H. (2012). Implementation of PSK and QAM demodulators on FPGA. *In 2012 20th Signal Processing and Communications Applications Conference (SIU)* (pp. 1-4). IEEE.



Ek-1. HH dönüşümü ile oluşturulmuş örnek görüntüler grubu



ÖZGEÇMİŞ

ORCID NO: 0000-0002-3414-1771

Ad Soyad : Yalçın KAPLAN

Yabancı Dil : İngilizce

Eğitim ve Mesleki Geçmişi:

- 2011-2014, Fen Bilimleri Enstitüsü, Elektrik ve Bilgisayar Mühendisliği Yüksek Lisans Bölümü, İSTANBUL
- 2018-2022, Selçuk Üniversitesi, Hukuk Fakültesi, Hukuk Bölümü, KONYA
- 2002-2006, Mühendislik Fakültesi, Elektrik Elektronik Mühendisliği Bölümü
- 2009-Devam, Mühendis Subay, Sahil Güvenlik Komutanlığı

Eğitim ve Mesleki Geçmişi:

- 2014, Kaplan Y., Saray U., “Examination of Turkey’s Renewable Energy and Fossil Energy Consumption with Analytic Hierarchy Process (AHP)”, Journal of New Results in Science, ISSN: 1304-7981, 5(2014), 28-36.
- 2014, Kaplan Y., Saray U., Azkeskin E., “Çevre Kirliliğine Neden Olan SO₂ ve PM₁₀ maddelerinin incelenmesi: Levenberg-Marquardt Algoritması Kullanılarak PM₁₀ Tahminin Yapılması ve Hata Oranın Hesaplanması” Afyon Kocatepe Üniversitesi Fen ve Mühendislik Bilimleri Dergisi, ISSN: 2147-5296, 025201, 1-6 Cilt 14(2),2014.
- Kaplan Y., Bayat O., Turan F.K., Tüzüner A., “Güneş Enerjisi için Yapay Sinir Ağları ile Antalya İlinin sıcaklık Tahmini”, UTES’13-9 Ulusal Temiz Enerji Sempozyumu, Selçuk Üniversitesi Süleyman Demirel Kültür Merkezi, 25-28 Aralık 2013- 270-275, Konya.
- Kaplan Y., Saray U., Emeksiz C., Yeşilnacar Y., O., Önal S., Karaca V., “Yapay Sinir Ağı geri yayılım algoritması kullanılarak rüzgâr hızı tahmini”, UTES’13-9 Ulusal Temiz Enerji Sempozyumu, Selçuk Üniversitesi Süleyman Demirel Kültür Merkezi, 25-28 Aralık 2013- 779-783, Konya.
- Kaplan Y., Saray U., “Genetik Algoritma Kullanılarak SO₂ ve PM₁₀ tahminin yapılarak hata oranının tespit edilmesi ve çevre kirliliği açısından bir model geliştirilmesi”, Poster bildiri, Bildiri Özet Kitabı Sayfa 114, 5. Ekoloji Sempozyumu.

Mesleki Birlik/Dernek/Kuruluş Üyelikleri:

- 2022, Ankara Barosu, Ankara.
- 2006-2016, Elektrik Mühendisler Odası, Antalya.