T.C.
İSTANBUL ÜNİVERSİTESİ-CERRAHPAŞA
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

DERİN ÖĞRENME ALGORİTMALARIYLA OTOMATİK MODÜLASYON TANIMLAMA

Ayşenur ÇAMLIBEL

DANIŞMAN
Dr. Öğr. Üyesi Bahattin KARAKAYA

Elektrik-Elektronik Mühendisliği Anabilim Dalı

Elektrik-Elektronik Mühendisliği Programı

İSTANBUL-2022

Bu çalışma, 19.01.2022 tarihinde aşağıdaki jüri tarafından Elektrik-Elektronik Mühendisliği Anabilim Dalı, Elektrik-Elektronik Mühendisliği Programı'nda Yüksek Lisans tezi olarak kabul edilmiştir.

Tez Jürisi

Dr. Öğr. Üyesi Bahattin KARAKAYA
İstanbul Üniversitesi-Cerrahpaşa
Mühendislik Fakültesi

Doç. Dr. Abdurrahim AKGÜNDOĞDU
İstanbul Üniversitesi-Cerrahpaşa
Mühendislik Fakültesi

Dr. Öğr. Üyesi Mürsel ÖNDER
Tokat Gaziosmanpaşa Üniversitesi
Mühendislik ve Doğa Bilimleri Fakültesi

20.04.2016 tarihli Resmi Gazete'de yayımlanan Lisansüstü Eğitim ve Öğretim Yönetmeliğinin 9/2 ve 22/2 maddeleri gereğince; Bu Lisansüstü teze, İstanbul Üniversitesi-Cerrahpaşa'nın abonesi olduğu intihal yazılım programı kullanılarak Lisansüstü Eğitim Enstitüsü'nün belirlemiş olduğu ölçütlere uygun rapor alınmıştır.

ÖNSÖZ

Tezimi yazma sürecinde hiçbir desteğini ve yardımını esirgemeyen saygıdeğer danışman hocam Dr.Öğr.Üyesi Bahattin KARAKAYA'ya en içten dileklerimle teşekkür ederim.

Tez konumu seçmemden başlayıp teslim sürecine kadar tüm tez çalışmamda beni en doğru şekilde yönlendiren, her türlü desteği ve imkanı sağlayan, bilgi ve birikimlerini benimle paylaşan sevgili hocam Arş.Gör.Dr. Yeşim HEKİM TANÇ'a sonsuz teşekkürlerimi sunarım.

Tüm İstanbul Üniversitesi-Cerrahpaşa Elektrik-Elektronik Mühendisliği Bölümü hocalarıma çok teşekkür ederim.

Tez çalışmam boyunca desteğini esirgemeyen Mohamed L Traoré'e teşekkür ederim. Volkan Ünal'a tüm çalışmam boyunca beni desteklediği ve motivasyon sağladığı için teşekkür ederim.

Hayatım boyunca maddi manevi her zaman yanımda olan yüksek lisans yapmam konusunda beni cesaretlendiren ve destekleyen canım anneme, babama, abim ve ailesine, canım kardeşim Baha'ya çok çok teşekkür ederim.

Ocak 2022 Ayşenur ÇAMLIBEL

İÇİNDEKİLER

Sayfa No

ÖNSÖZ ..... **iv**
İÇİNDEKİLER ..... **v**
ŞEKİL LİSTESİ ..... **viii**
TABLO LİSTESİ ..... **x**
SİMGE VE KISALTMA LİSTESİ ..... **xi**
ÖZET ..... **xiv**
SUMMARY ..... **xvi**
1. GİRİŞ **1**
2. GENEL KISIMLAR **3**
2.1. MODÜLASYON 3
2.2. OTOMATİK MODÜLASYON TANIMA 3
2.2.1. Karar Teorisine Dayalı Modülasyon Sınıflandırma Yöntemleri 5
2.2.2. Örüntü Tanıma Teorisine Dayalı Modülasyon Sınıflandırma Yöntemleri 8
2.3. DERİN ÖĞRENME 11
2.3.1. Yapay Sinir Ağlarının Yapısı 13
2.3.2. Derin Öğrenme Algoritmaları 14
2.3.2.1. Evrişimli Sinir Ağları 14
2.3.2.2. Özyinelemeli Sinir Ağları 15
2.3.2.3. Geçitlenmiş Özyinelemeli Birimler ve Uzun Kısa Vadeli Bellek Modeli 17
2.3.3. Sinyal ve Modülasyon Tanıma için Derin Öğrenme ile Yapılan Çalışmalar 17
2.4. SENKRONİZE SIKIŞTIRMA DÖNÜŞÜMÜ 21
2.4.1. Fourier Tabanlı Senkronize Sıkıştırma Dönüşümü 23
3. MALZEME VE YÖNTEM **25**
3.1. VERİ SETİ 25
3.2. VERİ ÖN İŞLEME 27
3.2.1. Veri Seti İçerisindeki Sinyallerin FSST Görüntülerinin Alınması 27
3.2.2. Verilerin Karıştırılması 30
3.2.3. Hedef Sınıfların Sayısal Verilere Dönüştürülmesi 31
3.2.4. Veri Setinin Eğitim ve Test Sınıflarına Ayrılması 31

3.3. MODEL 31
3.3.1. Geliştirilen CNN Modeli ve Parametreleri 32
3.3.2. Modelin Eğitilmesi 34
3.3.3. Modelin Değerlendirilmesi 34
3.4. KULLANILAN TEKNOLOJİLER 35
4. BULGULAR 36
4.1. MODELE AİT METRİK FONKSİYONLARI 36
4.1.1. 100 Epoch Sayısı İçin Modele Ait Metrik Fonksiyonları 36
4.1.2. 200 Epoch Sayısı İçin Modele Ait Metrik Fonksiyonları 37
4.1.3. 300 Epoch Sayısı İçin Modele Ait Metrik Fonksiyonları 38
4.2. GENEL MODÜLASYON SINIFLANDIRMA RAPORU VE HATA MATRİSİ 39
4.3. SNR DEĞERLERİNE GÖRE MODÜLASYON TANIMA SONUÇLARI 42
4.3.1. SNR -20 dB Değeri İçin Genel Sınıflandırma Raporu ve Hata Matrisi 42
4.3.2. SNR -18 dB Değeri İçin Genel Sınıflandırma Raporu ve Hata Matrisi 43
4.3.3. SNR -16 dB Değeri İçin Genel Sınıflandırma Raporu ve Hata Matrisi 44
4.3.4. SNR -14 dB Değeri İçin Genel Sınıflandırma Raporu ve Hata Matrisi 46
4.3.5. SNR -12 dB Değeri İçin Genel Sınıflandırma Raporu ve Hata Matrisi 47
4.3.6. SNR -10 dB Değeri İçin Genel Sınıflandırma Raporu ve Hata Matrisi 48
4.3.7. SNR -8 dB Değeri İçin Genel Sınıflandırma Raporu ve Hata Matrisi 49
4.3.8. SNR -6 dB Değeri İçin Genel Sınıflandırma Raporu ve Hata Matrisi 51
4.3.9. SNR -4 dB Değeri İçin Genel Sınıflandırma Raporu ve Hata Matrisi 52
4.3.10. SNR -2 dB Değeri İçin Genel Sınıflandırma Raporu ve Hata Matrisi 53
4.3.11. SNR 0 dB Değeri İçin Genel Sınıflandırma Raporu ve Hata Matrisi 54
4.3.12. SNR 2 dB Değeri İçin Genel Sınıflandırma Raporu ve Hata Matrisi 55
4.3.13. SNR 4 dB Değeri İçin Genel Sınıflandırma Raporu ve Hata Matrisi 56
4.3.14. SNR 6 dB Değeri İçin Genel Sınıflandırma Raporu ve Hata Matrisi 57
4.3.15. SNR 8 dB Değeri İçin Genel Sınıflandırma Raporu ve Hata Matrisi 58
4.3.16. SNR 10 dB Değeri İçin Genel Sınıflandırma Raporu ve Hata Matrisi 59
4.3.17. SNR 12 dB Değeri İçin Genel Sınıflandırma Raporu ve Hata Matrisi 61
4.3.18. SNR 14 dB Değeri İçin Genel Sınıflandırma Raporu ve Hata Matrisi 62
4.3.19. SNR 16 dB Değeri İçin Genel Sınıflandırma Raporu ve Hata Matrisi 63
4.3.20. SNR 18 dB Değeri İçin Genel Sınıflandırma Raporu ve Hata Matrisi 64
5. TARTIŞMA VE SONUÇ 66
KAYNAKLAR 67

EKLER **72**
EK 1. Geliştirilen CNN Modelinin Çizdirilmesi 72
ÖZGEÇMİŞ **73**

ŞEKİL LİSTESİ

Sayfa No

Şekil 2.1: Genel otomatik modülasyon tanıma sistemi. 4
Şekil 2.2: Rakam sınıflandırma için derin bir sinir ağı [34]. 11
Şekil 2.3: Rakam sınıflandırma modeliyle öğrenilen derin gösterimler [34]. 12
Şekil 2.4: Sinir ağı, katmanlar, kayıp fonksiyonu ve optimizer arasındaki ilişki [34]. 13
Şekil 2.5: Evrişim işleminin çalışma yapısı [34]. 15
Şekil 2.6: Döngü içinde özyinelemeli bir sinir ağı [34]. 16
Şekil 2.7: Zaman üzerinde açılmış basit bir RNN yapısı [34]. 16
Şekil 2.8: Basit RNN yapısına taşıyıcı eklenmesi LSTM'ye gidiş [34]. 17
Şekil 3.1: RadioML 2016.10A veri setindeki sinyallere ait örnek görüntüler. 26
Şekil 3.2: Zaman-frekans dönüşümleri alınan karmaşık sinyallere ait örnek görüntüler. 28
Şekil 3.3: Leaky ReLU aktivasyon fonksiyonu. 32
Şekil 4.1: 100 epoch sayısı için modele ait doğrulama fonksiyonu. 36
Şekil 4.2: 100 epoch sayısı için modele ait kayıp fonksiyonu. 36
Şekil 4.3: 200 epoch sayısı için modele ait doğrulama fonksiyonu. 37
Şekil 4.4: 200 epoch sayısı için modele ait kayıp fonksiyonu. 38
Şekil 4.5: 300 epoch sayısı için modele ait doğrulama fonksiyonu. 38
Şekil 4.6: 300 epoch sayısı için modele ait kayıp fonksiyonu. 39
Şekil 4.7: Modele ait modülasyon tanıma hata matrisi. 41
Şekil 4.8: SNR -20 dB değeri için modele ait modülasyon sınıflandırma hata matrisi. 42
Şekil 4.9: SNR -18 dB değeri için modele ait modülasyon sınıflandırma hata matrisi. 44
Şekil 4.10: SNR -16 dB değeri için modele ait modülasyon sınıflandırma hata matrisi. 45
Şekil 4.11: SNR -14 dB değeri için modele ait modülasyon sınıflandırma hata matrisi. 46
Şekil 4.12: SNR -12 dB değeri için modele ait modülasyon sınıflandırma hata matrisi. 48
Şekil 4.13: SNR -10 dB değeri için modele ait modülasyon sınıflandırma hata matrisi. 49
Şekil 4.14: SNR -8 dB değeri için modele ait modülasyon sınıflandırma hata matrisi. 50
Şekil 4.15: SNR -6 dB değeri için modele ait modülasyon sınıflandırma hata matrisi. 51
Şekil 4.16: SNR -4 dB değeri için modele ait modülasyon sınıflandırma hata matrisi. 52
Şekil 4.17: SNR -2 dB değeri için modele ait modülasyon sınıflandırma hata matrisi. 53
Şekil 4.18: SNR 0 dB değeri için modele ait modülasyon sınıflandırma hata matrisi. 54
Şekil 4.19: SNR 2 dB değeri için modele ait modülasyon sınıflandırma hata matrisi. 55

Şekil 4.20: SNR 4 dB değeri için modele ait modülasyon sınıflandırma hata matrisi. 57
Şekil 4.21: SNR 6 dB değeri için modele ait modülasyon sınıflandırma hata matrisi. 58
Şekil 4.22: SNR 8 dB değeri için modele ait modülasyon sınıflandırma hata matrisi. 59
Şekil 4.23: SNR 10 dB değeri için modele ait modülasyon sınıflandırma hata matrisi. 60
Şekil 4.24: SNR 12 dB değeri için modele ait modülasyon sınıflandırma hata matrisi. 61
Şekil 4.25: SNR 14 dB değeri için modele ait modülasyon sınıflandırma hata matrisi. 62
Şekil 4.26: SNR 16 dB değeri için modele ait modülasyon sınıflandırma hata matrisi. 64
Şekil 4.27: SNR 18 dB değeri için modele ait modülasyon sınıflandırma hata matrisi. 65

TABLO LİSTESİ

Sayfa No

Tablo 2.1: Örüntü tanımaya dayalı modülasyon sınıflandırma literatür taraması-1 [7]. 9
Tablo 2.2: Örüntü tanımaya dayalı modülasyon sınıflandırma literatür taraması-2 [7]. 10
Tablo 3.1: RadioML 2016.10A veri seti içerisinde bulunan modülasyon türleri. 25
Tablo 3.2: RadioML 2016.10A veri seti içerisinde bulunan verinin boyutu. 26
Tablo 3.3: Eğitim ve test verilerine ait değerler. 31
Tablo 3.4: Model ve model parametreleri. 33
Tablo 4.1: Modele ait modülasyon sınıflandırma raporu. 40
Tablo 4.2: SNR -20 dB değeri için modele ait modülasyon sınıflandırma raporu. 42
Tablo 4.3: SNR -18 dB değeri için modele ait modülasyon sınıflandırma raporu. 43
Tablo 4.4: SNR -16 dB değeri için modele ait modülasyon sınıflandırma raporu. 44
Tablo 4.5: SNR -14 dB değeri için modele ait modülasyon sınıflandırma raporu. 46
Tablo 4.6: SNR -12 dB değeri için modele ait modülasyon sınıflandırma raporu. 47
Tablo 4.7: SNR -10 dB değeri için modele ait modülasyon sınıflandırma raporu. 48
Tablo 4.8: SNR -8 dB değeri için modele ait modülasyon sınıflandırma raporu. 49
Tablo 4.9: SNR -6 dB değeri için modele ait modülasyon sınıflandırma raporu. 51
Tablo 4.10: SNR -4 dB değeri için modele ait modülasyon sınıflandırma raporu. 52
Tablo 4.11: SNR -2 dB değeri için modele ait modülasyon sınıflandırma raporu. 53
Tablo 4.12: SNR 0 dB değeri için modele ait modülasyon sınıflandırma raporu. 54
Tablo 4.13: SNR 2 dB değeri için modele ait modülasyon sınıflandırma raporu. 55
Tablo 4.14: SNR 4 dB değeri için modele ait modülasyon sınıflandırma raporu. 56
Tablo 4.15: SNR 6 dB değeri için modele ait modülasyon sınıflandırma raporu. 57
Tablo 4.16: SNR 8 dB değeri için modele ait modülasyon sınıflandırma raporu. 58
Tablo 4.17: SNR 10 dB değeri için modele ait modülasyon sınıflandırma raporu. 59
Tablo 4.18: SNR 12 dB değeri için modele ait modülasyon sınıflandırma raporu. 61
Tablo 4.19: SNR 14 dB değeri için modele ait modülasyon sınıflandırma raporu. 62
Tablo 4.20: SNR 16 dB değeri için modele ait modülasyon sınıflandırma raporu. 63
Tablo 4.21: SNR 18 dB değeri için modele ait modülasyon sınıflandırma raporu. 64

SİMGE VE KISALTMA LİSTESİ

Simgeler **Açıklama**

dB : Desibel
GB : Gigabyte
GiB : Gigabinarybyte

Kısaltmalar **Açıklama**

AI : Artificial Intelligence
ALRT : Average Likelihood Ratio Test
AM-DSB : Amplitude Modulation-Double Sideband
AM-SSB : Amplitude Modulation-Single Sideband
AM-DSB-WC : Amplitude Modulation-Double Sideband-Modulation With Carrier
AM-SSB-SC : Amplitude Modulation-Single Sideband Suppressed-Carrier Modulation
AMR : Automatic Modulation Recognition
ANN : Artificial Neural Network
APSK : Amplitude and Phase-Shift Keying
ASK : Amplitude-Shift Keying
AWGN : Additive White Gaussian Noise
BPSK : Binary Phase Shift Keying
CAE : Computer Aided Design
CM : Correction Module
CNN : Convolutional Neural Network
CPFSK : Continous Phase Frequency Shift Keying
CPU : Central Processing Unit
CRLB : The Cramer-Rao Lower Bound
CWT : Continuous Wavelet Transform
DAE : Digital Audio Extraction
DCNN : Deep Convolutional Neural Network
DNN : Deep Neural Network
DL : Deep Learning
FM : Frequency Modulation
FSK : Frequency Shift Keying

FSST : Fourier-Based Synchrosquezing Transform
FPGA : For Field-Programmable Gate Array
GFSK : Gaussian Frequency Shift Keying
GMSK : Gaussian Minimum Shift Keying
GLRT : Generalized Likelihood Ratio Test
GP : Genetic Programming
GPU : Graphics Processing Unit
GRU : Gated Recurrent Unit
HDMF : Heterogeneous Deep Model Fusion
HHT : Hilbert Hung Transform
HMM : Hidden Markov Models
HLRT : Hybrid Likelihood Ratio Test
KNN : K-Nearest Neighbors
LDA : Latent Dirichlet Allocation
LSTM : Long Short Term Memory,
MEL : Mobile Edge Learning
MFSK : Multiple Frequency Shift Keying
MIMO : Multiple-Input Multiple-Output
ML : Maximum Likelihood
MLP : Multilayer Perceptron
MPSK : M-ary Phase Shift Keying
PAM : Pulse Amplitude Modulation
PDF : Probability Density Function
PSK : Phase Shift Keying
QAM : Quadrature Amplitude Modulation
QALRT : Quasi Average Likelihood Ratio Test
QHLRT : Quasi Hybrid Likelihood Ratio Test
QLLR : Quasi Log Likelihood Ratio
QPSK : Quadrature Phase Shift Keying
RAM : Random Access Memory
RNN : Recurent Neural Network
SDR : Software-Defined Radio
SNR : Signal to Noise Ratio
SST : Synchrosquezing Transform

STFT : Short-Time Fourier Transform

SVM : Support Vector Machine

WBFM : Wideband Frequency Modulation

WSST : Wavelet-Based Synchrosqueezing Transform

WT : Wavelet Transform

ÖZET

YÜKSEK LİSANS TEZİ

DERİN ÖĞRENME ALGORİTMALARIYLA OTOMATİK MODÜLASYON TANIMLAMA

Ayşenur ÇAMLIBEL

İstanbul Üniversitesi-Cerrahpaşa

Lisansüstü Eğitim Enstitüsü

Elektrik-Elektronik Mühendisliği Anabilim Dalı

Danışman: Dr. Öğr. Üyesi Bahattin KARAKAYA

Otomatik modülasyon tanıma, tüm haberleşme sistemleri için sinyal analizinin hızlı bir şekilde gelişen alanıdır. Bu alanda farklı algoritmalarla birçok çalışma yapılmıştır. Literatürde var olan yöntemlerin birçoğu modern yapıda ve yüksek kapasiteli sistemlerde modülasyon sinyallerinin tanınmasında başarısız olabilmektedir. Günümüzde yapay zeka alanındaki gelişmelerle beraber derin öğrenme algoritmaları da sinyal işleme alanında kullanılmaya başlanmıştır. Otomatik modülasyon sınıflama için oluşturulan derin öğrenme modellerinin başarı yüzdeleri yapılan çalışmalarla birlikte artış göstermektedir.

Bu tez çalışmasında derin öğrenme algoritmaları kullanılarak Evrişimli Sinir Ağı (Convolutional Neural Network, CNN) tabanlı bir otomatik modülasyon sınıflandırıcı geliştirilmiştir. Sınıflandırma için değişen sinyal-gürültü oranlarında 11 modülasyondan oluşan GNU Radyo ile oluşturulmuş sentetik bir veri seti kullanılmıştır. Veri seti içerisinde bulunan karmaşık sinyallerin zaman-frekans alanındaki görüntüleri elde edilmiştir. Karmaşık sinyallerin zaman-frekans temsillerini sağlamak için etkili bir yaklaşım olan Senkronize Sıkıştırma Dönüşümü (Synchrosqueezing Transform, SST) kullanılmıştır. Fourier Tabanlı Senkronize Sıkıştırma Dönüşümü (Fourier-Based Synchrosqueezig Transform, FSST) yöntemi ile ortaya çıkan zaman-frekans analizi görüntülerinin sınıflandırılması için bir CNN modeli geliştirilmiştir. FSST ile alınan görüntülerden oluşan yeni veri seti, tasarlanan CNN modeli için 128x128x2 şeklinde üç boyutlu bir girdi haline getirilmiştir. Bu girdiler yedi evrişim katmanı ve beş tane de yoğun katman kullanılarak oluşturulan CNN modeli ile eğitilerek bir modülasyon sınıflandırıcı hazırlanmıştır. Önerilen sınıflandırıcı %87 oranında başarılı bir sonuç vermiştir.

Ocak 2022, 90 sayfa.

Anahtar kelimeler: Otomatik modülasyon tanıma, modülasyon sınıflama, derin öğrenme, zaman-frekans analizi, CNN, SST, FSST.

SUMMARY

M.Sc. THESIS

AUTOMATIC MODULATION RECOGNITION WITH DEEP LEARNING ALGORITHMS

Ayşenur ÇAMLIBEL

Istanbul University-Cerrahpasa

Institute of Graduate Studies

Department of Electrical and Electronic Engineering

Supervisor : Assist. Prof. Dr. Bahattin KARAKAYA

Automatic modulation recognition is a rapidly developing field of signal analysis for all communication systems. Many studies have been carried out in this area with different algorithms. Many of the methods available in the literature fail to recognize modulation signals in modern structures and high-capacity systems. Today, with the developments in the field of artificial intelligence, deep learning algorithms have started to be used in the field of signal processing. The success rates of deep learning models created for automatic modulation classification increase with the studies done.

In this thesis, an automatic modulation classifier based on Convolutional Neural Network (CNN) was developed using deep learning algorithms. A synthetic dataset created with GNU Radio consisting of 11 modulations at varying signal-to-noise ratios was used for classification. The images in the time-frequency domain of the complex signals in the data set were obtained. An efficient approach, Synchrosqueezing Transform (SST), is used to provide time-frequency representations of complex signals. A CNN model has been developed for the classification of time-frequency analysis images produced by the Fourier-Based Synchrosqueezig Transform (FSST) method. The new dataset, consisting of images taken with FSST, is a three-dimensional input in the form of 128x128x2 for the designed CNN model has been made into. A modulation classifier was prepared by training these inputs with the CNN model created using seven convolution layers and five dense layers. The proposed classifier gave a successful result of 87%.

January 2022, 90 pages.

Keywords: Automatic modulation recognition, modulation classification, deep learning, time-frequency analysis, CNN, SST, FSST.

1. GİRİŞ

Haberleşme sistemlerinde modüleli işaretin modülasyon türünü otomatik olarak tespit eden sistemlerin önemi gün geçtikçe artmaktadır. Bu sistemler çoğunlukla sivil ve askeri haberleşme sistemlerinde kullanılmaktadır. Yapılan bazı çalışmalarda [1, 2] otomatik modülasyon tanımanın askeri haberleşme sistemlerinde en çok elektronik harp ve elektronik savunma alanlarında dinleme, boğma, engelleme, izge yönetimi, girişim tespiti için kullanıldığı belirlenirken sivil haberleşme sistemlerinde ise daha çok internet radyolarında kullanılmaktadır.

Şengür [1] yapmış olduğu araştırmalarda, haberleşme sinyallerinin modülasyon türünün otomatik olarak tanınması için genellikle zaman-frekans analizi yöntemlerinin kullanıldığını ve geleneksel zaman-frekans analizlerinin sinyal işleme yöntemiyle elde edilen yeterli özelliklerin çıkarılamadığını ve karar teknikleriyle de çok doğru sınıflandırılmadığını belirlemiştir.

Son yıllarda yapay zeka alanında yapılan çalışmalarda birçok gelişme sağlanmıştır. Yapay zeka alanında makine öğrenmesi içinde derin öğrenmenin başarı oranının diğer alanlardan daha yüksek olduğunu bilinmektedir. Çünkü derin öğrenme yöntemlerinde veri sayısının fazla olduğu durumlarda diğer makine öğrenimi yöntemlerine göre başarı oranında bariz bir üstünlük sağlanırken, veri sayısının az olduğu durumlarda bile diğer makine öğrenim yöntemlerine çok yakın bir sonuç ortaya çıkardığı bilinmektedir. Bu durum artık birçok alanda derin öğrenme yöntemlerinin kullanılmasına olanak sağlamıştır.

Yıldırım ve diğ. [3], yaptıkları çalışmalarda derin öğrenme algoritmaları için iletişim teknolojilerinde kullanılmakta olan fiziksel katmanların yeniden tasarlanmasından telsiz ağlarının modellenmesine kadar birçok değişikliğe katkı sağlayacak bir teknoloji olduğunu söylemişlerdir. Özellikle 5G ve moleküler iletişim sistemleri gibi matematiksel olarak modellemesi zor olan iletişim sistemlerinde derin öğrenme yöntemlerinin uygulanmasını konu alan araştırmaların son günlerde oldukça yaygın olarak yapılmakta olduğunu söylemişlerdir. Fakat haberleşme teknolojileriyle ilgilenen araştırmacı ve kurumların derin öğrenme tekniklerine hakim olmaması bu alanda yapılan çalışmaların sayısını ve etkisini kısıtlamaktadır. Bu nedenle haberleşme teknolojileri üzerinde derin öğrenme teknikleriyle yapılan çalışmaların bir ekip halinde değerlendirilmesi, elde edilen sonuçların başarı oranının tespit edilmesi ve yeni

çalışma konularının belirlenmesi ile derin öğrenmenin haberleşme teknolojileri alanında çalışan araştırmacılara katkısı sağlanmalıdır.

Bu tez çalışması kapsamında otomatik modülasyon tanımada kullanılan geleneksel yöntemlerin yeterince doğru sınıflandırma yapamaması ve derin öğrenmenin haberleşme alanındaki gelişmeleri de dikkate alınarak derin öğrenme algoritmalarıyla zaman-frekans analizinin de kullanıldığı başarı yüzdesi yüksek otomatik modülasyon tanımada kullanılabilecek sınıflandırıcı yapılarının geliştirilmesi hedeflenmiştir.

Bu tez çalışmasında, sınıflandırma için değişen sinyal-gürültü oranlarında GNU Radyo ile oluşturulmuş 11 modülasyondan oluşan sentetik bir veri seti kullanılmıştır.

Tezin ikinci bölümünde, kısaca modülasyon tanımından bahsedilip otomatik modülasyon tanıma, derin öğrenme ve zaman-frekans analizi ile ilgili literatürde var olan çalışmalar hakkında detaylı bilgiler verilmiştir.

Tezin üçüncü bölümünde, derin öğrenme algoritmalarıyla geliştirilen modülasyon sınıflandırıcıya yönelik çalışmalarda kullanılan veri seti, sinyallerin zaman-frekans alanındaki dönüşümleri ve kullanılan yöntemler, zaman-frekans dönüşümleri alınan görüntülerin sınıflandırılması için oluşturulan derin öğrenme modeli, modelin parametreleri, modelin değerlendirilmesi ve yöntemleri hakkında bilgiler verilmiştir.

Tezin dördüncü bölümünde, FSST ile zaman-frekans görüntüleri elde edilen sayısal ve analog modülasyon türündeki sinyallere ait görüntülerin, oluşturulan CNN modeli ile sınıflandırılması sonucunda ortaya çıkan simülasyon sonuçları incelenmiştir. CNN modelinin performansı ile ilgili değerlendirilmelerde bulunulmuştur. Simülasyon sonuçlarından elde edilen bulgular detaylı bir şekilde değerlendirilmiştir.

Tezin son bölümünde, modülasyon sınıflandırıcı olarak geliştirilen algoritma sonuçları hakkında değerlendirmeler yapılmıştır.

2. GENEL KISIMLAR

Bu bölümde kısaca modülasyon kavramından bahsedilip otomatik modülasyon tanıma, derin öğrenme algoritmaları ve zaman-frekans analizi hakkında literatür taraması yapılıp özet bilgiler verilecektir.

2.1. MODÜLASYON

Alçak frekanslı işaretlerin yüksek frekanslı bir taşıyıcı işaret üzerine bindirilmesi işlemine modülasyon denir. Modülasyon işlemi alçak frekanslı mesaj işaretinin kısıtlı bant genişliği problemini çözmek ve bu alçak frekanslı işaretleri uzun mesafelere aktarabilmek amacıyla yapılmaktadır. Düşük frekanslı işaretin yüksek frekans ile taşınabilmesi için modüleli haber işaretinin anlık değerleri üzerinden bir yüksek frekans işaretinin genlik, frekans veya faz değerlerinin değiştirilmesi işlemlerinin yapılması gerekmektedir.

Modülasyon işleminin tersine ise demodülasyon denir. Yani demodülasyon modüle edilmiş işaretten asıl bilgi sinyalini tekrar elde etme işlemidir [4].

Modülasyon: Analog Modülasyon ve Sayısal Modülasyon olarak ikiye ayrılır. Bunların da çeşitli yöntemleri bulunmaktadır. Modülasyon yöntemlerinin belirlenmesinde temel olarak genlik, faz ve frekans bilgileri kullanılmaktadır.

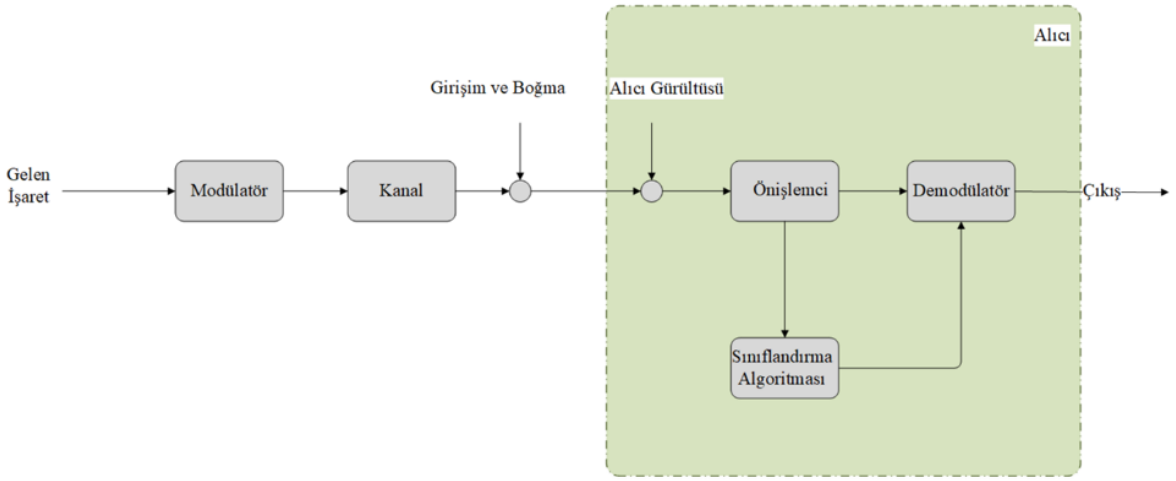
2.2. OTOMATİK MODÜLASYON TANIMA

Otomatik Modülasyon Tanıma (Automatic Modulation Recognition, AMR), gönderici tarafından gelen işaretin alıcı tarafında bu gelen işaret hakkında herhangi bir bilgiye sahip olmadan işaretin modülasyon türünün tespit edilmesi işlemine denir.

Bir işaretin modülasyon türünü bilmenin iki temel sebebi vardır: Birincisi sinyal bilgisini korumak, ikincisi ise sinyal bozulmasına karşı yapılması gereken doğru eyleme karar verebilmektir. Dolayısıyla zaman ve frekans kaymalarının, senkronizasyon hatalarının ve çeşitli sinyal bozulmalarının söz konusu olduğu haberleşme sistemlerinde otomatik modülasyon tekniklerinin kullanılması çok önemli bir hale gelmiştir [5].

Otomatik modülasyon tanıma, hem askeri hem de sivil haberleşme sistemlerinde yaygın bir şekilde kullanılmaktadır. Bu sistemlerde AMR'nin amacı, alınan işaretten yararlanarak gönderilen işarete ait bilgilere ulaşmaktır.

Modülasyon tanıma işlemi eski zamanlardan beri yapılmaktadır. Sadece bir modülasyon türü için tasarlanmış bir dizi demodülatör kullanılarak oluşturulan sınıflandırıcı, en eski modülasyon tanımlayıcıdır. Otomatik modülasyon tanıma, manuel modülasyon tanımaya göre daha üstündür. Çünkü otomatik modülasyon tanıyıcılar operatörün verimliliğinin artırılmasına ve ortamdaki farklı faaliyetleri izleme yeteneğinin gelişmesine olanak tanımaktadır [5].



Şekil 2.1: Genel otomatik modülasyon tanıma sistemi.

Şekil 2.1'de genel bir otomatik modülasyon tanıma sisteminin yapısı görülmektedir. AMR sistemi; bir ön işlemci, otomatik tanımlayıcı ve demodülatör kısımlarından oluşmaktadır. Önişlemci, bir işaret işleme modülü olarak çalışır ve alıcı taraftaki gürültüyü azaltır. Otomatik tanımlayıcı ise sınıflandırma algoritmalarıyla bir sınıflandırma modülü olarak kullanılmaktadır. Otomatik modülasyon tanıma işlemi demodülasyon aşamasından önce gerçekleşmektedir.

Literatürde bulunan mevcut çalışmalar incelendiğinde genel olarak modülasyon tanıma problemini çözmek için kullanılan iki yaklaşım vardır: Karar Teorisine Dayalı Yaklaşımlar ve İstatistiksel Örüntü Tanımaya Dayalı Yaklaşımlar. Karar Teorisine Dayalı Yaklaşımlarda, modülasyon tanıma problemine ait matematiksel formüllerin elde edilmesi için olasılık, hipotez ve test argümanları kullanılmaktadır. İstatistiksel Örüntü Tanımaya Dayalı yaklaşımlarda ise

modülasyon tanıma yöntemleri iki alt sisteme ayrılır: Birinci sistem, özellik çıkarma alt sistemidir. Görevi, alınan verilerden önceden tanımlı özellikleri çıkartmaktır. İkinci sistem ise örüntü tanıma alt sistemidir. Burada yapılan işlem, bir sinyalin modülasyon türünü belirlemektir. İstatistiksel örüntü tanımaya dayalı yöntemlerde yapılan çalışmalarda da sınıflandırıcı yapısını ayarlamak için bir eğitim aşaması ve sınıflandırma kararını vermek için de bir test aşaması olmak üzere toplam iki aşamadan oluşmaktadır [5].

Literatürde her iki yaklaşımın da kullanıldığı modülasyon tanıma algoritmaları mevcuttur. Ayrıca her iki yaklaşımın beraber kullanıldığı modülasyon tanıma algoritmaları da geliştirilmiştir.

2.2.1. Karar Teorisine Dayalı Modülasyon Sınıflandırma Yöntemleri

Karar teorisine dayalı yöntemlerde, olabilirlik olasılık fonksiyonları kullanılarak modülasyon sınıflandırılması bir hipotez test etme problemine dönüştürülür. Bu hipotez testi, ortaya çıkan olasılık oranı değerini bir eşik değeri ile karşılaştırarak modülasyon tipine karar verir. Karar teorisine dayalı yöntemler, gerekli bütün kanal bilgisinin bilindiği durumda yüksek oranda sınıflandırma doğruluğu sağlar.

Çukur ve Serbes [6] yaptıkları araştırmalarda, olabilirlik yöntemlerinin Bayes sınıflandırma için en uygun dedektör olduğunu söylemişlerdir. Bununla beraber, olabilirlik olasılığının çıkartılması için bütün kanal parametrelerinin kestirilmesi gerektiğinden dolayı işlem karmaşıklığı artmaktadır. Bu karmaşıklığı hesaplamak ise mümkün değildir. Bu nedenle karar teorisine dayalı sınıflandırma için alternatif ve daha hızlı sonuç veren algoritmalara ihtiyaç duyulmaktadır.

Literatürde karar teorisine dayalı yöntemler için üç farklı otomatik modülasyon sınıflama tekniği önerilmiştir. Bunlar: Ortalama Olabilirlik Oranı Testi (Average Likelihood Ratio Test, ALRT), Genelleştirilmiş Olabilirlik Oranı Testi (Generalized Likelihood Ratio Test, GLRT) ve Karma Olabilirlik Oranı Testi (Hybrid Likelihood Ratio Test, HLRT)'dir.

ALRT yöntemi, bilinmeyen parametreleri belirli olasılık yoğunluk fonksiyonu (probability density function, pdf) değerlerine sahip rastgele değişkenler olarak tanımlar. $i = 1, \dots, N_{mod}$ i'inci modülasyon türünü temsilen olabilirlik fonksiyonu altındaki H_i hipotezi denklem 2.1'de ifade edilmektedir.

$$\Lambda_A^{(i)}[r(t)] = \int \Lambda[\mathrm{r(t)} \mid v_i\ , H_i]\ p(v_i\ , H_i\ )\ dv_i \tag{2.1}$$

Bu denklemde $\Lambda[\mathrm{r(t)}|v_i\ , H_i$ ifadesi H_i hipotezi altındaki $r(t)$ gürültü sinyalinin koşullu olabilirlik fonksiyonunu, v_i bilinmeyen vektörü ve $p(v_i\ , H_i)$ ise H_i hipotezi altında v_i vektörünün koşullu önsel pdf değerini göstermektedir [7].

GLRT yöntemi, bilinmeyen parametreleri bilinmeyen belirleyiciler olarak tanımlar. H_i hipotezi aşağıdaki denklemle ifade edilmektedir [7].

$$\Lambda_G^{(i)}[r(t)] = \ max_{vi}\ \Lambda[\ \mathrm{r(t)} \mid v_i\ , H_i\ ] \tag{2.2}$$

HLRT ise ALRT ve GLRT yöntemlerinin her ikisinin birden uygulandığı yöntemdir. H_i hipotezi aşağıdaki denklemde ifade edilmektedir.

$$\Lambda_H^{(i)}\ [r(t)] = \ max_{vi1} \int \Lambda\ [\mathrm{r(t)}|\ v_{i1}, v_{i2}, H_i]\ p(v_{i2}, \mid H_i\ )\ dv_{i2} \tag{2.3}$$

v_{i1} ve v_{i2} rastgele değişkenlerin bilinmeyen büyüklüklerini ve bilinmeyen belirleyicilerin vektörlerini göstermektedir [7].

Panagiotou ve diğ. [8], modülasyon sınıflama probleminin çözümüne yönelik karar teorisine dayalı GLRT ve HLRT yöntemlerini kullanarak iki modülasyon sınıflandırma algoritması tasarlamışlardır. Tasarlanan bu algoritmaların performanslarını bir Katkılı Beyaz Gauss Gürültüsü (Additive White Gaussian Noise, AWGN) kanalında 16QAM-16PSK, V.29-16PSK ve 16QAM-V.29 olmak üzere üç modülasyon çifti üzerinden simüle etmişlerdir. Bu algoritmalardan simülasyon sonucunda elde ettikleri performans değerlerini literatürde var olan iki ALRT tabanlı sınıflandırma algoritmasıyla karşılaştırmışlardır. Oluşturulan bu iki algoritmanın, değişken zarf modülasyonlarının sınıflandırılması için kullanılan ALRT tabanlı sınıflandırma algoritmalarına göre önemli ölçüde performans kazancı sağladığını söylemişlerdir.

Hameed ve diğ. [9], lineer sayısal modülasyon tanıma için karar teorisine dayalı olabilirlik tabanlı algoritmaları araştırarak HLRT ve Yarı Hibrit Olabilirlik Oranı Testi (Quasi Hybrid Likelihood Ratio Test, QHLRT) tabanlı, bilinmeyen parametre olarak sinyal genliği, faz ve gürültü gücünü kullanan algoritmalar sunmuşlardır. Bu algoritmaları İkili Faz Kaydırmalı Anahtarlama (Binary Phase Shift Keying, BPSK) ve Dörtlü Faz Kaydırmalı Anahtarlama (Quadrature Phase Shift Keying, QPSK) modülasyonlarının sınıflandırılması için

kullanmışlardır. Bu algoritmaların sonuçlarını üst sınırlarla ve dördüncü dereceden kümülatif tabanlı algoritmalarla karşılaştırmışlardır. Bu karşılaştırma sonuçlarına göre tasarladıkları algoritmalar Sinyal-Gürültü Oranı (Signal to Noise Ratio, SNR) değeri 10'dan büyükken üst sınırlara ve kümalatif tabanlı algoritmalara göre daha üstün sonuç verirken SNR değeri 10'nun altına düşünce performans olarak daha kötü sonuç vermiştir.

Huan ve Polydoros [10], AWGN kanalında M Seviyeli Faz Kaydırmalı Anahtarlama (M-ary Phase Shift Keying, MPSK) modülasyonlarının sınıflandırılması problemine yönelik olabilirlik tabanlı algoritmalar önermişlerdir. Önerdikleri algoritmaları, literatürde var olan diğer algoritmalara göre teorik olarak basitleştirerek yorumlamışlardır. Bu bağlamda bir Yarı Günlük Olabilirlik Oranı (Quasi Log Likelihood Ratio, QLLR) algoritması önermişlerdir. Bu algoritmadan elde edilen başarı oranı oldukça yüksek çıkmıştır. Fakat bu durum QLLR algoritmasının sınıflandırıcı karmaşıklığında ciddi bir artışa sebep olmuştur.

Wei ve Mendel [11], AWGN kanalında sayısal kareleme modülasyonlarının sınıflandırma problemi için Maksimum Olasılık (Maximum Likelihood, ML) yöntemini kullanmışlardır. Geliştirilen bu algoritma Faz Kaydırmalı Anahtarlama (Phase Shift Keying, PSK), Karesel Genlik Modülasyonu (Quadrature Amplitude Modulation, QAM), Darbe Genlik Modülasyonu (Pulse Amplitude Modulation, PAM) gibi herhangi bir sayısal genlik-faz modülasyonuna uygulanabilen bir ML sınıflandırıcıdır. Bu ML sınıflandırıcının SNR değerinin küçük olduğu durumlar dışında başarı oranları oldukça iyi çıkmıştır.

Sills [12], AWGN kanalında uyumlu ve uyumlu olmayan koşullar altında PSK ve QAM modülasyon türlerinin otomatik modülasyon sınıflandırma problemine yönelik çalışmalarda bulunmuştur. Bu bağlamda 8PSK, QPSK, BPSK, 16QAM, 32QAM ve 64QAM sinyallerini sınıflandırmıştır. Bu sinyallerin sınıflandırılması için bir ML algoritmasını, bilinmeyen parametre olarak ise taşıyıcı fazını kullanmıştır. ML yönteminde modülasyonlar üzerinde çok fazla sembol kullanılmasının hata oranını azaltacağını belirtmiştir.

Xu ve diğ. [13], askeri ve ticari uygulamalarda çokça talep edilen Yazılım Tanımlı Radyolarda (Software-Defined Radio, SDR) kullanılabilecek otomatik modülasyon sınıflandırma algoritması geliştirmişlerdir. Bu sınıflandırma için ALRT tekniğini kullanmışlardır. Yeterli parametreler bilindiğinde ALRT yöntemi ile geliştirilmiş sınıflandırıcı, SDR uygulamaları için karmaşıklığı azaltma ve algoritmaları hızlandırıcı bazı adımlara ihtiyaç duymuştur. Bu algoritmada modülasyon sınıflama için optimum çözüme en yakın sonuçlar elde edilmiştir.

Beidas ve Weber [14], AWGN kanalında bilinmeyen parametre olarak faz seğirmesini seçerek ALRT ve Yarı Ortalama Olabilirlik Oranı Testi (Quasi Average Likelihood Ratio Test, QALRT) tabanlı modülasyon sınıflandırma algoritmaları geliştirmişlerdir. Bu algoritmaları Çoklu Frekans Kaydırmalı Anahtarlama (Multiple Frequency Shift Keying, MFSK) sinyallerinin sınıflandırılması için kullanmışlardır. MFSK (32FSK, 64FSK) sinyallerinin sınıflandırılmasında önemli bir performans sağlamışlardır.

2.2.2. Örüntü Tanıma Teorisine Dayalı Modülasyon Sınıflandırma Yöntemleri

Örüntü tanıma teorisine dayalı yöntemlerde, modülasyon sınıflama işlemi öznitelik çıkarma ve sınıflandırma olmak üzere iki adımdan oluşmaktadır. Öznitelik çıkarma işlemi, giriş işaretlerinden alınan özniteliklerin çıkartıldığı adımdır. Sınıflandırma işlemi ise, bu giriş işaretlerinden çıkartılan öznitelikleri kullanarak modülasyon türünün tespit edildiği adımdır.

Örüntü tanıma teorisine dayalı yöntemlerin, karar teorisine dayalı yöntemler kadar işlem karmaşıklığı yoktur. Ayrıca örüntü tanıma teorisinde işarete ait parametre bilgisine de gerek yoktur. Bu yüzden örüntü tanıma yöntemlerinin uygulanması karar teorisi yöntemlerine göre daha kolaydır. Örüntü tanıma yöntemleri, birçok durumda kullanılması uygun olmamasına ve yarı performans göstermesine rağmen uygulanabilirliğinin kolay olmasından dolayı sıklıkla kullanılmaktadır.

Literatürde mevcut olan çalışmaların çoğunda öznitelik olarak yüksek dereceli momentler, kümülantlar, dalgacık dönüşümü, çevrimsel öznitelikler, takım yıldızı grafikleri, anlık genlik, anlık frekans ve anlık faz gibi çeşitli istatistiksel momentler kullanılmıştır. Bu öznitelikler sınıflandırıcılarla beraber değişik şekillerde kullanılarak otomatik modülasyon sınıflandırıcıyı oluşturmaktadır [7]. Literatürde mevcut olan örüntü tanıma ile ilgili yapılmış çalışmaların ayrıntılı hali Tablo 2.1 ve Tablo 2.2'de gösterilmiştir.

Tablo 2.1: Örüntü tanımaya dayalı modülasyon sınıflandırma literatür taraması-1 [7].

Öznitelikler	Yazarlar	Modülasyon Türleri	Sınıflandırıcı
	Lopatka ve Pedzisz [15]	ASK, PSK, QAM, FSK	Fuzzy Classifier
	Swami ve Sadler [16]	PAM, PSK, QAM	Asymptotic Threshold Analysis
Yüksek Dereceli Momentler ve Kümülantların Kullanıldığı Çalışmalar	Wong ve Nandi [17]	ASK2, ASK4, BPSK, QPSK, FSK2, FSK4, QAM16, V29, V32, QAM64	ANN ve GP
	Wu ve diğ. [18]	BPSK, QPSK, 4QAM, 16QAM, 64QAM	CRLB
	Shermeh ve Ghazalian [19]	ASK4, ASK8, PSK2, PSK4, PSK8, Star-QAM8, V29, QAM32, QAM64	SVM
	Aslam ve diğ. [20]	BPSK, QPSK, QAM16, QAM64	GP ve kNN
Dalgacık Dönüşümü Temelli Çalışmalar	Ho ve diğ. [21]	PSK, FSK	Threshold Analysis
	Hassan ve diğ. [22]	FSK, ASK, PSK, QAM	ANN

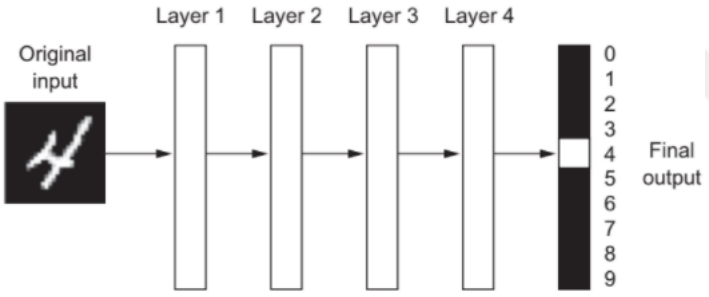
Tablo 2.2: Örüntü tanımaya dayalı modülasyon sınıflandırma literatür taraması-2 [7].

Öznitelikler	Yazarlar	Modülasyon Türleri	Sınıflandırıcılar
Çevrimsel Özniteliklerin Kullanıldığı Çalışmalar	Dobre ve diğ. [23]	QAM, PSK, ASK	Match Filter
	Dobre ve diğ. [24]	4QAM, 16QAM	Threshold Analysis
	Fehske ve diğ. [25]	BPSK, QPSK, FSK, MSK, AM	ANN
	Ramkumar [26]	ASK, PSK, QAM, FSK	ML,HMM,ANN
	Dobre ve diğ. [27]	4-ASK, 8-ASK, BPSK, QPSK, 8-PSK, 16-PSK, 16-QAM, 32-QAM ve 64-QAM	Threshold Analysis
	Dobre ve Inkol [28]	AM, FSK, M-PSK, M -QAM, M -ASK, Mobile WiMAX OFDM	Threshold Analysis
	Satija ve diğ. [29]	BPSK, QPSK, MSK, FSK	ANN, kNN, LDA, NB, SVM
Takımyıldızı Grafiğinin Kullanıldığı Çalışmalar	Mobasseri [30]	V.29, 8PSK, 16QAM	ML
	Ahmadi ve Berangi [31]	QAM, PSK	GP, Hierarchical Clustering
Zero Crossing	Hsue ve Soliman [32]	BPSK, QPSK, 8PSK, BFSK, 4FSK, 8FSK	Threshold Analysis
S Transform	Satija ve diğ. [33]	BPSK, QPSK, MSK, FSK	ANN, kNN, LDA, NB, SVM

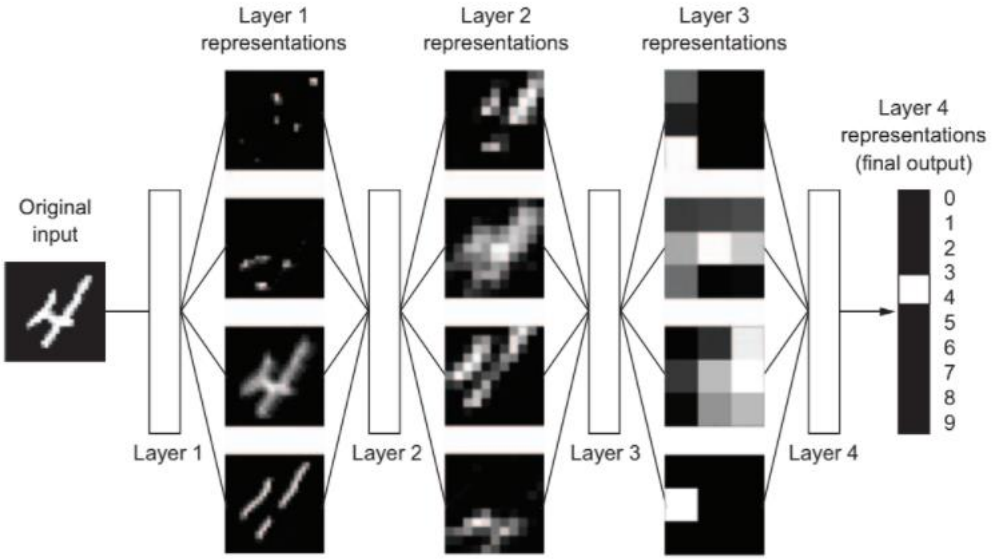
2.3. DERİN ÖĞRENME

Derin öğrenme (Deep Learning, DL), birbiri ardına sıralanmış katmanlarda özgün girdi verilerinden başlanarak veriler sırasıyla işlenirken gittikçe artan şekilde daha kullanılabilir gösterimler elde edebilen makine öğrenmesinin bir alt dalıdır. Derin kelimesinden kastedilen derin bilgiler edinilmesi değil, birbirini takip eden çok sayıda katmanın olmasıdır. Yani modelin derinliği katman sayısının çokluğundan oluşmaktadır. Bu yönüyle derin öğrenme algoritmaları, genelde daha az katmandan oluşan diğer makine öğrenme algoritmalarından ayrılmaktadırlar [34].

Katmanlı gösterim yapısı, sinir ağı olarak adlandırılmaktadır. Veri, sinir ağları ve birbiri ardına sıralanmış katmanları olan model sayesinde öğrenilmektedir. Katman sayısı arttıkça derinlik artar ve veriden daha anlamlı gösterimler öğrenilmiş olur. Şekil 2.2'de rakam sınıflandırma için derin bir sinir ağı gösterilmektedir. Şekil 2.3.'te ise rakam sınıflandırma modeliyle öğrenilen derin gösterimler gözükmektedir [34].



Şekil 2.2: Rakam sınıflandırma için derin bir sinir ağı [34].



Şekil 2.3: Rakam sınıflandırma modeliyle öğrenilen derin gösterimler [34].

Derin öğrenme, yüksek performans sunması ve öznitelik çıkarma işlemini tamamen otomatikleştirmesi ile de hızlı bir şekilde yayılmıştır. Ayrıca modern derin öğrenme modelleri basitlik, ölçeklenebilirlik, çok yönlülük ve yeniden kullanılabilirlik gibi önemli özelliklere sahip olduğundan sıklıkla tercih edilmektedir. Derin öğrenmenin, veriden kullanışlı gösterimler öğrenebilmesi iki durumla açıklanabilir. Birinci durum, birbirini takip eden katman sayısını artırarak daha karmaşık gösterimler oluşturulabilir. İkinci durumda ise bütün katmanlar birlikte öğrenilebilir, herhangi bir katman kendi üstündeki ve altındaki katmanlara göre kendisini yenileyebilir. Bu iki durum beraber derin öğrenmenin başarı oranının yüksek olmasını sağlar [34].

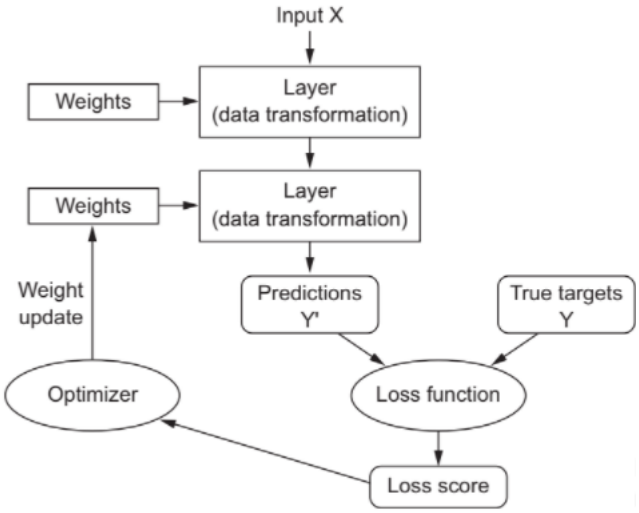
Derin öğrenme matematiksel temellere dayanan bir yöntemdir. Öğrenme süreci boyunca, sinir ağlarındaki tüm işlevler türevlenebilir zincirleme tensör işlemleridir. Türevin zincir kuralına göre mevcut parametlerini gradyan değerleri ile eşleyen bir gradyan fonksiyonu bulunmaktadır. Sinir ağına özgün girdi gönderilmeden önce kayıp fonksiyonu (loss) ve eniyileme (optimizer) algoritması belirlenmektedir. Kayıp fonksiyonu sinir ağının başarı oranını ölçmek için bir kriter olmaktadır çünkü öğrenmenin sağlandığı geri bildirim sinyalini belirler. Optimizer, kaybın gradyanının parametrelerini güncellemeyi sağlar yani öğrenmenin nasıl gerçekleşeceğini belirler [34].

Derin öğrenmenin çıkış tarihinin makine öğrenmesi kadar eski olmasına rağmen derin öğrenme ile ilgili yapılan çalışmalar ancak 2010 yılından itibaren artış göstermeye başlamıştır. Bunun sebebi donanım, veri setleri ve algoritmalarda yapılan iyileştirmelerden kaynaklanmaktadır. Literatüre bakıldığında derin öğrenme alanında görüntü tanıma, ses tanıma, sinyal işleme, insan seviyesinde el yazısı, otomatik tercüme sistemleri, metinden ses üretimi, otonom araç sürüşü, digital reklamlar için hedef kitle tespiti, haberleşme sistemleri gibi birçok konuda çalışmalar yapılmış ve yüksek performans sağlanmıştır [34].

2.3.1. Yapay Sinir Ağlarının Yapısı

Yapay sinir ağları (Artificial Neural Network, ANN) derin öğrenmeyi oluşturan algoritmalardan bir tanesidir. Yapay sinir ağları biyolojik sinir ağlarından ilham alınarak tasarlanmıştır. Dolayısıyla insan beyninin bir modeli değildir.

Bir sinir ağının eğitilmesi katmanlar, ağı ya da modeli oluşturan yapılar, girdi verileri, hedefler, kayıp fonksiyonu ve eniyileme algoritması gibi nesneler arasındaki döngüsel ilişki üzerinden yapılmaktadır. Bu nesneler arasındaki ilişki Şekil 2.4'te gösterilmektedir. Sinir ağı birbirini izleyen katmanlardan oluşur. Girilen veriyi tahminlere eşler. Kayıp fonksiyonu sayesinde tahmin edilen ve hedeflenen değerler arasındaki fark kayıp değerini oluşturur. Bu değer sinir ağının tahminlerinin hedeflenen gerçek değeri ne kadar karşıladığını gösterir. Optimizer ise kayıp değerinden yola çıkarak ağırlıkları günceller [34].



Şekil 2.4: Sinir ağı, katmanlar, kayıp fonsiyonu ve optimizer arasındaki ilişki [34].

2.3.2. Derin Öğrenme Algoritmaları

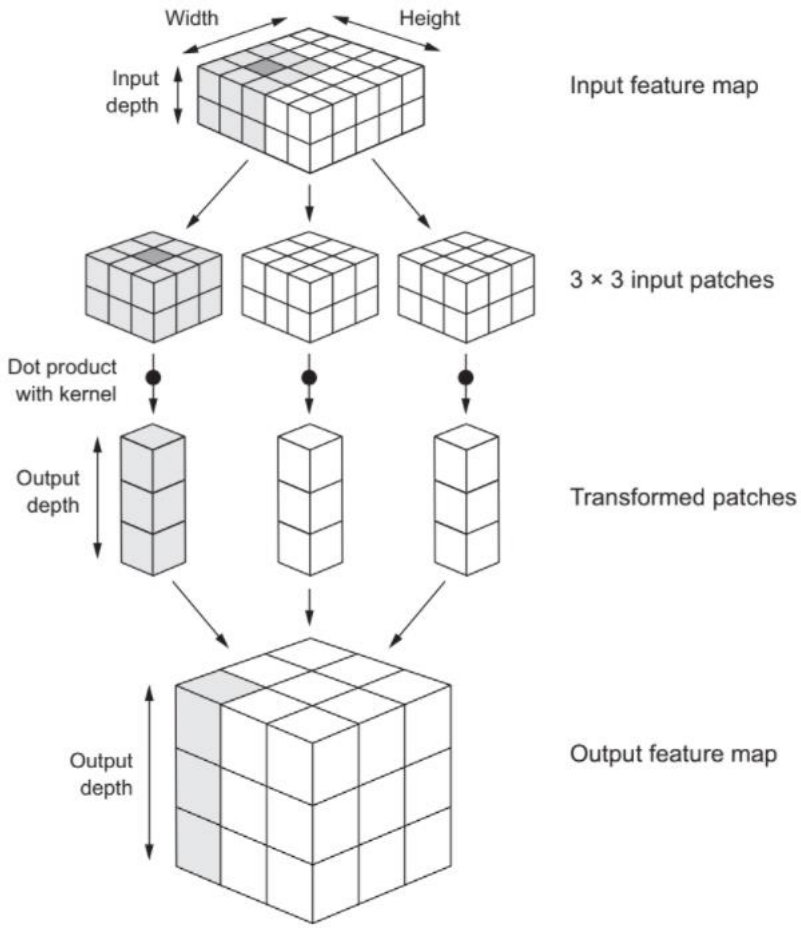
Bu başlık altında, derin öğrenmeyi oluşturan Evrişimli Sinir Ağları (Convolutional Neural Network, CNN), Özyinelemeli Sinir Ağları (Recurent Neural Network, RNN), Geçitlenmiş Özyinelemeli Birimler (Gated Recurrent Unit, GRU) ve Uzun Kısa Vadeli Bellek Modeli (Long Short Term Memory, LSTM) algoritmalarından bahsedilecektir.

2.3.2.1. Evrişimli Sinir Ağları

Evrişimli sinir ağları, çok boyutlu sinir ağı girdileri için özellikle bilgisayarlı görü alanlarında çok başarılı olan bir derin öğrenme algoritmasıdır. İlk defa 1998 yılında Lecun ve diğ. [35] yaptıkları çalışmalarla 0-9 arasındaki rakamları, CNN ile sınıflandırma ve sayısallaştırma yapmayı başarmışlardır. Günümüzde genelde görsel üzerinden sınıflandırma yapmak için kullanımı yaygındır. Yani görsel sınıflandırma sorununa en iyi çözüm evrişimli sinir ağları olmuştur. Literatürde CNN ile ilgili yapılan çalışmalara bakıldığında görüntü sınıflandırmanın yanında doğal dil işleme, nesne bulma ve takip etme gibi problemlerin çözümünde de kullanılmıştır.

Evrişimli sinir ağları, öğrendikleri örüntülerin yön değişmezliği ve örüntülerin uzamsal hiyerarşileri öğrenebilme özelliği olmak üzere iki özelliğe sahiptir. Birinci özellik sayesinde daha az veri ile daha yüksek gösterimler elde edilebilmektedir. İkinci özellikte ise gitgide karmaşıklaşan ve soyut hale gelen görsellerin etkin bir şekilde öğrenilebilmesini sağlar [34].

AlexNet, VGG, DenseNet, GoogLeNet ve ResNet görseller üzerinde iyi sonuçlar almış CNN mimarileridir.



Şekil 2.5: Evrişim işleminin çalışma yapısı [34].

Şekil 2.5'te evrişim işleminin çalışma yapısı gösterilmektedir. Evrişim işlemi, matematiksel olarak yapılan konvolüsyon işlemlerinin bilgisayarlı görü için iki boyutta yapılması işlemidir. Görsel üzerinde işlem yapabilmek için görseller matris olarak ifade edilmektedir. İşlemler matris boyutlarında yapıldığı için işlem yükü çok fazlalaşmaktadır. Bu yüzden evrişimli sinir ağı modellerini eğitebilmek için yüksek Grafik İşlemci Birimi (Graphics Processing Unit, GPU) ve Merkezi İşlem Birimi (Central Processing Unit, CPU)'ne sahip donanımlara ihtiyaç duyulmaktadır.

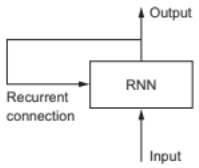
2.3.2.2. Özyinelemeli Sinir Ağları

Özyinelemeli sinir ağları, zaman serisi şeklinde ifade edilebilen problemlerin çözümü için kullanılabilen bir derin öğrenme algoritmasıdır. Literatürde yapılan çalışmalara bakıldığında RNN zaman serisi sınıflandırma, ses işleme, doğal dil işleme, doküman sınıflandırma, dizi

etiketleme, zaman serisi kapsamında geleceği tahmin etmede, müzik üretme, medikal uygulamalarda, makine çeviri uygulamalarında, video çözümlemelerinde, cümleden veya metinden duygu analizi gibi birçok uygulamada kullanılmaktadır. Verilerin sıralaması önemli ise RNN kullanılması tercih edilmelidir.

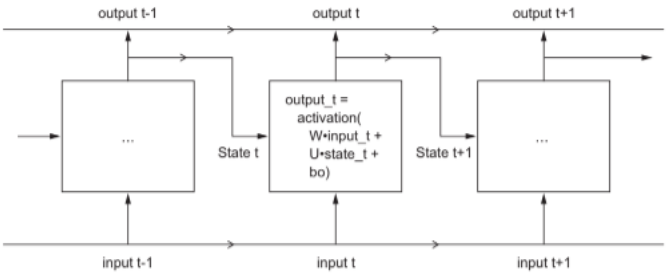
CNN mimarisinde hafıza bulunmamaktadır. Her giriş verisi birbirinden bağımsız bir şekilde işlenir ve giriş verileri arasında herhangi bir durum bilgisi tutulmaz. Dolayısıyla CNN gibi bu tarz ağlarda dizileri ve zamana bağlı verileri işlemek için verileri tek bir veriymiş gibi sinir ağına iletmek gerekir. Bu tarz ağlara ileri besleme ağları denir [34].

RNN mimarisinde ise, veriler dizilerin her elemanı üzerinden ilerleyerek işlenir. Her seferinde o ana kadar öğrenilen bilgiler durum bilgisi olarak tutulur. Yani RNN Şekil 2.6'da görüldüğü gibi kendi içinde döngüsü olan bir sinir ağı yapısıdır [34].



Şekil 2.6: Döngü içinde özyinelemeli bir sinir ağı [34].

RNN, her döngü sırasında bir önceki adımın değerlerini kullanır. Dolayısıyla Şekil 2.7'de görüldüğü üzere RNN mimarisi adım fonksiyonları ile ifade edilebilirler.

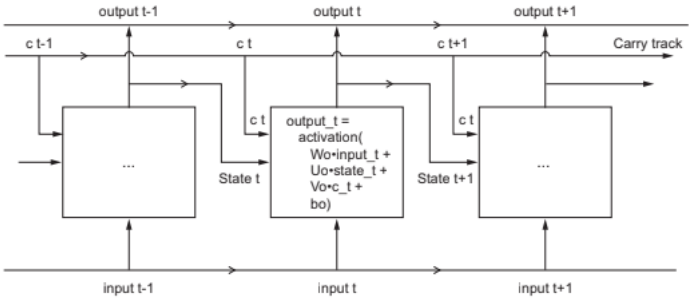


Şekil 2.7: Zaman üzerinde açılmış basit bir RNN yapısı [34].

2.3.2.3. Geçitlenmiş Özyinelemeli Birimler ve Uzun Kısa Vadeli Bellek Modeli

LSTM ve GRU, gradyan yok olması probleminin çözümüne yönelik klasik RNN yapısına göre birtakım bağlantıların güncellenmesi ile oluşturulan yinelemeli katmanlardır. Gradyan yok olması sorunu, katman eklendikçe ağın eğitilemez olması durumudur. Bu yüzden GRU ve LSTM geliştirilmiştir.

Basit RNN yapısı, teorik olarak tüm adımlardaki girdi verileriyle ilgili bilgileri tutmaktadır. Fakat uygulamada bu kadar uzun vadeli bilgilerin öğrenilmesi imkansızdır. LSTM'de GRU'ya göre daha güçlü bir modeldir. Uzun dizilerde LSTM, RNN yapısına göre daha iyi sonuçlar vermektedir [34].



Şekil 2.8: Basit RNN yapısına taşıyıcı eklenmesi LSTM'ye gidiş [34].

Basit bir RNN yapısına taşıyıcı eklenerek oluşturulmuş LSTM yapısı Şekil 2.8'de gösterilmektedir. Bu yapıda, işlenecek olan diziye paralel olarak çalışan bir taşıyıcı eklenmiştir. Dizideki bir veri herhangi bir anda taşıyıcıya geçebilir. Bu şekilde bir sonraki zaman adımına ulaşmış olur ve ihtiyaç duyulduğunda tekrar eski haline geçebilir. Böylece bilgi daha sonra tekrar kullanmak için saklanmış olur ve gradyan yok olması problemi çözülmüş olur.

2.3.3. Sinyal ve Modülasyon Tanıma için Derin Öğrenme ile Yapılan Çalışmalar

Yıldırım ve diğ. [3] yaptıkları araştırmalarda derin öğrenmenin literatürde sinyal tanıma, modülasyon, kanal kestirim, eşitlenme, dedeksiyon, kodlama gibi haberleşme uygulamalarında kullanıldığını söylemişlerdir.

Önder ve diğ. [36], kablosuz haberleşme sistemleri için alıcının eğitim sembolleri tarafından sağlanan kanalın gürültülü bir tahminine erişiminin olduğu sinyal demodülasyonu probleminin çözümüne yönelik yapay sinir ağı tabanlı bir SDR alıcısı önermişlerdir. Sinir ağı tabanlı bu

SDR alıcısı eğitim dizisi ile bilinmeyen kanal modelini hesaba katmaktadır. Önerilen SDR alıcısından elde ettikleri sonuçlara göre AWGN kanalı için korelasyon alıcısı ile aynı performansa sahip olduğunu ve girişim, faz kayması kanalları için bir önemli bir avantaj sağladığını söylemişlerdir. Ayrıca önerdikleri alıcının istenmeyen etkileri tahmin edebileceği, bu etkileri iptal edebileceği ve sönümlenen kanallar için de kullanılabileceğini söylemişlerdir.

Chikha ve diğ. [37], çok girişli ve çok çıkışlı (multiple-input multiple-output, MIMO) yayın kanalları için, örüntü tanımaya dayalı karar ağacı sınıflandırıcısını (J48) ve eğitilmiş çok katmanlı algıyacıyı (Multilayer Perceptron, MLP) kullanarak bir modülasyon tanıma algoritması sunmuşlardır. Sinyal tanıma için M-ary kaydırmalı anahtarlama (M-ary shift-keying) kullanmışlardır. Uygulama makul bir eğitim süresinde başarılı sonuçlar vermiştir. Sonuç olarak J48-MLP karışımı sınıflandırıcı geniş bant teknolojilerinde sinyallerin daha iyi izlenmesi için kullanıldığında yüksek performans sağlayabilmektedir.

O'Shea ve diğ. [38], derin evrişimli sinir ağlarının, karmaşık zamanlı radyo sinyalleri üzerine uygulanmasını araştırmışlardır. Modülasyon türü olarak BPSK, QPSK, 8PSK, 16QAM, 64QAM, BPSK, CPFSK, PAM4, WB-FM, AM-SSB ve AM-SSB'den oluşan 11 modülasyonlu bir veri setini kullanmışlardır. Düşük SNR değerlerinde radyo sinyallerinin tanınmasında evrişimli sinir ağlarından öğrenilen özniteliklerin kullanılmasının yüksek performans sağladığını söylemişlerdir.

West ve O'Shea [39], derin öğrenme algoritmalarını radyo modülasyonunu tanıma probleminde kullanmaya yönelik çalışmalar yapmışlardır. Elde ettikleri sonuçlarda radyo modülasyonu tanımanın sinir ağının derinliği ile sınırlandırılmamasını, daha çok çalışma yapılarak öğrenme senkronizasyonunun ve eşitlenmenin geliştirilmesine odaklı çalışmaların yapılmasının da gerekli olduğunu söylemişlerdir.

O'Shea ve diğ. [40], radyo haberleşme sinyallerinin sınıflandırma probleminin çözümüne yönelik derin öğrenme tabanlı bir sınıflandırıcı tasarlamışlardır. Sınıflandırma modelini oluşturmak için CNN ile Artık Sinir Ağı (Residual Neural Network, ResNet) mimarilerini kullanmışlardır. Sınıflandırma için 4ASK, BPSK, QPSK, 8PSK, 16QAM, AM-SSB-SC, AM-DSB-SC, FM, GMSK, OQPSK sinyallerinin bulunduğu normal sınıf ve 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 sinyallerinin bulunduğu zor sınıf olmak üzere iki farklı veri setini kullanmışlardır. Sundukları iki yaklaşımın arasındaki performansları tartışmışlardır.

Liu ve diğ. [41], kablosuz sinyallerin modülasyon tanıma probleminin çözümüne yönelik derin öğrenme algoritmalarını kullanarak çeşitli mimariler geliştirmişlerdir. Çalışmalarında GNU radyo ile oluşturulmuş 8PSK, AM-DSB, BPSK, CPFSK, GFSK, PAM4, QAM16, QAM64, QPSK, WBFM olmak üzere 10 farklı modülasyon içeren bir veri seti kullanmışlardır. İlk önce yüksek performans sağlayan dört evrişim katmanı ve iki yoğun katman içeren bir CNN mimarisi geliştirmişlerdir. Bu CNN mimarisi yüksek SNR değerlerinde yaklaşık olarak %83,8 oranında bir doğruluk sağlamıştır. Ardından benzer oranda yüksek SNR değerlerinde doğruluk elde etmek için ResNet ve Yoğun Bağlantılı Ağlar (Densely Connected Networks, DenseNet) teknolojilerini kullanarak yeni mimariler geliştirmişlerdir. En son, yüksek SNR değerinde yaklaşık olarak %88,5 oranında bir doğruluk elde ettikleri Evrişimli Uzun Kısa Vadeli Derin Sinir Ağı (Convolutional Long Short-term Deep Neural Network, CLDNN) mimarisini geliştirmişlerdir.

Zhang ve diğ. [42], otomatik modülasyon sınıflama probleminin çözümüne yönelik heterojen bir derin model birleştirme (Heterogeneous Deep Model Fusion, HDMF) metodu önermişlerdir. Çalışmalarda MASK, MFSK, MPSK ve MQAM modülasyonlarını kullanmışlardır. CNN ve LSTM mimarilerinin birleştirilmesiyle oluşturulan HDMF mimarisi bu ağların birleştirilmeden önce oluşturulan mimarilere göre daha iyi performans gösterdiğini söylemişlerdir.

Önder [43], Yazılım Tabanlı Haberleşme Sistemleri için Yapay Sinir Ağları kullanarak alıcı tasarımı çalışmaları yapmıştır. Bu çalışmalarda örneklenmiş ve temel banda düşürülmüş alttaşıyıcılı sinyal demodülasyonu üzerinde durmuştur. Demodülasyon işlemi sırasında ortaya çıkan sistem hataları, girişim, çeşitli gürültü kanallarının etkilerini de ele alarak bu etkilerinde yapay sinir ağları ile giderilebildiğini gösteren çalışmalar yapmıştır.

Mohammad ve Sorour [44], makine ve derin öğrenme algoritmalarını kullanarak Mobil Uç Öğrenme (Mobile Edge Learning, MEL) adını verdikleri bir optimizasyon paradigması oluşturmuşlardır. MEL'in görevi heterojen haberleşme sistemlerine sahip kanallar üzerinde heterojen düğümlerde dağıtılmış öğrenme görevlerini verimli bir şekilde yürütmek ve öğrenme doğruluğunu üst seviyelere çıkarabilmektir.

Elbaz ve Zibulevsky [45], Frekans Modülasyonu (Frequency Modulation, FM) demodülasyonu için LSTM derin öğrenme algoritmalarını kullanarak uçtan uca öğrenme sağlayan, demodülasyon esnasında gönderilen sesli mesajın ön bilgisini kullanan bir SDR alıcısı önermişlerdir. Konuşma sinyallerini kullanan bu SDR alıcısı düşük SNR değerlerinde yüksek performans göstermiştir.

Mohammad ve diğ. [46], derin öğrenme algoritmalarını kullanarak sönümlemeli kablosuz sinyallerin demodülasyonu için bir Derin Evrişimli Sinir Ağı (Deep Convolutional Neural Network, DCNN) mimarisi önermişlerdir. DCNN mimarisi Destek Vektör Makinesi (Support Vector Machine, SVM), Doğrusal Ayırt Edici Analizi (Linear Discriminant Analysis, LDA) ve MLP gibi diğer ML sınıflandırıcılar ile karşılaştırılmıştır. Geliştirilen DCNN yaklaşık 10 dB değerinde olağanüstü bir performans göstermiştir. Bir AWGN Rayleig kanalı üzerinde 10 dB ile 20 dB arasında FSK demodülasyonunun simülasyonu gerçekleştirilmiştir ve DCNN'in demodülatör olarak kullanılmasının ne kadar faydalı olduğu gösterilmiştir.

Ramjee ve diğ. [47], kablosuz haberleşme sinyallerinin modülasyon türünü tespit eden derin öğrenme tabanlı otomatik modülasyon sınıflandırıcılar geliştirmişlerdir. CNN, DenseNet, CLDNN, LSTM ve ResNet mimarilerinden oluşan modeller tasarlamışlardır. Çalışmalarında BPSK, QPSK, 8PSK, QAM16, QAM64, BFSK, CPFSK, PAM4, WBFM ve AM-DSB olmak üzere 10 farklı modülasyon içeren GNU radyo tabanlı bir veri seti kullanmışlardır. İlk olarak geliştirdikleri CNN mimarisinde yüksek performans yakalamışlardır. Ardından geliştirilen CLDNN, LSTM ve ResNet mimarilerinde de yüksek SNR değerlerinde yaklaşık olarak %90 oranında tipik sınıflandırma doğruluğu sağlanmıştır.

Yashashwi ve diğ. [48], bilişsel radyolarda spektrum algılama yaparken modülasyon tanıma probleminin çözümüne yönelik derin öğrenme tabanlı CNN mimarisini kullanan bir modülasyon sınıflayıcı geliştirmişlerdir. CNN, kablosuz kanallardan kaynaklanan bozulmaları geri almakta çok etkin olamamaktadır. Bu yüzden CNN tabanlı modülasyon tanıyıcının yanında sinyal bozulma düzeltme modülü (Correction Module, CM) kullanmayı uygun görmüşlerdir. CNN ve CM'le birleşik bir ağ oluşturarak birlikte uçtan uca eğitilmiştir. Çalışmalarda 8PSK, AM-DSB, AM-SSB, BPSK, CPFSK, PAM4, QAM16, QAM64, QPSK, WBFM olmak üzere 11 farklı modülasyondan oluşan GNU radyo tabanlı bir veri seti kullanılmıştır. Önerilen bu birleşik ağ hem düşük hem de yüksek SNR değerlerinde önemli doğruluk iyileştirmeleri elde etmiş ve yüksek performans sağlanmıştır.

Mendis ve diğ. [49], yaptıkları çalışmalarda radyo sinyallerini tespit etme ve tanıma probleminin çözümüne yönelik bilişsel radar ile mikro insansız hava sistemlerini tanıma ve bilişsel radyo için modülasyon sınıflandırma olmak üzere derin öğrenme tabanlı bir yöntem geliştirmişlerdir. Önerdikleri bu derin ağ sınıflandırıcı için spektral korelasyon fonksiyonunu kullanarak bir özellik çıkarıcı oluşturulmuş ve düşük Sahada Programlanabilir Kapı Dizisi (For Field-Programmable Gate Array, FPGA) mantık kullanımından faydalanılmıştır.

Wang ve diğ. [50], derin öğrenmenin sinyal demodülasyonu üzerindeki yöntemlerini araştırmışlar ve kablosuz haberleşme sistemleri için modüleli sinyallerden oluşan ilk açık veri setini oluşturmuşlardır. Oluşturdukları açık veri seti BPSK, 4-QAM, 8-QAM, 16-QAM, 32-QAM, 64-QAM, 128-QAM ve 256-QAM olmak üzere sekiz farklı modülasyondan oluşmaktadır. DBN-SVM tabanlı ve AdaBoost tabanlı olmak üzere iki adet DL tabanlı demodülatör önermişlerdir. Yapılan deneysel çalışmalar sonucunda önerdikleri demolatörlerin yüksek performans gösterdiklerini söylemişlerdir.

2.4. SENKRONİZE SIKIŞTIRMA DÖNÜŞÜMÜ

Zaman-Frekans Analizi, bir sinyalin frekans içeriğinin zaman içerisinde nasıl değiştiğini analiz etmeye yarar. Senkronize Sıkıştırma Dönüşümü (Synchrosqueezing Transform, SST), karmaşık sinyalleri zamanla değişen salınımlı bileşenlere ayrıştırabilen bir zaman-frekans analiz yöntemidir. SST seyrek, tersine çevrilebilir ve sinyalin kurtarılmasına izin veren zaman-frekans yeniden atama biçimidir [51].

Sürekli Dalgacık Dönüşümü (Continuous Wavelet Transform, CWT), Kısa Zamanlı Fourier Dönüşümü (Short-Time Fourier Transform, STFT), Fourier Tabanlı Senkronize Sıkıştırma Dönüşümü (Fourier-Based Synchrosqueezing Transform, FSST) ve Dalgacık Tabanlı Senkronize Sıkıştırma Dönüşümü (Wavelet-Based Synchrosqueezing Transform, WSST) yaygın olarak kullanılan SST yöntemleridir.

Literatürde SST yöntemleri ve derin öğrenme algoritmaları birlikte kullanılarak yapılan çalışmalar bulunmaktadır.

Kong ve Koivunen [52], radar dalga biçimlerini tanıma problemine yönelik bir derin öğrenme algoritması önermişlerdir. Alınan radar sinyalini, keskin ve konsantre gösterim sağlayan Fourier Tabanlı Senkronize Sıkıştırma Dönüşümü (Fourier-Based Synchrosqueezig Transform,

FSST) tarafından zaman-frekans görüntülerine dönüştürmüşlerdir. FSST sonucu ortaya çıkan iki değişkenli görüntünün, görüntü kırpma ve yeniden boyutlandırma işlemlerini gerçekleştirmişlerdir. Ardından görüntüyü tasarladıkları CNN mimarisinde bir girdi olarak kullanmışlardır. Önerdikleri bu yöntemin, CWD'li CNN'e kıyasla neredeyse %3 oranında daha iyi genel sınıflandırma ve ayırt etme yeteneğine sahip olduğunu gözlemlemişlerdir. Çok fazlı sinyaller için performans kazancı yüksek çıkmıştır. Önerilen yöntem düşük SNR değerinde ise CWD ile CNN yöntemine kıyasla daha düşük ayrım yeteneğine sahiptir.

Kong ve diğ. [53], çok yollu kanallarda radar dalga formu tanıma problemine yönelik hiyerarşik bir derin öğrenme algoritması önermişlerdir. İlk olarak çok yollu solmanın radar sinyali üzerindeki etkisini azaltmak için DAE kullanarak sinyali eşitlemişlerdir. Eşitlenmiş sinyali FSST kullanarak keskin, nedensel ve konsantre bir zaman-frekans gösterimine sahip karmaşık değerli görüntüye dönüştürmüşlerdir. Ortaya çıkan iki değişkenli görüntü, kırpma ve yeniden boyutlandırma işleminden geçirildikten sonra tasarladıkları CNN mimarisinde bir girdi olarak kullanmışlardır. DAE kör bir ekolayzer olarak kullanılarak tek aşamalı sınıflandırmanın genel sınıflandırma olasılığını önemli oranda iyileştirmişlerdir. İki aşamalı sınıflandırma için hiyerarşik yapıyı uygulayarak SNR -8 dB'nin altında olduğu durumda tek aşamalı sınıflandırmaya göre %0,5'ten fazla genel sınıflandırma olasılığı olduğunu gözlemlemişlerdir. FSST sayesinde düşük SNR değerlerinde CWD'ye göre P1 ve P4 dalga biçimleri arasında daha iyi ayrım yeteneğine sahip olduklarını görmüşlerdir. Önerdikleri iki aşamalı sınıflandırmada SNR -8 dB'den az olduğu durumda CWD'den %0,3'ten daha fazla genel sınıflandırma olasılığı gösterir.

Zhang ve diğ. [54], çapraz terim içermeyen zaman-frekans görüntüleri elde etmek için CAE mimarisini kullanan bir makine öğrenimi algoritması önermişlerdir. Önerdikleri algoritmada; bir DNN, sinyalin otomatik terimlerini korurken istenmeyen çapraz terimleri tamamen azaltmak için etkili üretken öğrenme yeteneği sağlamak üzere eğitilmiştir. Simülasyon sonuçları, sinir ağlarının yeterince eğitilmiş olması şartıyla önerilen algoritmanın sağlam çalıştığını mevcut zaman-frekans yeniden yapılandırma algoritmalarına kıyasla önemli bir performans artışı sağladığını söylemişlerdir.

Verstraete ve diğ. [55], rulmanlı rulmanların arıza tespiti problemine yönelik ham titreşim sinyallerinin zaman-frekans görüntü temsillerine yeni bir CNN mimarisi uygulamışlardır. Önerdikleri CNN modelinin hatayı doğru şekilde tespit etme yeteneğini belirlemek için STFT,

WT ve HHT olmak üzere üç zaman-frekans analiz yöntemi ile karşılaştırmışlardır. Toplamda 189.406 tane görüntüyü analiz etmişlerdir. Önerdikleri CNN mimarisinin, deneysel gürültüye karşı dayanıklı olduğunu söylemişlerdir. Mimari, spektrogramlar ve HHT görüntüleri için benzer mimarilerden daha iyi performans vermiştir.

Pham [56], fizyolojik sinyalleri kullanarak hastalıkları tespit etme performansını geliştirmek için yapay zeka tabanlı bir algoritma sunmuştur. Önerilen algoritmada, sınıflandırma görevini artırmak, hesaplama karmaşıklığını azaltmak ve etkili derin öğrenme için zaman verilerden hem frekanstan hem de alandan çıkarılan bilgilerin avantajlarını kullanmıştır. Çalışmada sunduğu Al tabanlı yöntem, fizyolojik verileri kaydetmek için birden fazla sensör kullanma ihtiyacını azaltma potansiyeline sahip olduğunu ve böylece katılımcılara hem maliyet tasarrufu hem de rahatlık sağladığını söylemiştir.

2.4.1. Fourier Tabanlı Senkronize Sıkıştırma Dönüşümü

FSST, karmaşık yapılı çok bileşenli sinyallerin zaman-frekans alanında konsantre bir zaman-frekans temsilini sağlamak için kullanılan ve etkili bir yaklaşım olan bir zaman-frekans dönüşümü yöntemidir [57].

FSST, sinyal modüllerini zaman içinde sınırlamak ve daha sonra sinyalin davranışının frekanstaki değişimini analiz etme yeteneğine sahiptir [52]. FSST dönüşümü, bir tür zaman-frekans yeniden atama yöntemi türüdür. Katsayıları ölçek veya frekansta yeniden atayarak kısa zamanlı Fourier dönüşümünün zaman-frekans alanında çalışır [52]. Bu yer değiştirme işlemi sayesinde seyrek ve keskin zaman-frekans görüntüleri elde edilir. Böylece alınan çeşitli sinyal biçimleri arasında sınıflandırma yapma kolaylaştırılır. FSST'de nedenselliği korumak için katsayılar yalnızca frekans bileşeninde atanır [52].

FSST, $f(t)$ ile tanımlanan çok bileşenli bir sinyali K osilatör bileşenlerine ayırır [57].

$$f(t) = \sum_{k=1}^{K} f_k(t) = \sum_{k=1}^{K} A_k(t)\, e^{j2\pi\phi_k(t)} \tag{2.4}$$

Burada $A_k(t)$ anlık genlik, $\phi_k'(t)$ ise k bileşeninin anlık frekansıdır [57].

FSST $T_f(\omega, t)$, STFT $V_f(\eta, t)$'nin (η, t)'den $(\widehat{\omega}_f(n, t), t)$'ye değiştirilmiş katsayılarına dayanır [52].

$$T_f = \frac{1}{g(0)} \int V_f\,(\eta, t)\; \delta\left(-\widehat{\omega}_f\,(\eta, t)\right) d_\eta \tag{2.5}$$

Bu denklemde $g(0)$, 0 anındaki $g(t)$ kayan pencerenin değerini, δ dirac delta fonksiyonunu ve $\widehat{\omega}_f\,(\eta, t)$ ise tanımlanan anlık frekansı ifade etmektedir [52].

$$\widehat{\omega}_f\,(n, t) = Re\left(\frac{1}{j2\pi}\,\frac{\partial_t V_f\,(\eta,t)}{V_f\,(\eta,t)}\right) \tag{2.6}$$

$V_f\,(\eta, t) > 0$ olduğu zaman anlık frekans $\widehat{\omega}_f\,(\eta, t)$ ile tahmin edilebilir. FSST ile L x L boyutunda karmaşık değerli iki değişkenli $T_f\,(\omega, t)$ görüntüsü elde edilebilir [52].

Bu tez çalışmasında RadioML 2016.10A veri seti içerisinde bulunan karmaşık modülasyon sinyallerine FSST yöntemi uygulanarak sinyallerin zaman-frekans alanındaki görüntüleri elde edilmiştir. Keskin ve konsantre görüntüler elde edebilmek için FSST yöntemi tercih edilmiştir.

3. MALZEME VE YÖNTEM

Bu bölümde; ilk olarak tez çalışmasında kullanılan veri seti, zaman-frekans analizi için kullanılan yöntemler, veri seti içerisinde bulunan sinyallerin zaman-frekans görüntülerinin elde edilmesi, zaman-frekans görüntüleri alınan verinin eğitim ve test verilerine ayrılması gibi veri ön işlemesi ile ilgili bilgiler verilecektir.

İkinci adımda zaman-frekans dönüşümleri alınan sinyallerin sınıflandırılması için oluşturulan derin öğrenme modeli, sınıflandırma yöntemleri, konfigürasyonları ve oluşturulan modelin eğitilmesi hakkında bilgiler verilecektir.

3.1. VERİ SETİ

Bu tez çalışmasında RadioML 2016.10A [58] hazır veri seti kullanılmıştır. RadioML 2016.10A değişen sinyal-gürültü oranlarında GNU Radyo kullanılarak oluşturulmuş içerisinde 11 modülasyon bulunan sentetik bir veri setidir. Bu veri seti ilk olarak O'Shea ve West [59] tarafından 6. Yıllık GNU Radyo Konferansında yayınlanmıştır. Veri seti içerisindeki 11 modülasyondan üçü analog modülasyon, sekizi ise sayısal modülasyon türlerinden oluşmaktadır. Tablo 3.1'de bu veri seti içerisinde bulunan analog ve sayısal modülasyon türleri gösterilmektedir.

Tablo 3.1: RadioML 2016.10A veri seti içerisinde bulunan modülasyon türleri.

Analog Modülasyon Türleri	AM-SSB, AM-SSB ve WBFM
Sayısal Modülasyon Türleri	8PSK, BPSK, CPFSK, GFSK, PAM4, QAM16, QAM64 ve QPSK

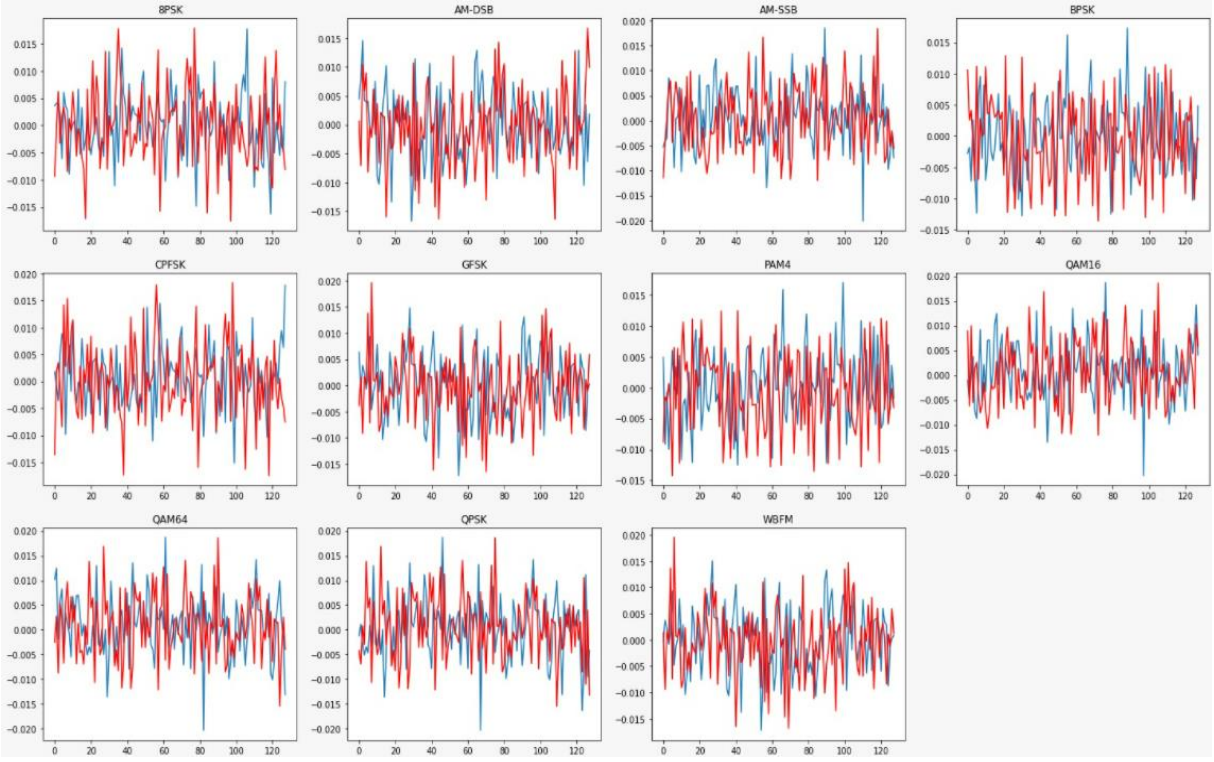
Alıcıda belirli bir gürültüde termik gürültü simülasyonunu tanıtan GNU Radyo, AWGN gürültü modeli ile güç seviyesine karşılık gelen sinyal gürültü oranlarını elde etmiştir. Veri seti içerisinde bulunan 11 modülasyondan her biri -20 dB ile +18 dB arasında 2'şer artarak değişen 20 farklı SNR değerinden oluşmaktadır. Her bir modülasyon türünün 20 farklı SNR değerindeki veri kümesi, her bir SNR değerinde 128 örnek uzunluğunda 1000 tane karmaşık radyo sinyali veri örneğini barındırmaktadır. Her bir modülasyon türü için bir SNR değerindeki veri boyutu

(1000, 2, 128)'dir. Dolayısıyla veri setinin boyutu (20*11*1000, 2, 128)'dir. Tablo 3.2'de veri setine ait veri boyutları gösterilmektedir.

Tablo 3.2: RadioML 2016.10A veri seti içerisinde bulunan verinin boyutu.

Tek bir modülasyon türüne ait tek bir SNR değerindeki verinin boyutu	(1000, 2, 128)
Tek bir modülasyon türüne ait toplam 20 farklı SNR değeri içeren verinin boyutu	(20000, 2, 128)
Tüm veri setinin boyutu	(220000, 2, 128)

Veri seti içerisinde bulunan sinyallere ait örnek görüntüler Şekil 3.1'de gösterilmektedir.



Şekil 3.1: RadioML 2016.10A veri setindeki sinyallere ait örnek görüntüler.

3.2. VERİ ÖN İŞLEME

3.2.1. Veri Seti İçerisindeki Sinyallerin FSST Görüntülerinin Alınması

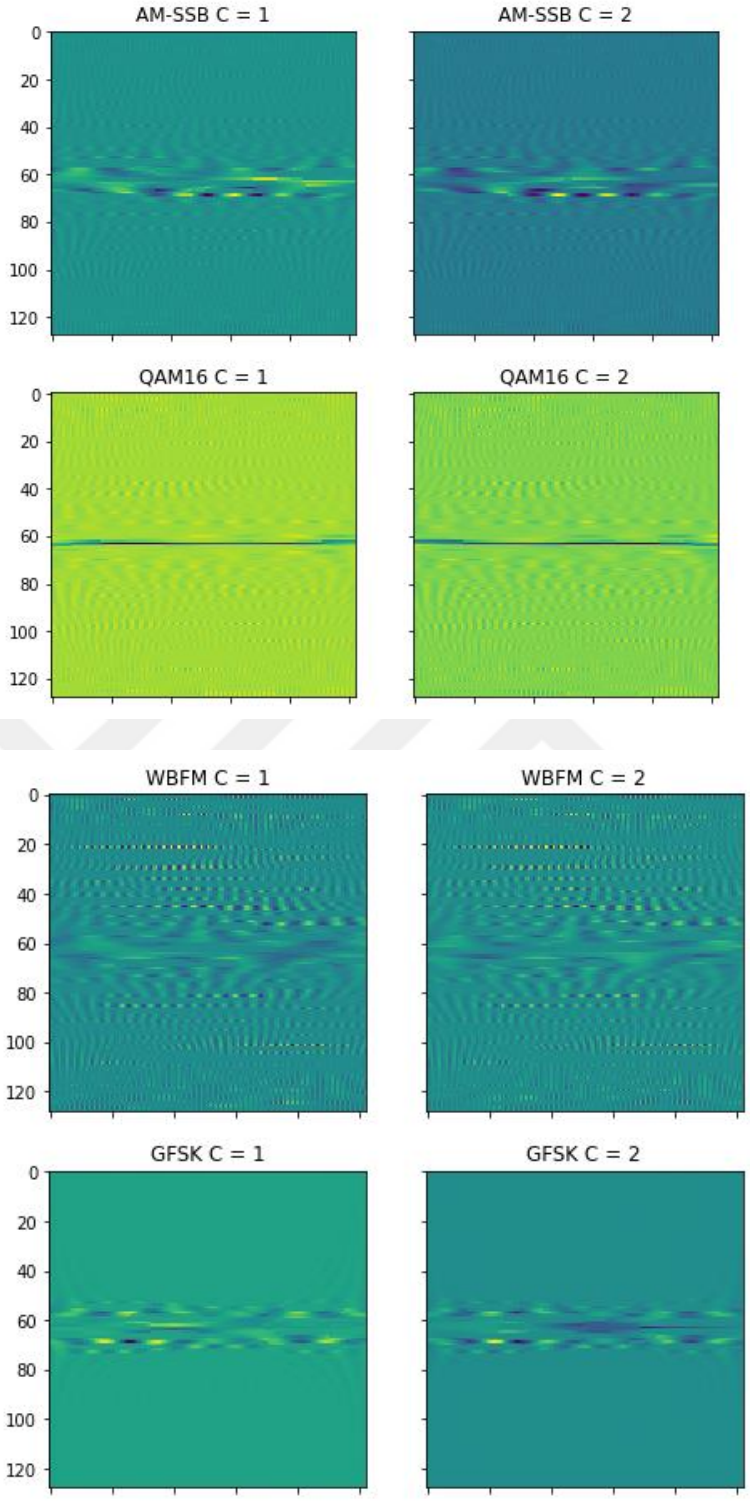
Bu çalışmada, kullanılan veri seti içerisinde bulunan 11 modülasyona ait ham sinyallerin özelliklerinin ortaya çıkartılması ve eğitilebilir bir veri seti haline getirilebilmesi için sinyallerin zaman-frekans dönüşümleri alınarak zaman-frekans görüntüleri elde edilmiştir.

Sinyallerin zaman-frekans dönüşümleri MATLAB ortamında alınmıştır. MATLAB ortamında modülasyon sinyallerine zaman-frekans dönüşümü yöntemlerinden CWD, STFT ve FSST dönüşümleri uygulanmıştır. Ortaya çıkan zaman-frekans görüntüleri incelendiğinde sinyallere ait en keskin ve konsantre görüntülerin FSST yöntemi ile elde edildiği belirlenmiştir. Bu yüzden veri seti içerisindeki tüm modülasyonlara ait sinyallerin FSST görüntüleri alınarak sinyallerin özellikleri ortaya çıkartılmıştır.

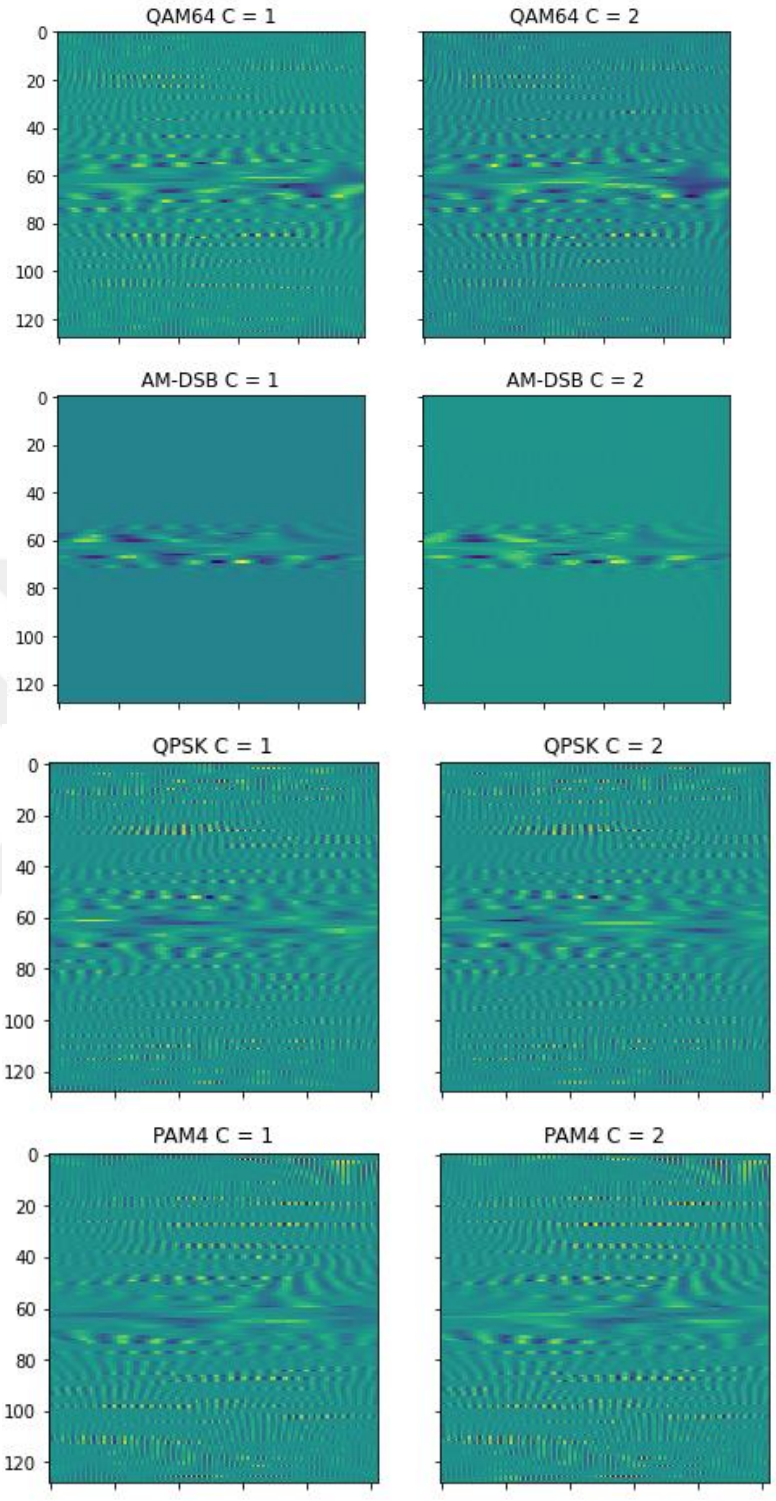
Veri seti içerisinde 11 modülasyondan oluşan, her bir modülasyon türüne ait 20 farklı SNR değerine sahip toplamda 220000 tane karmaşık sinyal bulunmaktadır. Bu sinyallere ait her bir modülasyon türünde 20 farklı SNR değeri için toplamda 220000 tane zaman-frekans görüntüsü elde edilmiştir.

MATLAB ortamının fiziksel özellikleri ve FSST sonucunda alınan görüntülerin boyutlarının çok büyük olması sebebiyle 220000 veri 5000'e bölünerek toplamda 44 tane veri seti olmak üzere görüntüler kaydedilmiştir. 44 tane veri seti daha sonra Google Colab Pro ortamında önerilen derin öğrenme modelinin eğitilebilmesi için birleştirilmiştir.

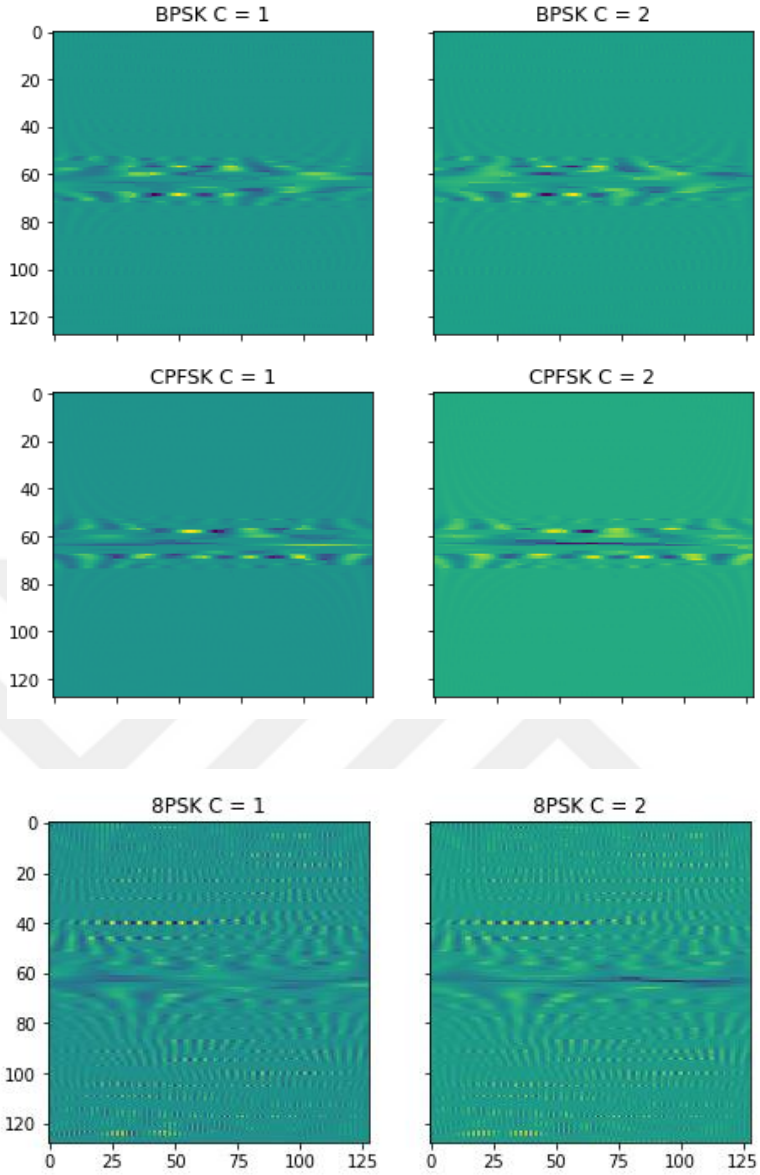
FSST sonucu çıkan verilerin reel ve sanal kısımları birleştirilerek iki kanallı bir görüntü haline getirilmiştir. Ardından derin öğrenme algoritmalarıyla oluşturulan modelin eğitilebilmesi için veriler 128x128x2 boyutlu girdi haline dönüştürülmüştür. MATLAB ortamında alınan herhangi bir SNR değerine sahip tüm modülasyon türlerine ait örnek zaman-frekans görüntüleri Şekil 3.2'de gösterilmektedir. Görüntülerde bulunan C=1 ifadesi karmaşık sinyallere ait reel kısmının görüntülerini, C=2 ise sanal kısımlarına ait zaman-frekans görüntüleri temsil etmektedir.



Şekil 3.2: Zaman-frekans dönüşümleri alınan karmaşık sinyallere ait örnek görüntüler.



Şekil 3.2 (devam): Zaman-frekans dönüşümleri alınan karmaşık sinyallere ait örnek görüntüler.



Şekil 3.2 (devam): Zaman-frekans dönüşümleri alınan karmaşık sinyallere ait örnek görüntüler.

3.2.2. Verilerin Karıştırılması

Ham veri seti içerisinde bulunan modülasyon sınıfları sırasıyla AM-SSB, QAM16, WBFM, GFSK, QPSK, PAM4, QAM64, AM-DSB, BPSK, CPFSK, 8PSK olmak üzere belirli bir sırada bulunmaktadır. Bu modülasyon sınıfları FSST sonucu alınan görüntülerden oluşturulan veri seti üzerinde rastgele bir şekilde karıştırılmıştır.

3.2.3. Hedef Sınıfların Sayısal Verilere Dönüştürülmesi

Veri seti içerisinde bulunan hedef sınıflar sırasıyla AM-SSB, QAM16, WBFM, GFSK, QPSK, PAM4, QAM64, AM-DSB, BPSK, CPFSK, 8PSK başlıkları ile bulunmaktadır. Sınıflandırma sırasında bu başlıkların sıkıntı oluşturmaması için hedef sınıflar sırasıyla 0, 1, 2, 3, 4, 5, 6, 7, 8, 9, 10 olmak üzere sayısal değerlere dönüştürülmüştür.

3.2.4. Veri Setinin Eğitim ve Test Sınıflarına Ayrılması

Veri seti içerisinde toplamda 220000 veri bulunmaktadır. Sinyallerin FSST görüntüleri alındıktan sonra oluşan görüntülerin boyutu çok yüksek değerlere ulaşmıştır. Verilerin yüklenmesi gereken ve önerilen derin öğrenme modelinin eğitilebilmesi için kullanılan ortamın fiziksel donanım yetersizliğinden dolayı eğitim verileri 60000, 70000 ve 60000 olmak üzere 3 veri setine bölünmüştür. Kalan 30000 veri ise test sınıfları olarak kullanılmıştır**.** Eğitim ve test verilerine ait değerler Tablo 3.3'te gösterilmektedir.

Tablo 3.3: Eğitim ve test verilerine ait değerler.

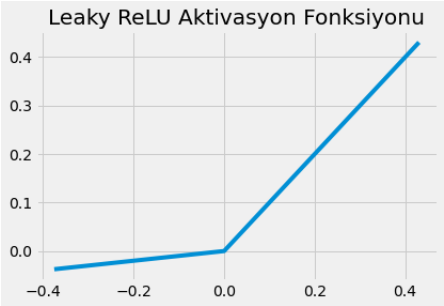
Eğitim Veri Sınıfları	60000, 70000, 60000
Test Veri Sınıfı	30000

3.3. MODEL

Bu tez çalışmasında veri seti üzerindeki modülasyonlu sinyallere FSST uygulanarak zaman-frekans alanındaki görüntüleri elde edilmiş ve içerisinde zaman-frekans görüntülerinin bulunduğu yeni bir veri seti haline getirilmiştir. Modülasyon sınıflandırma, bu veri seti içerisindeki görüntülerin sınıflandırılması üzerinden yapılmıştır. Bu nedenle görüntü sınıflandırmada en iyi sonuçları verebilen ve en doğru yöntem olan CNN derin öğrenme algoritması kullanılmıştır. Sınıflandırma için gerekli parametreler oluşturularak yedi tane evrişim katmanı ve beş tane de yoğun (dense) katman kullanılarak bir CNN mimarisi tasarlanmıştır. Ardından eğitim verileriyle model eğitilmiş ve modelin değerlendirilmesi yapılmıştır. EK-1'de modelin çizdirilmiş ayrıntılı görüntüsünü inceleyebilirsiniz.

3.3.1. Geliştirilen CNN Modeli ve Parametreleri

Geliştirilen model, yedi katmanlı bir evrişimli sinir ağından oluşmaktadır. Modelde aktivasyon fonksiyonu olarak Leaky Relu kullanılmıştır. Veri seti içerisinde bulunan görüntülere ait negatif değerleri de kaybetmemek için bu aktivasyon fonksiyonu tercih edilmiştir. Leaky ReLU aktivasyon fonksiyonu Şekil 3.3'te görülmektedir.



Şekil 3.3: Leaky ReLU aktivasyon fonksiyonu.

FSST ile alınan görüntülerden oluşan veri seti içerisinde bulunan veriler, tasarlanan modelin eğitilebilmesi için evrişimli sinir ağına 128x128x2 boyutlu bir girdi halinde verilmiştir. Hem veri boyutu büyüklüğünden kaynaklı modelin yavaş öğrenmesini engellemek hem de modelin aşırı öğrenmesini engellemek için her evrişimli sinir ağı katmanı için bir max pooling katmanı da kullanılmıştır. Sinir ağı girdilerinin yeniden merkezlenerek sinir ağlarını daha hızlı ve kararlı hale getirilebilmesi için toplu normalleştirme (batch normalization) yapılmıştır. Toplu normalleştirmedeki amaç tüm renkleri 0 ile 1 arasına taşıyarak farklı renklerden kaynaklı belli başlı hataların ortaya çıkmasının önlenmesidir. Girdiler on bir sınıfta sınıflandırılacağı için düzleştirme (flatten) katmanı kullanılarak son katman çıktı sayısı on bir olacak şekilde ayarlanmıştır. Bu adımda çoklu sınıflandırma problemlerinin çözümünde başarılı sonuç veren softmax aktivasyon fonksiyonu kullanılmıştır. Model derlenirken öğrenme oranını değiştirebilmek için Adam eniyileme (optimizer) parametresi kullanılmıştır. Beş tane yoğun katman kullanılarak alınan sinir ağlarının bir sonraki sinir ağına bağlanmasını sağlanmıştır. Ezberlemeyi engellemek ve çeşitliliği artırmak için bazı ağları devre dışı bırakmaya yarayan üç adet dropout kullanılmıştır.

Tasarlanan CNN modeline ait katmanlar ve kullanılan parametreler Tablo 3.4'te ayrıntılı bir şekilde gösterilmektedir.

Tablo 3.4: Model ve model parametreleri.

Model: "model"

Layer (type)	Output Shape	Param #
input_1 (InputLayer)	[(None, 128, 128, 2)]	0
conv2d (Conv2D)	(None, 128, 128, 4)	76
batch_normalization (BatchNormalization)	(None, 128, 128, 4)	16
max_pooling2d (MaxPooling2D)	(None, 64, 64, 4)	0
conv2d_1 (Conv2D)	(None, 64, 64, 8)	296
batch_normalization_1 (BatchNormalization)	(None, 64, 64, 8)	32
max_pooling2d_1 (MaxPooling2D)	(None, 32, 32, 8)	0
conv2d_2 (Conv2D)	(None, 32, 32, 16)	1168
batch_normalization_2 (BatchNormalization)	(None, 32, 32, 16)	64
max_pooling2d_2 (MaxPooling2D)	(None, 16, 16, 16)	0
conv2d_3 (Conv2D)	(None, 16, 16, 32)	4640
batch_normalization_3 (BatchNormalization	(None, 16, 16, 32)	128
max_pooling2d_3 (MaxPooling2D)	(None, 8, 8, 32)	0
conv2d_4 (Conv2D)	(None, 8, 8, 64)	18496
batch_normalization_4 (BatchNormalization)	(None, 8, 8, 64)	256
max_pooling2d_4 (MaxPooling2D)	(None, 4, 4, 64)	0
conv2d_5 (Conv2D)	(None, 4, 4, 128)	73856
batch_normalization_5 (BatchNormalization)	(None, 4, 4, 128)	512
max_pooling2d_5 (MaxPooling2D)	(None, 2, 2, 128)	0
conv2d_6 (Conv2D)	(None, 2, 2, 256)	295168
batch_normalization_6(BatchNormalization)	(None, 2, 2, 256)	1024
max_pooling2d_6 (MaxPooling2D)	(None, 1, 1, 256)	0
flatten (Flatten)	(None, 256)	0
dense (Dense)	(None, 512)	13158

Tablo 3.4 (devam): Model ve Model parametreleri.

Layer (type)	Output Shape	Param #
dropout (Dropout)	(None, 512)	0
dense_1 (Dense)	(None, 128)	65664
dropout_1 (Dropout)	(None, 128)	0
dense_2 (Dense)	(None, 64)	8256
dropout_2 (Dropout)	(None, 64)	0
dense_3 (Dense)	(None, 32)	2080
dropout_3 (Dropout)	(None, 32)	0
dense_4 (Dense)	(None, 11)	363

Total params: 603,679
Trainable params: 602,663
Non-trainable params: 1,016

3.3.2. Modelin Eğitilmesi

Model eğitimi 60000, 70000 ve 60000 olmak üzere 3 veri seti şeklinde ayırdığımız eğitim verileri kullanılarak 3 adımda gerçekleşmiştir. İlk adımda 60000 veri seti üzerinde epoch sayısı 100 olacak şekilde ayarlanarak model eğitilmiştir. Ardından modelin eğitim başarısı değerlendirilerek model kaydedilmiştir. İkinci adımda kaydedilen model 70000 veri seti kullanılarak epoch sayısı 200 olacak şekilde model tekrar eğitilmiştir. Eğitim sonucunda modelin öğrenme başarısının biraz daha iyileştiği görülmüştür ve bu modelde kaydedilmiştir. Üçüncü adımda kaydedilen en son modelin üzerine 3. olarak ayırdığımız 60000 veri seti kullanılarak yine epoch sayısı 300 olacak şekilde model eğitilmiş ve modelin öğrenme başarısının çok yüksek olduğu görülmüştür.

3.3.3. Modelin Değerlendirilmesi

Modelin değerlendirilmesi için ilk olarak doğrulama (accuracy) ve kayıp (loss) metrikleri kullanılarak eğitim verilerinin doğrulama fonksiyonu ve kayıp fonksiyonu çizdirilerek modelin eğitim başarısı değerlendirilmiştir.

Eğitim sonucunda elde ettiğimiz modelin modülasyonları sınıflandırma başarısını değerlendirmek için 30000 olarak ayırdığımız test verileri kullanılmıştır. Modülasyonlara göre SNR değeri belirtilmeksizin genel bir sınıflandırma yapılarak sınıflandırma raporu ve hata matrisi çizdirilmiştir. Ardından sınıflandırma raporu ve hata matrisi incelenerek sınıflandırma sonuçları değerlendirilmiştir.

Son olarak, 20 farklı SNR değerinde 11 modülasyon türünün her birine ait 100 örnek alınıp toplamda 1100 tane veri üzerinden her bir SNR değerine ait modülasyon sınıflandırma raporları ve hata matrisleri ayrı ayrı alınarak değerlendirilmiş ve sonuçlar kaydedilmiştir.

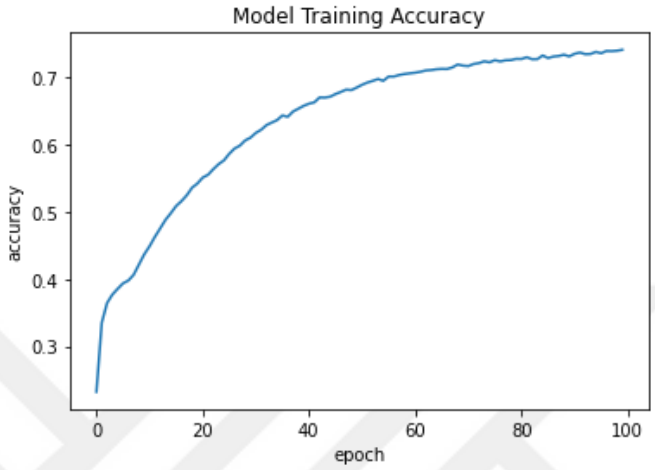
3.4. KULLANILAN TEKNOLOJİLER

Bu çalışmada, verilerin zaman-frekans görüntülerinin alınması için MATLAB ortamında çalışılmıştır. Model eğitim çalışmalarının ve sınıflandırmaların yapılması gibi diğer tüm işlemler için Google Colab Pro ortamında çalışılmıştır. Google Colab Pro ortamında eğitim için kullanılan makine 16 GiB GPU ve 54 GB RAM özelliklerine sahiptir.

4. BULGULAR

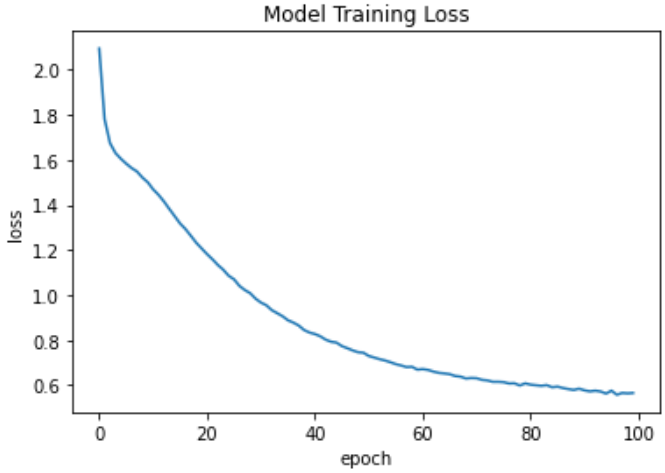
4.1. MODELE AİT METRİK FONKSİYONLARI

4.1.1. 100 Epoch Sayısı İçin Modele Ait Metrik Fonksiyonları



Şekil 4.1: 100 epoch sayısı için modele ait doğrulama fonksiyonu.

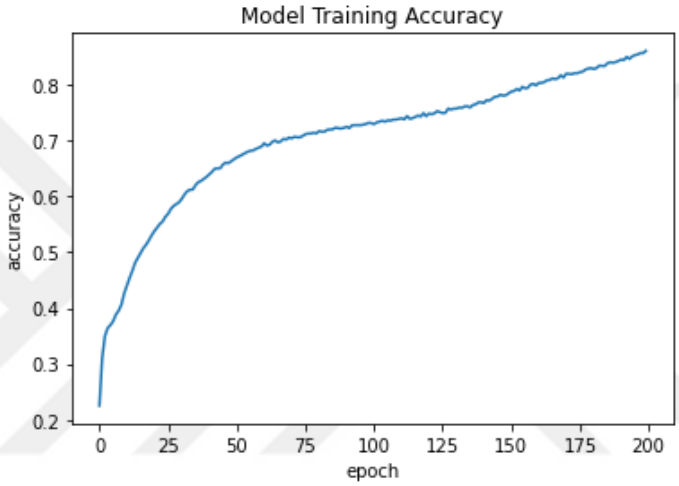
3 set olarak ayırdığımız ilk 60000 eğitim verisinin 100 epoch sayısı için model üzerinde eğitilmesi sonucunda modelin eğitim başarısı %74,16 çıkmıştır. Şekil 4.1'de bu eğitim verilerinin doğrulama fonksiyonu görülmektedir. Doğrulama fonksiyonu 100 epoch değeri için %70 civarında bir başarı göstermektedir. Epoch sayısı artırılarak modelin biraz daha iyileştirilmesi gerekmektedir.



Şekil 4.2: 100 epoch sayısı için modele ait kayıp fonksiyonu.

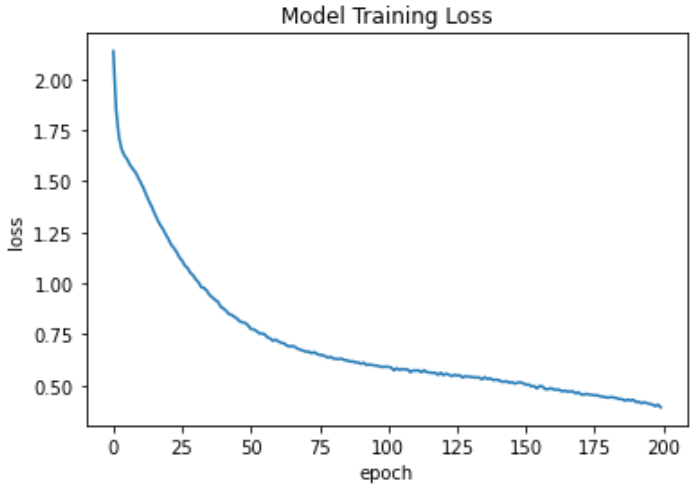
3 set olarak ayırdığımız 60000 eğitim verisinin 100 epoch sayısı için model üzerinde eğitilmesi sonucunda modelin kayıp değeri %56,51 çıkmıştır. Şekil 4.2'de 100 epoch sayısı için eğitim verilerinin kayıp fonksiyonu gösterilmektedir. 100 epoch değerinde modelin kayıp fonksiyonunun yaklaşık %50 civarında olduğu görülmektedir. Bu da modelin başarı performansının biraz daha yükseltilmesi gerektiğini göstermektedir.

4.1.2. 200 Epoch Sayısı İçin Modele Ait Metrik Fonksiyonları



Şekil 4.3: 200 epoch sayısı için modele ait doğrulama fonksiyonu.

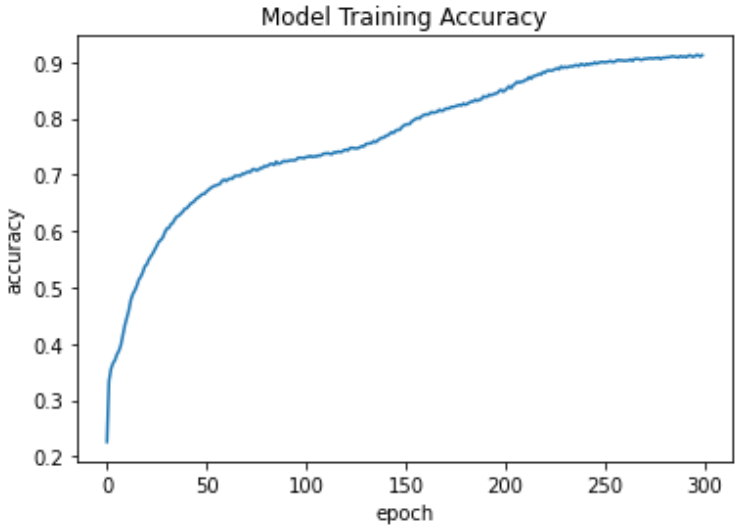
3 set olarak ayırdığımız ikinci 70000 eğitim verisinin 200 epoch sayısı için model üzerinde eğitilmesi sonucunda modelin eğitim başarısı %86,09 çıkmıştır. Şekil 4.3'te bu eğitim verilerinin doğrulama fonksiyonu gösterilmektedir. Doğrulama fonksiyonu 200 epoch değeri için %80 civarında bir başarı göstermektedir. Epoch sayısı artırılarak model biraz daha iyileştirilebilir.



Şekil 4.4: 200 epoch sayısı için modele ait kayıp fonksiyonu.

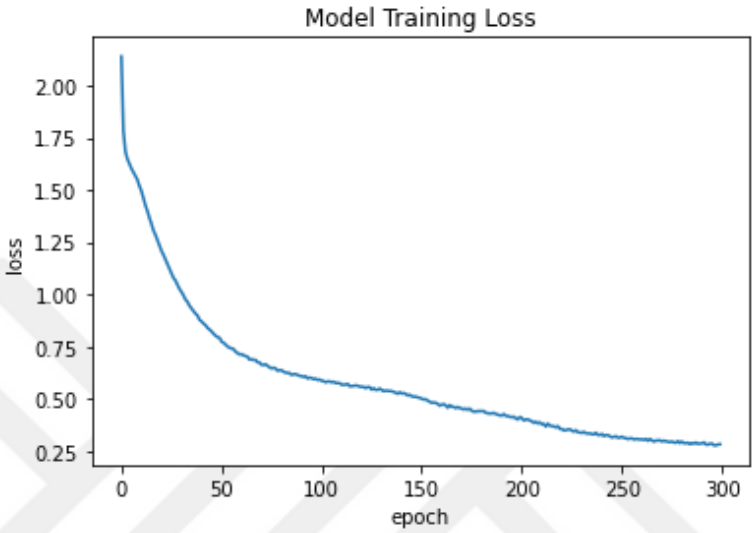
3 set olarak ayırdığımız 70000 eğitim verisinin 200 epoch sayısı için model üzerinde eğitilmesi sonucunda modelin kayıp değeri %39,20 çıkmıştır. Şekil 4.4'te 200 epoch sayısı için eğitim verilerinin kayıp fonksiyonu gösterilmektedir. 200 epoch değerinde modelin kayıp fonksiyonunun yaklaşık %40 civarında olduğu görülmektedir. Bu da modelin başarı performansının yükseltilebilmesi için epoch sayısının biraz daha artırılması gerektiğini göstermektedir.

4.1.3. 300 Epoch Sayısı İçin Modele Ait Metrik Fonksiyonları



Şekil 4.5: 300 epoch sayısı için modele ait doğrulama fonksiyonu

3 set olarak ayırdığımız 60000 eğitim verisinin, 300 epoch sayısı için model üzerinde eğitilmesi sonucunda modelin eğitim başarısı %91,71 çıkmıştır. Şekil 4.5'te bu eğitim verilerinin doğrulama fonksiyonu görülmektedir. Doğrulama fonksiyonu 300 epoch değeri için %90 civarında bir başarı göstermektedir. Böylece 300 epoch değerinde modelin daha da iyileştirilerek yüksek performans sağladığı görülmüştür.



Şekil 4.6: 300 epoch sayısı için modele ait kayıp fonksiyonu

3 set olarak ayırdığımız 60000 eğitim verisinin 300 epoch sayısı için model üzerinde eğitilmesi sonucunda modelin kayıp değeri %26,21 çıkmıştır. Şekil 4.6'da 300 epoch sayısı için eğitim verilerinin kayıp fonksiyonu gösterilmektedir. 300 epoch değerinde modelin kayıp fonksiyonunun yaklaşık %26 değerlerine kadar düşmüştür. Bu da modelin başarı performansının yüksek olduğunu ve iyileştirildiğini göstermektedir.

4.2. GENEL MODÜLASYON SINIFLANDIRMA RAPORU VE HATA MATRİSİ

Eğitim sonrası ortaya çıkan sonuçlar incelendiğinde model 300 epoch sayısına yükseltilerek iyileştirilmiş ve yüksek başarı oranı elde edilmiştir. Modülasyon sınıflandırmalar iyileştirilen model üzerinden yapılmıştır. Eğitim sonucunda elde ettiğimiz modelin, modülasyonları sınıflandırma başarısını değerlendirmek için 30000 olarak ayırdığımız test verileri kullanılmıştır. Test verileri kullanılarak modelin sınıflandırma raporu (classification report) ve hata matrisi (confusion matrix) alınarak modülasyon türlerine göre sınıflandırma başarıları değerlendirilmiştir.

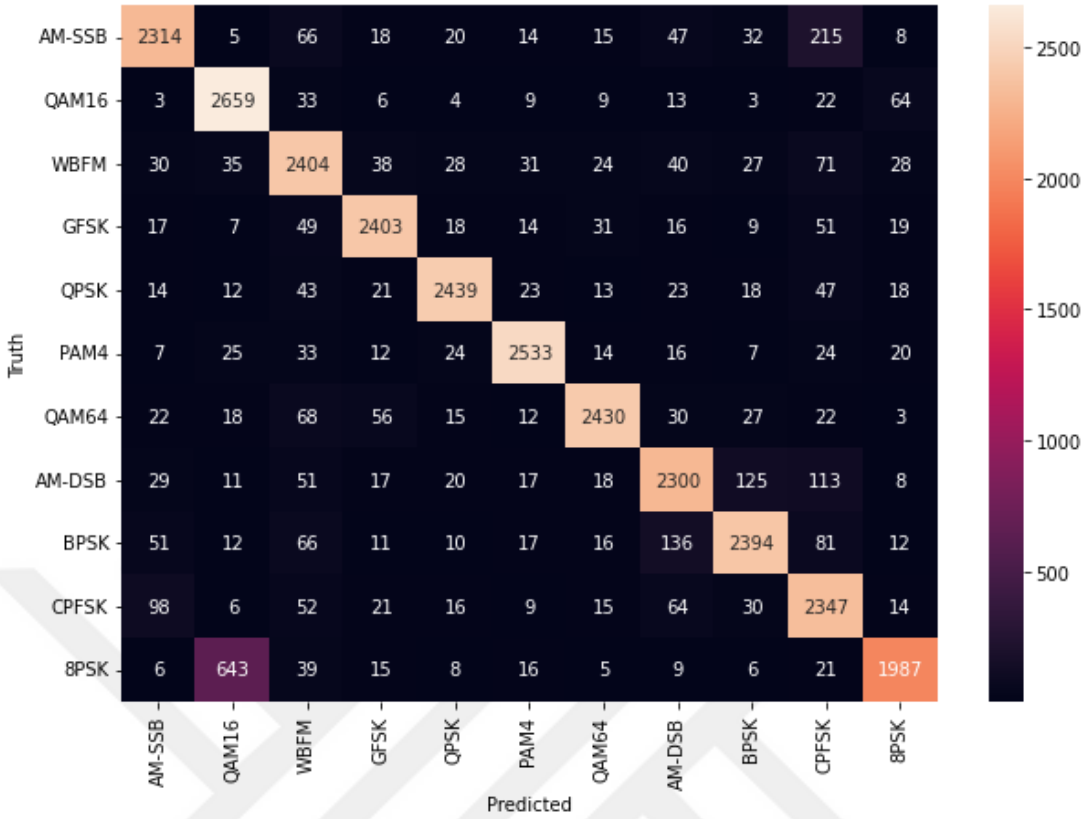
Tablo 4.1: Modele ait modülasyon sınıflandırma raporu.

Classification report:

	precision	recall	f1-score	support
AM-SSB	0.89	0.84	0.87	2754
QAM16	0.77	0.94	0.85	2825
WBFM	0.83	0.87	0.85	2756
GFSK	0.92	0.91	0.92	2634
QPSK	0.94	0.91	0.93	2671
PAM4	0.94	0.93	0.94	2715
QAM64	0.94	0.90	0.92	2703
AM-DSB	0.85	0.85	0.85	2709
BPSK	0.89	0.85	0.87	2806
CPFSK	0.78	0.88	0.83	2672
8PSK	0.91	0.72	0.81	2755
accuracy			0.87	30000
macro avg	0.88	0.87	0.87	30000
weighted avg	0.88	0.87	0.87	30000

Tablo 4.1'de modele ait sınıflandırma raporu görülmektedir. Model, sınıflandırma raporu ile doğruluk, duyarlılık (recall), kesinlik (precision) ve f1-skor (f1-score) metrikleri üzerinden değerlendirmektedir. Doğruluk, doğru olarak sınıflandırılan görüntülerin yüzdesini gösteren bir metriktir. Duyarlılık, pozitif olarak tahmin edilmesi gereken işlemlerin ne kadarının pozitif şekilde tahmin edildiğini gösteren bir metriktir. Kesinlik, pozitif olarak tahminlenen değerlerin gerçekten kaç tanesinin pozitif olduğunu gösteren bir metriktir. F1 skoru, doğruluk ve kesinliğin harmonik ortalamasını gösteren bir metriktir. Modelin sağlamlığının ve kesinliğinin ölçüsüdür.

Tablo 4.1'e bakıldığında doğru olarak sınıflandırılan modülasyonların doğruluk değeri %87 olarak görülmektedir. Model %94 f1 skoru ile en çok PAM4 modülasyonunu en az da %81 f1 skoru ile 8PSK modülasyonunu tanımaktadır.



Şekil 4.7: Modele ait modülasyon tanıma hata matrisi.

Modelin performansını değerlendirmek için hata matrisleri de kullanıldı. Hata matrisi, modelin öğrenmesinin ne kadar kaliteli olduğunu değerlendirmemizi sağlayan matristir. Her modülasyon türüne ait verilerin kaç tanesinin doğru kaç tanesinin yanlış öğrenildiğini değerlendirmemizi sağlar. Şekil 4.7'de geliştirilen modele ait modülasyon tanıma hata matrisi görülmektedir. Matrise bakıldığında 500'den 2500' e kadar belirli ölçeklerde artan renk tonları bulunmaktadır. Model en iyi PAM4 modülasyonunu tanımaktadır. Model 643 tane 8PSK modülasyonunu QAM16 modülasyonu olarak algılamaktadır. Dolayısıyla en az 8PSK modülasyonun tanımaktadır. Modelin genel olarak 8PSK dışında modülasyonları tanıma yüzdesi oldukça iyidir.

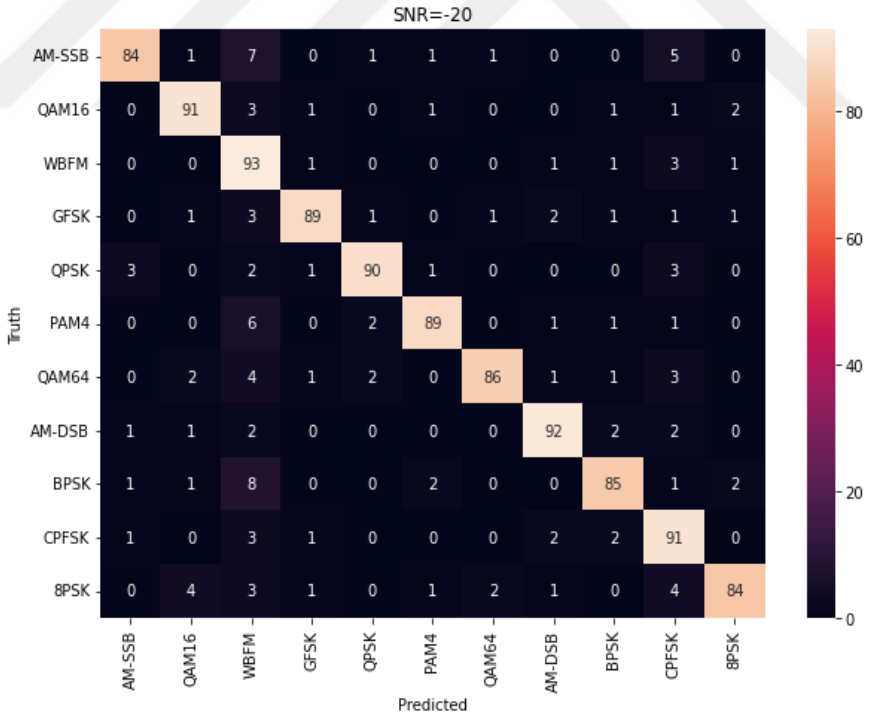
4.3. SNR DEĞERLERİNE GÖRE MODÜLASYON TANIMA SONUÇLARI

4.3.1. SNR -20 dB Değeri İçin Genel Sınıflandırma Raporu ve Hata Matrisi

Tablo 4.2: SNR -20 dB değeri için modele ait modülasyon sınıflandırma raporu.

Classification report:

	precision	recall	f1-score	support
AM-SSB	0.93	0.84	0.88	100
QAM16	0.90	0.91	0.91	100
WBFM	0.69	0.93	0.79	100
GFSK	0.94	0.89	0.91	100
QPSK	0.94	0.90	0.92	100
PAM4	0.94	0.89	0.91	100
QAM64	0.96	0.86	0.91	100
AM-DSB	0.92	0.92	0.92	100
BPSK	0.90	0.85	0.88	100
CPFSK	0.79	0.91	0.85	100
8PSK	0.93	0.84	0.88	100
accuracy			0.89	1100
macro avg	0.89	0.89	0.89	1100
weighted avg	0.89	0.89	0.89	1100



Şekil 4.8: SNR -20 dB değeri için modele ait modülasyon sınıflandırma hata matrisi.

Tablo 4.2'ye bakıldığında SNR -20 dB değeri için doğru olarak sınıflandırılan modülasyonların doğruluk değeri %89 olarak görülmektedir. Model SNR -20 dB değerinde, %92 f1 skoru ile en

çok QPSK ve AM-DSB modülasyonlarını, en az da %79 f1 skoru ile WBFM modülasyonunu tanımaktadır. Şekil 4.8'e bakıldığında modelin, en fazla karışıklığı WBFM modülasyonunu tanımaktadır. Hata matrisi, SNR -20 dB değerinde modelin en az WBFM modülasyonunu tanıdığını doğrulamaktadır.

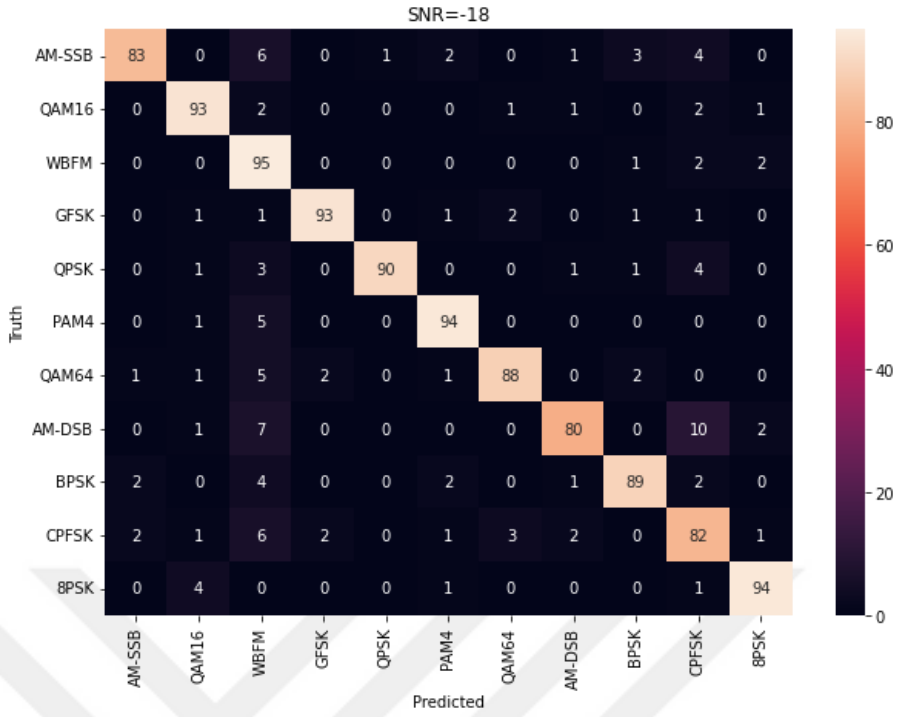
4.3.2. SNR -18 dB Değeri İçin Genel Sınıflandırma Raporu ve Hata Matrisi

Tablo 4.3: SNR -18 dB değeri için modele ait modülasyon sınıflandırma raporu.

Classification report:

	precision	recall	f1-score	support
AM-SSB	0.94	0.83	0.88	100
QAM16	0.90	0.93	0.92	100
WBFM	0.71	0.95	0.81	100
GFSK	0.96	0.93	0.94	100
QPSK	0.99	0.90	0.94	100
PAM4	0.92	0.94	0.93	100
QAM64	0.94	0.88	0.91	100
AM-DSB	0.93	0.80	0.86	100
BPSK	0.92	0.89	0.90	100
CPFSK	0.76	0.82	0.79	100
8PSK	0.94	0.94	0.94	100
accuracy			0.89	1100
macro avg	0.90	0.89	0.89	1100
weighted avg	0.90	0.89	0.89	1100

Tablo 4.3'e bakıldığında SNR -18 dB değeri için doğru olarak sınıflandırılan modülasyonların doğruluk değeri %89 olarak görülmektedir. Model SNR -18 dB değerinde, %94 f1 skoru ile en iyi QPSK, GFSK ve 8PSK modülasyonlarını, en az da %79 f1 skoru ile CPFSK modülasyonunu tanımaktadır. Şekil 4.9'a bakıldığında modelin, en fazla karışıklığı CPFSK modülasyonunu tanımada yaşadığı görülmektedir. Hata matrisi, SNR -18 dB değerinde modelin en az CPFSK modülasyonunu tanıdığını doğrulamaktadır.

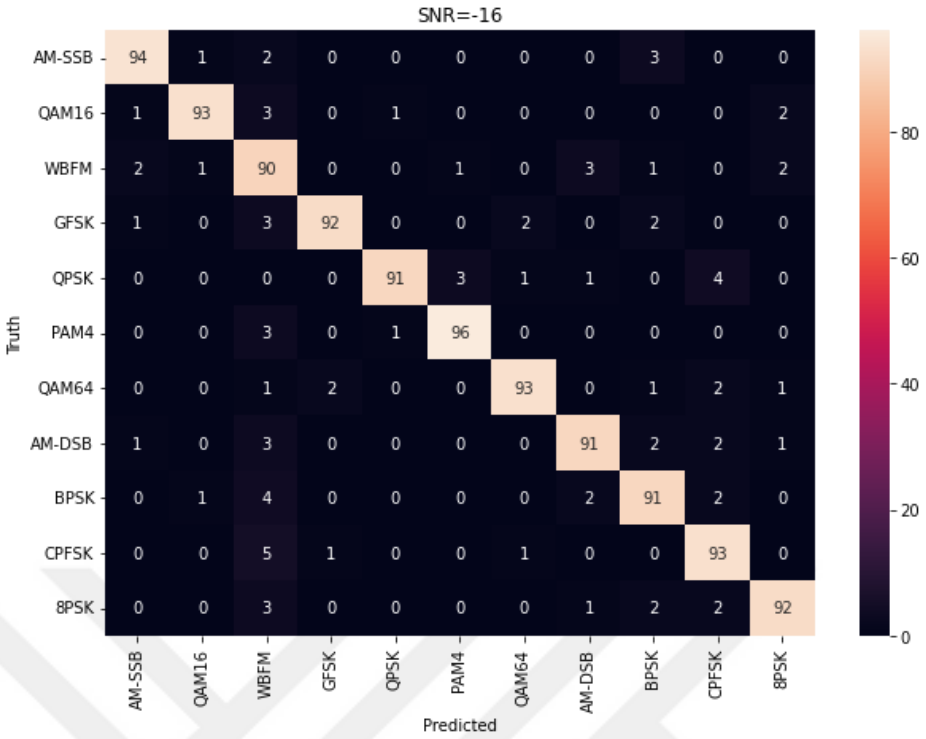


Şekil 4.9: SNR -18 dB değeri için modele ait modülasyon sınıflandırma hata matrisi.

4.3.3. SNR -16 dB Değeri İçin Genel Sınıflandırma Raporu ve Hata Matrisi

Tablo 4.4: SNR -16 dB değeri için modele ait modülasyon sınıflandırma raporu.

Classification report:	precision	recall	f1-score	support
AM-SSB	0.95	0.94	0.94	100
QAM16	0.97	0.93	0.95	100
WBFM	0.77	0.90	0.83	100
GFSK	0.97	0.92	0.94	100
QPSK	0.98	0.91	0.94	100
PAM4	0.96	0.96	0.96	100
QAM64	0.96	0.93	0.94	100
AM-DSB	0.93	0.91	0.92	100
BPSK	0.89	0.91	0.90	100
CPFSK	0.89	0.93	0.91	100
8PSK	0.94	0.92	0.93	100
accuracy			0.92	1100
macro avg	0.93	0.92	0.92	1100
weighted avg	0.93	0.92	0.92	1100



Şekil 4.10: SNR -16 dB değeri için modele ait modülasyon sınıflandırma hata matrisi.

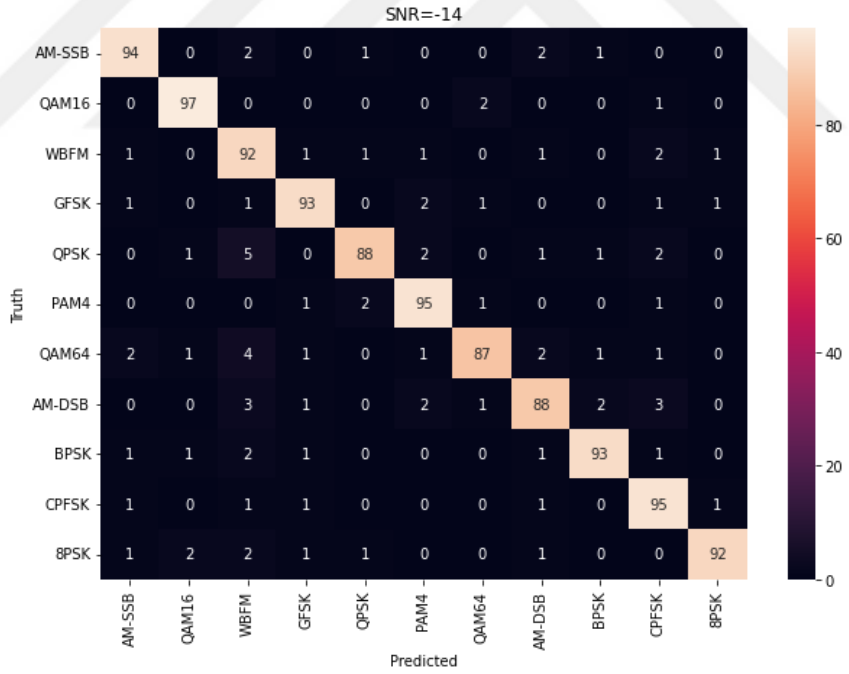
Tablo 4.4'e bakıldığında SNR -16 dB değeri için doğru olarak sınıflandırılan modülasyonların doğruluk değeri %92 olarak görülmektedir. Model SNR -16 dB değerinde, %96 f1 skoru ile en iyi PAM4 modülasyonunu, en az da %83 f1 skoru ile WBFM modülasyonunu tanımaktadır. Şekil 4.10'a bakıldığında modelin, en fazla karışıklığı WBFM modülasyonunu tanımada yaşadığı görülmektedir. Hata matrisi, SNR -16 dB değerinde modelin en az WBFM modülasyonunu tanıdığını doğrulamaktadır.

4.3.4. SNR -14 dB Değeri İçin Genel Sınıflandırma Raporu ve Hata Matrisi

Tablo 4.5: SNR -14 dB değeri için modele ait modülasyon sınıflandırma raporu.

Classification report:

	precision	recall	f1-score	support
AM-SSB	0.93	0.94	0.94	100
QAM16	0.95	0.97	0.96	100
WBFM	0.82	0.92	0.87	100
GFSK	0.93	0.93	0.93	100
QPSK	0.95	0.88	0.91	100
PAM4	0.92	0.95	0.94	100
QAM64	0.95	0.87	0.91	100
AM-DSB	0.91	0.88	0.89	100
BPSK	0.95	0.93	0.94	100
CPFSK	0.89	0.95	0.92	100
8PSK	0.97	0.92	0.94	100
accuracy			0.92	1100
macro avg	0.92	0.92	0.92	1100
weighted avg	0.92	0.92	0.92	1100



Şekil 4.11: SNR -14 dB değeri için modele ait modülasyon sınıflandırma hata matrisi.

Tablo 4.5'e bakıldığında SNR -14 dB değeri için doğru olarak sınıflandırılan modülasyonların doğruluk değeri %92 olarak görülmektedir. Model SNR -14 dB değerinde, %96 f1 skoru ile en iyi QAM16 modülasyonunu, en az da %87 f1 skoru ile WBFM modülasyonunu tanımaktadır.

Şekil 4.11'e bakıldığında modelin, en fazla karışıklığı WBFM modülasyonunu tanımada yaşadığı görülmektedir. Hata matrisi, SNR -14 dB değerinde modelin en az WBFM modülasyonunu tanıdığını doğrulamaktadır.

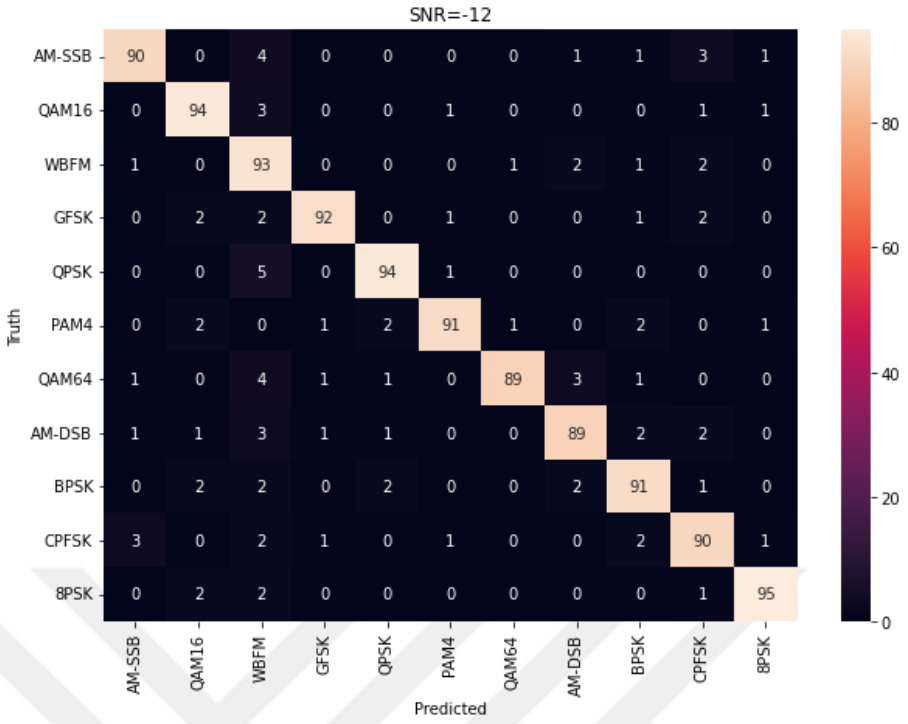
4.3.5. SNR -12 dB Değeri İçin Genel Sınıflandırma Raporu ve Hata Matrisi

Tablo 4.6: SNR -12 dB değeri için modele ait modülasyon sınıflandırma raporu.

Classification report:

	precision	recall	f1-score	support
AM-SSB	0.94	0.90	0.92	100
QAM16	0.91	0.94	0.93	100
WBFM	0.78	0.93	0.85	100
GFSK	0.96	0.92	0.94	100
QPSK	0.94	0.94	0.94	100
PAM4	0.96	0.91	0.93	100
QAM64	0.98	0.89	0.93	100
AM-DSB	0.92	0.89	0.90	100
BPSK	0.90	0.91	0.91	100
CPFSK	0.88	0.90	0.89	100
8PSK	0.96	0.95	0.95	100
accuracy			0.92	1100
macro avg	0.92	0.92	0.92	1100
weighted avg	0.92	0.92	0.92	1100

Tablo 4.6'ya bakıldığında SNR -12 dB değeri için doğru olarak sınıflandırılan modülasyonların doğruluk değeri %92 olarak görülmektedir. Model SNR -12 dB değerinde, %95 f1 skoru ile en iyi 8PSK modülasyonunu, en az da %85 f1 skoru ile WBFM modülasyonunu tanımaktadır. Şekil 4.12'ye bakıldığında modelin, en fazla karışıklığı WBFM modülasyonunu tanımada yaşadığı görülmektedir. Hata matrisi, SNR -12 dB değerinde modelin en az WBFM modülasyonunu tanıdığını doğrulamaktadır.



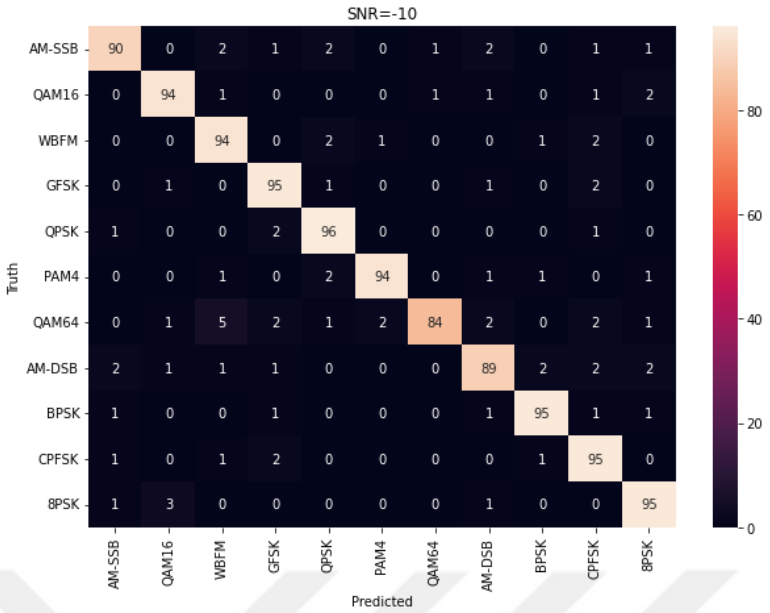
Şekil 4.12: SNR -12 dB değeri için modele ait modülasyon sınıflandırma hata matrisi.

4.3.6. SNR -10 dB Değeri İçin Genel Sınıflandırma Raporu ve Hata Matrisi

Tablo 4.7: SNR -10 dB değeri için modele ait modülasyon sınıflandırma raporu.

Classification report:

	precision	recall	f1-score	support
AM-SSB	0.94	0.90	0.92	100
QAM16	0.94	0.94	0.94	100
WBFM	0.90	0.94	0.92	100
GFSK	0.91	0.95	0.93	100
QPSK	0.92	0.96	0.94	100
PAM4	0.97	0.94	0.95	100
QAM64	0.98	0.84	0.90	100
AM-DSB	0.91	0.89	0.90	100
BPSK	0.95	0.95	0.95	100
CPFSK	0.89	0.95	0.92	100
8PSK	0.92	0.95	0.94	100
accuracy			0.93	1100
macro avg	0.93	0.93	0.93	1100
weighted avg	0.93	0.93	0.93	1100



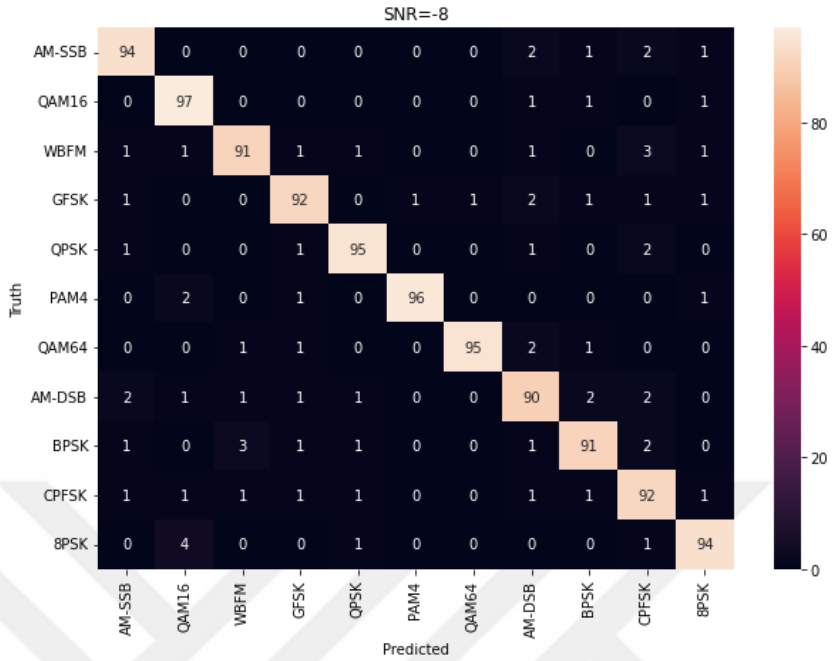
Şekil 4.13: SNR -10 dB değeri için modele ait modülasyon sınıflandırma hata matrisi.

Tablo 4.7'ye bakıldığında SNR -10 dB değeri için doğru olarak sınıflandırılan modülasyonların doğruluk değeri %93 olarak görülmektedir. Model SNR -10 dB değerinde, %95 f1 skoru ile en çok BPSK ve PAM4 modülasyonlarını, en az da %90 f1 skoru ile QAM64 ve AM-DSB modülasyonlarını tanımaktadır. Şekil 4.13'e bakıldığında modelin, en fazla karışıklığı QAM64 ve AM-DSB modülasyonlarını tanımada yaşadığı görülmektedir. Hata matrisi, SNR -10 dB değerinde modelin en az QAM64 ve AM-DSB modülasyonlarını tanıdığını doğrulamaktadır.

4.3.7. SNR -8 dB Değeri İçin Genel Sınıflandırma Raporu ve Hata Matrisi

Tablo 4.8: SNR -8 dB değeri için modele ait modülasyon sınıflandırma raporu.

Classification report:	precision	recall	f1-score	support
AM-SSB	0.93	0.94	0.94	100
QAM16	0.92	0.97	0.94	100
WBFM	0.94	0.91	0.92	100
GFSK	0.93	0.92	0.92	100
QPSK	0.95	0.95	0.95	100
PAM4	0.99	0.96	0.97	100
QAM64	0.99	0.95	0.97	100
AM-DSB	0.89	0.90	0.90	100
BPSK	0.93	0.91	0.92	100
CPFSK	0.88	0.92	0.90	100
8PSK	0.94	0.94	0.94	100
accuracy			0.93	1100
macro avg	0.93	0.93	0.93	1100
weighted avg	0.93	0.93	0.93	1100



Şekil 4.14: SNR -8 dB değeri için modele ait modülasyon sınıflandırma hata matrisi.

Tablo 4.8'e bakıldığında SNR -8 dB değeri için doğru olarak sınıflandırılan modülasyonların doğruluk değeri %93 olarak görülmektedir. Model SNR -8 dB değerinde, %97 f1 skoru ile en çok QAM64 ve PAM4 modülasyonlarını, en az da %90 f1 skoru ile CPFSK ve AM-DSB modülasyonlarını tanımaktadır. Şekil 4.14'e bakıldığında modelin, en fazla karışıklığı CPFSK ve AM-DSB modülasyonlarını tanımada yaşadığı görülmektedir. Hata matrisi, SNR -8 dB değerinde modelin en az CPFSK ve AM-DSB modülasyonlarını tanıdığını doğrulamaktadır.

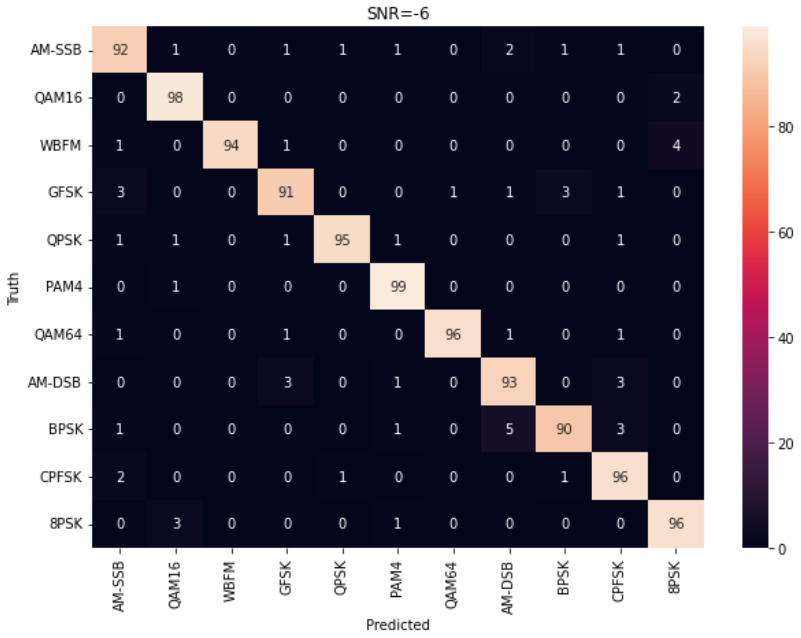
4.3.8. SNR -6 dB Değeri İçin Genel Sınıflandırma Raporu ve Hata Matrisi

Tablo 4.9: SNR -6 dB değeri için modele ait modülasyon sınıflandırma raporu.

Classification report:

	precision	recall	f1-score	support
AM-SSB	0.91	0.92	0.92	100
QAM16	0.94	0.98	0.96	100
WBFM	1.00	0.94	0.97	100
GFSK	0.93	0.91	0.92	100
QPSK	0.98	0.95	0.96	100
PAM4	0.95	0.99	0.97	100
QAM64	0.99	0.96	0.97	100
AM-DSB	0.91	0.93	0.92	100
BPSK	0.95	0.90	0.92	100
CPFSK	0.91	0.96	0.93	100
8PSK	0.94	0.96	0.95	100
accuracy			0.95	1100
macro avg	0.95	0.95	0.95	1100
weighted avg	0.95	0.95	0.95	1100

Tablo 4.9'a bakıldığında SNR -6 dB değeri için doğru olarak sınıflandırılan modülasyonların doğruluk değeri %95 olarak görülmektedir. Model SNR -6 dB değerinde, genel olarak tüm modülasyonları iyi tanımaktadır.



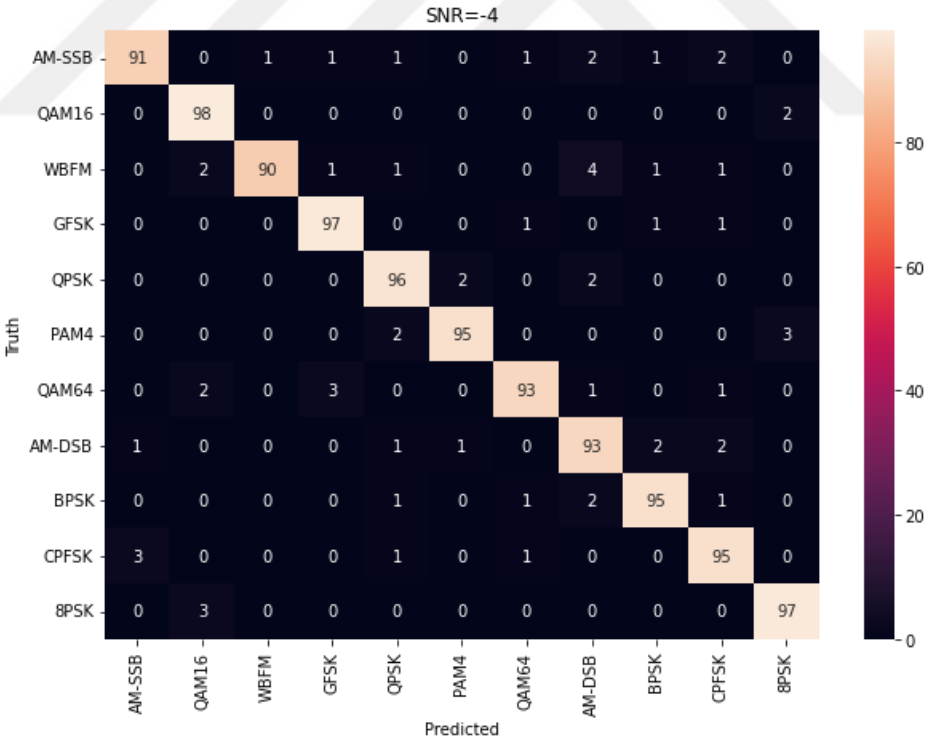
Şekil 4.15: SNR -6 dB değeri için modele ait modülasyon sınıflandırma hata matrisi.

4.3.9. SNR -4 dB Değeri İçin Genel Sınıflandırma Raporu ve Hata Matrisi

Tablo 4.10: SNR -4 dB değeri için modele ait modülasyon sınıflandırma raporu.

Classification report:

	precision	recall	f1-score	support
AM-SSB	0.96	0.91	0.93	100
QAM16	0.93	0.98	0.96	100
WBFM	0.99	0.90	0.94	100
GFSK	0.95	0.97	0.96	100
QPSK	0.93	0.96	0.95	100
PAM4	0.97	0.95	0.96	100
QAM64	0.96	0.93	0.94	100
AM-DSB	0.89	0.93	0.91	100
BPSK	0.95	0.95	0.95	100
CPFSK	0.92	0.95	0.94	100
8PSK	0.95	0.97	0.96	100
accuracy			0.95	1100
macro avg	0.95	0.95	0.95	1100
weighted avg	0.95	0.95	0.95	1100



Şekil 4.16: SNR -4 dB değeri için modele ait modülasyon sınıflandırma hata matrisi.

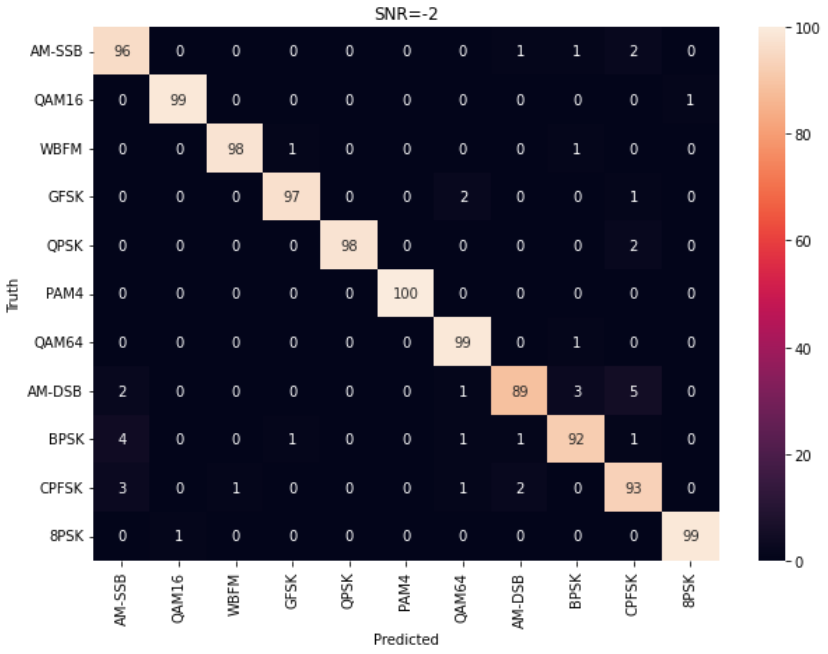
Tablo 4.10'a bakıldığında SNR -4 dB değeri için doğru olarak sınıflandırılan modülasyonların doğruluk değeri %95 olarak görülmektedir. Model SNR -4 dB değerinde, genel olarak tüm modülasyonları iyi tanımaktadır. Şekil 4.16'ya bakıldığında modelin, en fazla karışıklığı AM-DSB modülasyonunu tanımada yaşadığı görülmektedir. Hata matrisi, SNR -4 dB değerinde modelin en az AM-DSB modülasyonunu tanıdığını doğrulamaktadır.

4.3.10. SNR -2 dB Değeri İçin Genel Sınıflandırma Raporu ve Hata Matrisi

Tablo 4.11: SNR -2 dB değeri için modele ait modülasyon sınıflandırma raporu.

Classification report:

	precision	recall	f1-score	support
AM-SSB	0.91	0.96	0.94	100
QAM16	0.99	0.99	0.99	100
WBFM	0.99	0.98	0.98	100
GFSK	0.98	0.97	0.97	100
QPSK	1.00	0.98	0.99	100
PAM4	1.00	1.00	1.00	100
QAM64	0.95	0.99	0.97	100
AM-DSB	0.96	0.89	0.92	100
BPSK	0.94	0.92	0.93	100
CPFSK	0.89	0.93	0.91	100
8PSK	0.99	0.99	0.99	100
accuracy			0.96	1100
macro avg	0.96	0.96	0.96	1100
weighted avg	0.96	0.96	0.96	1100



Şekil 4.17: SNR -2 dB değeri için modele ait modülasyon sınıflandırma hata matrisi.

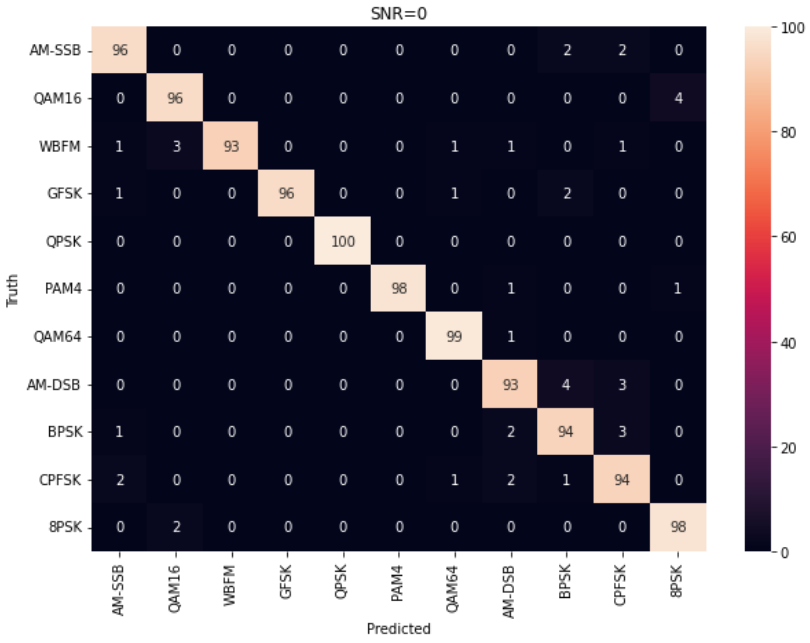
Tablo 4.11'e bakıldığında SNR -2 dB değeri için doğru olarak sınıflandırılan modülasyonların doğruluk değeri %96 olarak görülmektedir. Model SNR -2 dB değerinde, %100 f1 skoru ile en çok PAM4 modülasyonunu, en az da %91 f1 skoru ile CPFSK modülasyonunu tanımaktadır. Şekil 4.17'ye bakıldığında modelin, en fazla karışıklığı CPFSK modülasyonunu tanımada yaşadığı görülmektedir. Hata matrisi, SNR -2 dB değerinde modelin en az CPFSK modülasyonunu tanıdığını doğrulamaktadır.

4.3.11. SNR 0 dB Değeri İçin Genel Sınıflandırma Raporu ve Hata Matrisi

Tablo 4.12: SNR 0 dB değeri için modele ait modülasyon sınıflandırma raporu.

Classification report:

	precision	recall	f1-score	support
AM-SSB	0.95	0.96	0.96	100
QAM16	0.95	0.96	0.96	100
WBFM	1.00	0.93	0.96	100
GFSK	1.00	0.96	0.98	100
QPSK	1.00	1.00	1.00	100
PAM4	1.00	0.98	0.99	100
QAM64	0.97	0.99	0.98	100
AM-DSB	0.93	0.93	0.93	100
BPSK	0.91	0.94	0.93	100
CPFSK	0.91	0.94	0.93	100
8PSK	0.95	0.98	0.97	100
accuracy			0.96	1100
macro avg	0.96	0.96	0.96	1100
weighted avg	0.96	0.96	0.96	1100



Şekil 4.18: SNR 0 dB değeri için modele ait modülasyon sınıflandırma hata matrisi.

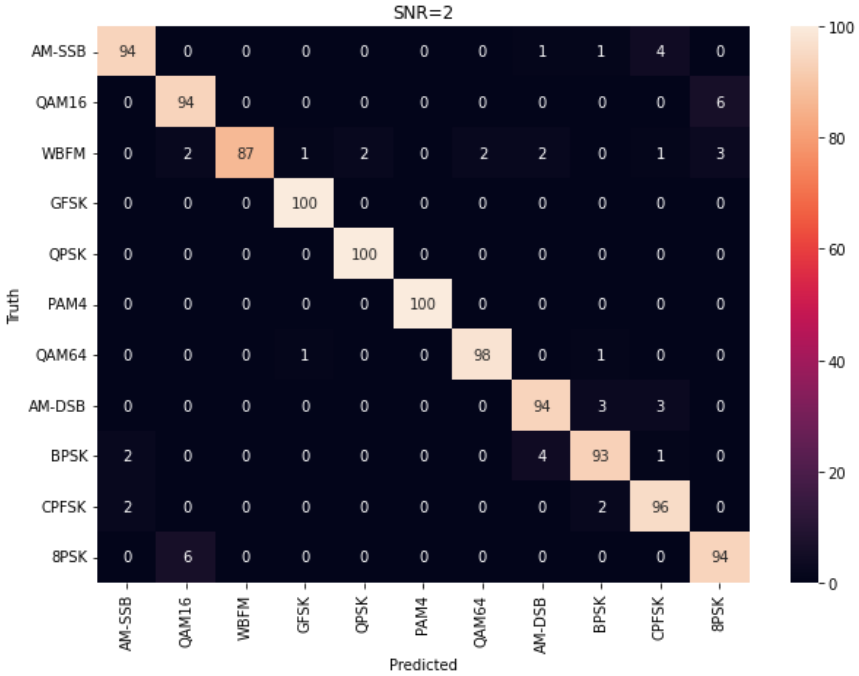
Tablo 4.12'ye bakıldığında SNR 0 dB değeri için doğru olarak sınıflandırılan modülasyonların doğruluk değeri %96 olarak görülmektedir. Model SNR 0 dB değerinde, %100 f1 skoru ile en iyi QPSK modülasyonunu tanımaktadır.

4.3.12. SNR 2 dB Değeri İçin Genel Sınıflandırma Raporu ve Hata Matrisi

Tablo 4.13: SNR 2 dB değeri için modele ait modülasyon sınıflandırma raporu.

Classification report:

	precision	recall	f1-score	support
AM-SSB	0.96	0.94	0.95	100
QAM16	0.92	0.94	0.93	100
WBFM	1.00	0.87	0.93	100
GFSK	0.98	1.00	0.99	100
QPSK	0.98	1.00	0.99	100
PAM4	1.00	1.00	1.00	100
QAM64	0.98	0.98	0.98	100
AM-DSB	0.93	0.94	0.94	100
BPSK	0.93	0.93	0.93	100
CPFSK	0.91	0.96	0.94	100
8PSK	0.91	0.94	0.93	100
accuracy			0.95	1100
macro avg	0.96	0.95	0.95	1100
weighted avg	0.96	0.95	0.95	1100



Şekil 4.19: SNR 2 dB değeri için modele ait modülasyon sınıflandırma hata matrisi.

Tablo 4.13'e bakıldığında SNR 2 dB değeri için doğru olarak sınıflandırılan modülasyonların doğruluk değeri %95 olarak görülmektedir. Model SNR 2 dB değerinde, %100 f1 skoru ile en iyi PAM4 modülasyonunu tanımaktadır.

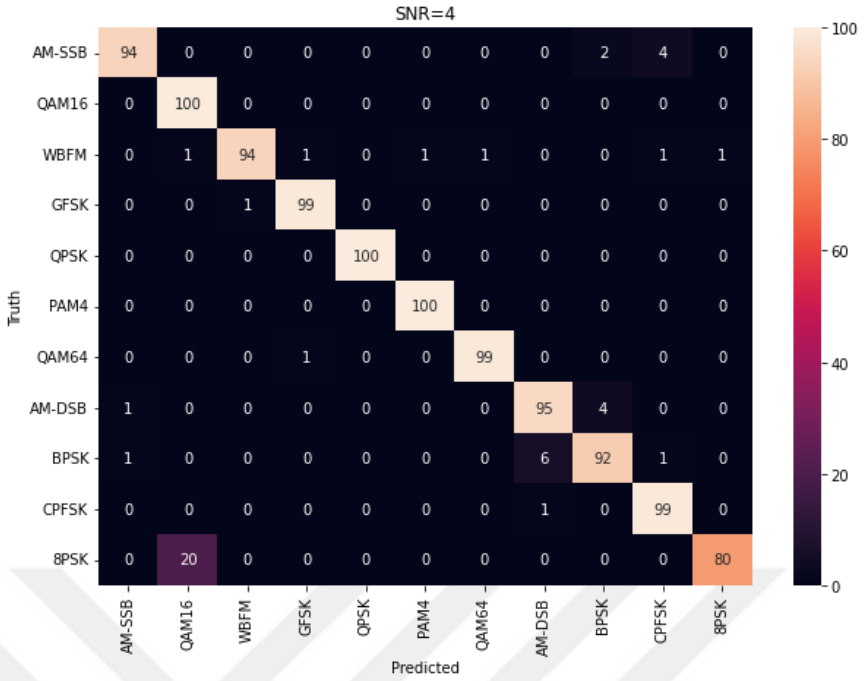
4.3.13. SNR 4 dB Değeri İçin Genel Sınıflandırma Raporu ve Hata Matrisi

Tablo 4.14: SNR 4 dB değeri için modele ait modülasyon sınıflandırma raporu.

Classification report:

	precision	recall	f1-score	support
AM-SSB	0.98	0.94	0.96	100
QAM16	0.83	1.00	0.90	100
WBFM	0.99	0.94	0.96	100
GFSK	0.98	0.99	0.99	100
QPSK	1.00	1.00	1.00	100
PAM4	0.99	1.00	1.00	100
QAM64	0.99	0.99	0.99	100
AM-DSB	0.93	0.95	0.94	100
BPSK	0.94	0.92	0.93	100
CPFSK	0.94	0.99	0.97	100
8PSK	0.99	0.80	0.88	100
accuracy			0.96	1100
macro avg	0.96	0.96	0.96	1100
weighted avg	0.96	0.96	0.96	1100

Tablo 4.14'e bakıldığında SNR 4 dB değeri için doğru olarak sınıflandırılan modülasyonların doğruluk değeri %96 olarak görülmektedir. Model SNR 4 dB değerinde, %100 f1 skoru ile en çok QPSK ve PAM4 modülasyonlarını, en az da %88 f1 skoru ile 8PSK modülasyonunu tanımaktadır. Şekil 4.20'ye bakıldığında modelin, en fazla karışıklığı 8PSK modülasyonunu tanımada yaşadığı görülmektedir. Hata matrisi, SNR 4 dB değerinde modelin en az 8PSK modülasyonunu tanıdığını doğrulamaktadır.



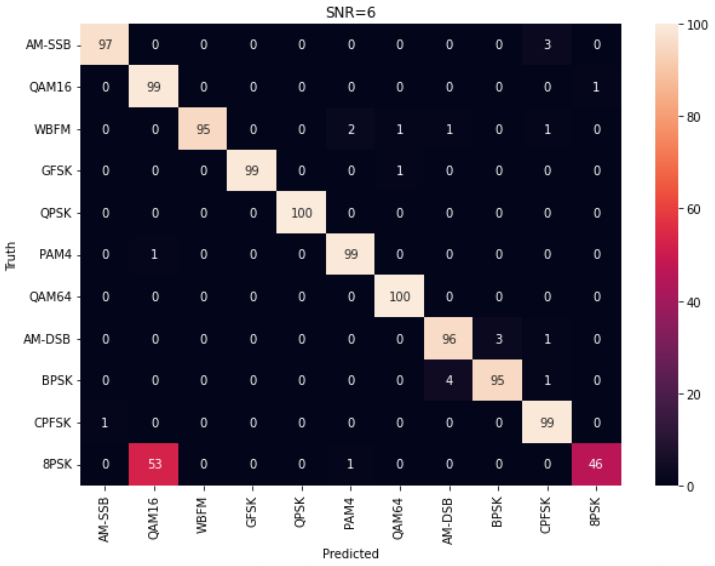
Şekil 4.20: SNR 4 dB değeri için modele ait modülasyon sınıflandırma hata matrisi.

4.3.14. SNR 6 dB Değeri İçin Genel Sınıflandırma Raporu ve Hata Matrisi

Tablo 4.15: SNR 6 dB değeri için modele ait modülasyon sınıflandırma raporu.

Classification report:

	precision	recall	f1-score	support
AM-SSB	0.99	0.97	0.98	100
QAM16	0.65	0.99	0.78	100
WBFM	1.00	0.95	0.97	100
GFSK	1.00	0.99	0.99	100
QPSK	1.00	1.00	1.00	100
PAM4	0.97	0.99	0.98	100
QAM64	0.98	1.00	0.99	100
AM-DSB	0.95	0.96	0.96	100
BPSK	0.97	0.95	0.96	100
CPFSK	0.94	0.99	0.97	100
8PSK	0.98	0.46	0.63	100
accuracy			0.93	1100
macro avg	0.95	0.93	0.93	1100
weighted avg	0.95	0.93	0.93	1100



Şekil 4.21: SNR 6 dB değeri için modele ait modülasyon sınıflandırma hata matrisi.

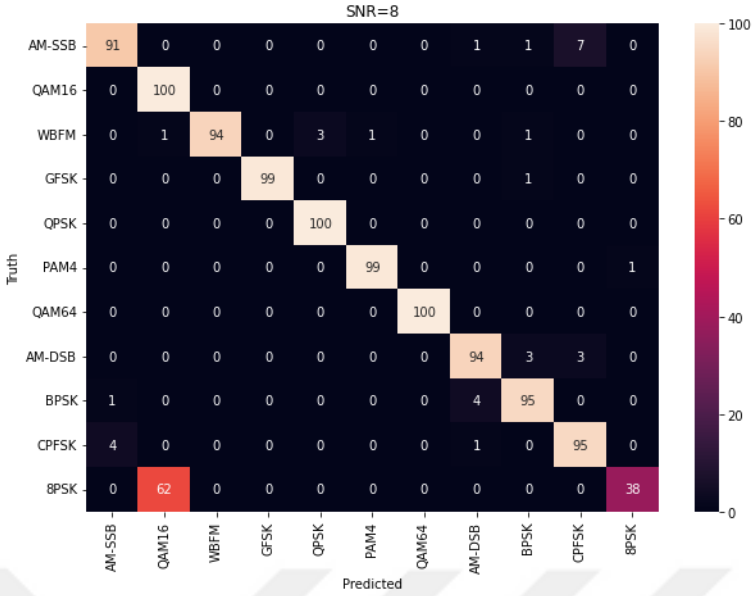
Tablo 4.15'e bakıldığında SNR 6 dB değeri için doğru olarak sınıflandırılan modülasyonların doğruluk değeri %93 olarak görülmektedir. Model SNR 6 dB değerinde, %100 f1 skoru ile en çok QPSK modülasyonunu, en az da %63 f1 skoru ile 8PSK modülasyonunu tanımaktadır. Şekil 4.21'e bakıldığında modelin, en fazla karışıklığı 8PSK modülasyonunu tanımada yaşadığı görülmektedir. Hata matrisi, SNR 6 dB değerinde modelin en az 8PSK modülasyonunu tanıdığını doğrulamaktadır.

4.3.15. SNR 8 dB Değeri İçin Genel Sınıflandırma Raporu ve Hata Matrisi

Tablo 4.16: SNR 8 dB değeri için modele ait modülasyon sınıflandırma raporu.

Classification report:

	precision	recall	f1-score	support
AM-SSB	0.95	0.91	0.93	100
QAM16	0.61	1.00	0.76	100
WBFM	1.00	0.94	0.97	100
GFSK	1.00	0.99	0.99	100
QPSK	0.97	1.00	0.99	100
PAM4	0.99	0.99	0.99	100
QAM64	1.00	1.00	1.00	100
AM-DSB	0.94	0.94	0.94	100
BPSK	0.94	0.95	0.95	100
CPFSK	0.90	0.95	0.93	100
8PSK	0.97	0.38	0.55	100
accuracy			0.91	1100
macro avg	0.93	0.91	0.91	1100
weighted avg	0.93	0.91	0.91	1100



Şekil 4.22: SNR 8 dB değeri için modele ait modülasyon sınıflandırma hata matrisi.

Tablo 4.16'ya bakıldığında SNR 8 dB değeri için doğru olarak sınıflandırılan modülasyonların doğruluk değeri %91 olarak görülmektedir. Model SNR 8 dB değerinde, %100 f1 skoru ile en çok QAM64 modülasyonunu, en az da %55 f1 skoru ile 8PSK modülasyonunu tanımaktadır. Şekil 4.22'ye bakıldığında modelin, en fazla karışıklığı 8PSK modülasyonunu tanımada yaşadığı görülmektedir. Hata matrisi, SNR 8 dB değerinde modelin en az 8PSK modülasyonunu tanıdığını doğrulamaktadır.

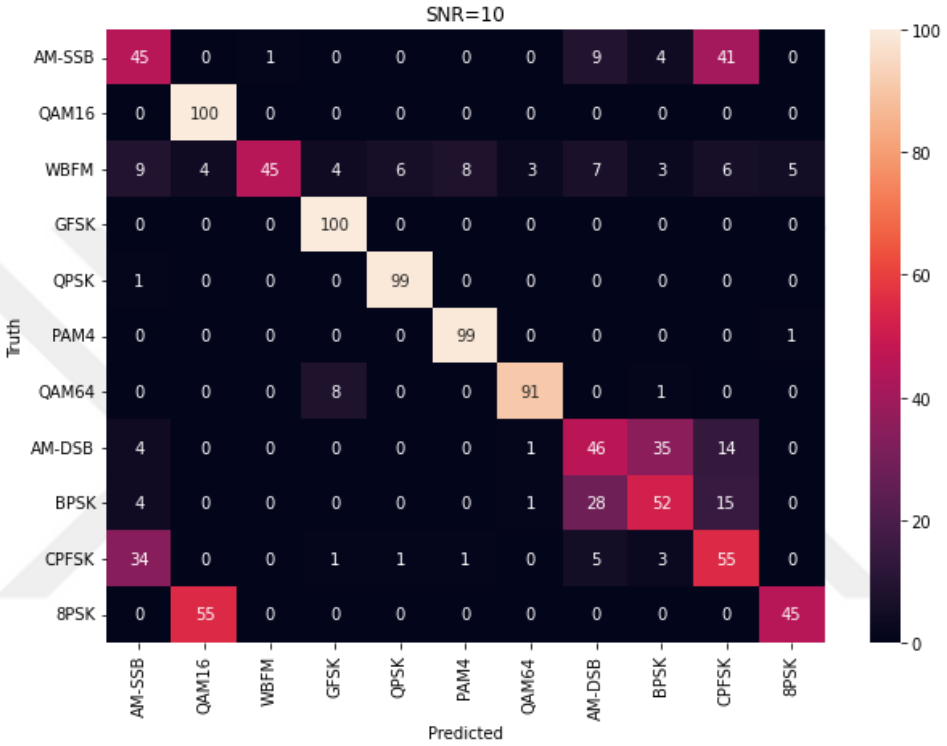
4.3.16. SNR 10 dB Değeri İçin Genel Sınıflandırma Raporu ve Hata Matrisi

Tablo 4.17: SNR 10 dB değeri için modele ait modülasyon sınıflandırma raporu.

Classification report:

	precision	recall	f1-score	support
AM-SSB	0.46	0.45	0.46	100
QAM16	0.63	1.00	0.77	100
WBFM	0.98	0.45	0.62	100
GFSK	0.88	1.00	0.94	100
QPSK	0.93	0.99	0.96	100
PAM4	0.92	0.99	0.95	100
QAM64	0.95	0.91	0.93	100
AM-DSB	0.48	0.46	0.47	100
BPSK	0.53	0.52	0.53	100
CPFSK	0.42	0.55	0.48	100
8PSK	0.88	0.45	0.60	100
accuracy			0.71	1100
macro avg	0.73	0.71	0.70	1100
weighted avg	0.73	0.71	0.70	1100

Tablo 4.17'ye bakıldığında SNR 10 dB değeri için doğru olarak sınıflandırılan modülasyonların doğruluk değeri %71 olarak görülmektedir. Model SNR 10 dB değerinde, %96 f1 skoru ile en iyi QPSK modülasyonunu tanımaktadır. Şekil 4.23'e bakıldığında hata matrisi, SNR 10 dB değerinde modelin birçok modülasyonu tanımakta zorlandığı görülmektedir.



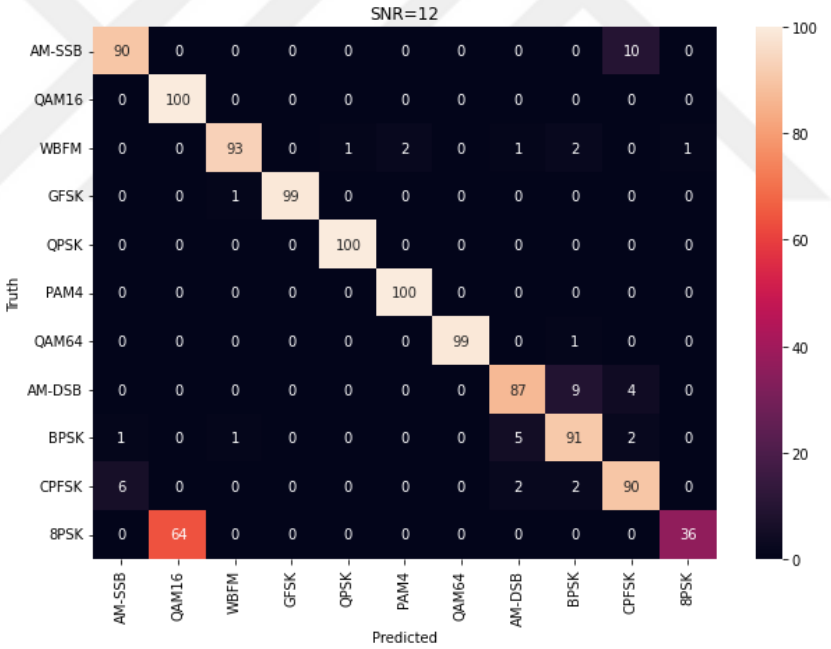
Şekil 4.23: SNR 10 dB değeri için modele ait modülasyon sınıflandırma hata matrisi.

4.3.17. SNR 12 dB Değeri İçin Genel Sınıflandırma Raporu ve Hata Matrisi

Tablo 4.18: SNR 12 dB değeri için modele ait modülasyon sınıflandırma raporu.

Classification report:

	precision	recall	f1-score	support
AM-SSB	0.93	0.90	0.91	100
QAM16	0.61	1.00	0.76	100
WBFM	0.98	0.93	0.95	100
GFSK	1.00	0.99	0.99	100
QPSK	0.99	1.00	1.00	100
PAM4	0.98	1.00	0.99	100
QAM64	1.00	0.99	0.99	100
AM-DSB	0.92	0.87	0.89	100
BPSK	0.87	0.91	0.89	100
CPFSK	0.85	0.90	0.87	100
8PSK	0.97	0.36	0.53	100
accuracy			0.90	1100
macro avg	0.92	0.90	0.89	1100
weighted avg	0.92	0.90	0.89	1100



Şekil 4.24: SNR 12 dB değeri için modele ait modülasyon sınıflandırma hata matrisi.

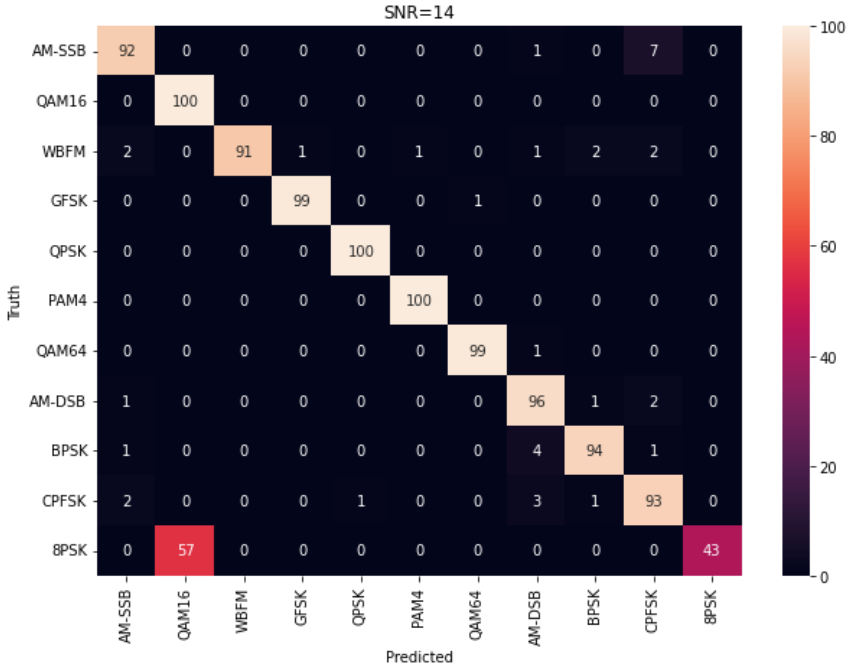
Tablo 4.18'e bakıldığında SNR 12 dB değeri için doğru olarak sınıflandırılan modülasyonların doğruluk değeri %90 olarak görülmektedir. Model SNR 12 dB değerinde, %100 f1 skoru ile en çok QPSK modülasyonunu, en az da %53 f1 skoru ile 8PSK modülasyonunu tanımaktadır. Şekil 4.24'e bakıldığında modelin, en fazla karışıklığı 8PSK modülasyonunu tanımada yaşadığı

görülmektedir. Hata matrisi, SNR 12 dB değerinde modelin en az 8PSK modülasyonunu tanıdığını doğrulamaktadır.

4.3.18. SNR 14 dB Değeri İçin Genel Sınıflandırma Raporu ve Hata Matrisi

Tablo 4.19: SNR 14 dB değeri için modele ait modülasyon sınıflandırma raporu.

Classification report:	precision	recall	f1-score	support
AM-SSB	0.94	0.92	0.93	100
QAM16	0.64	1.00	0.78	100
WBFM	1.00	0.91	0.95	100
GFSK	0.99	0.99	0.99	100
QPSK	0.99	1.00	1.00	100
PAM4	0.99	1.00	1.00	100
QAM64	0.99	0.99	0.99	100
AM-DSB	0.91	0.96	0.93	100
BPSK	0.96	0.94	0.95	100
CPFSK	0.89	0.93	0.91	100
8PSK	1.00	0.43	0.60	100
accuracy			0.92	1100
macro avg	0.94	0.92	0.91	1100
weighted avg	0.94	0.92	0.91	1100



Şekil 4.25: SNR 14 dB değeri için modele ait modülasyon sınıflandırma hata matrisi.

Tablo 4.19'a bakıldığında SNR 14 dB değeri için doğru olarak sınıflandırılan modülasyonların doğruluk değeri %92 olarak görülmektedir. Model SNR 14 dB değerinde, %100 f1 skoru ile en çok QPSK ve PAM4 modülasyonlarını, en az da %60 f1 skoru ile 8PSK modülasyonunu tanımaktadır. Şekil 4.25'e bakıldığında modelin, en fazla karışıklığı 8PSK modülasyonunu tanımada yaşadığı görülmektedir. Hata matrisi, SNR 14 dB değerinde modelin en az 8PSK modülasyonunu tanıdığını doğrulamaktadır.

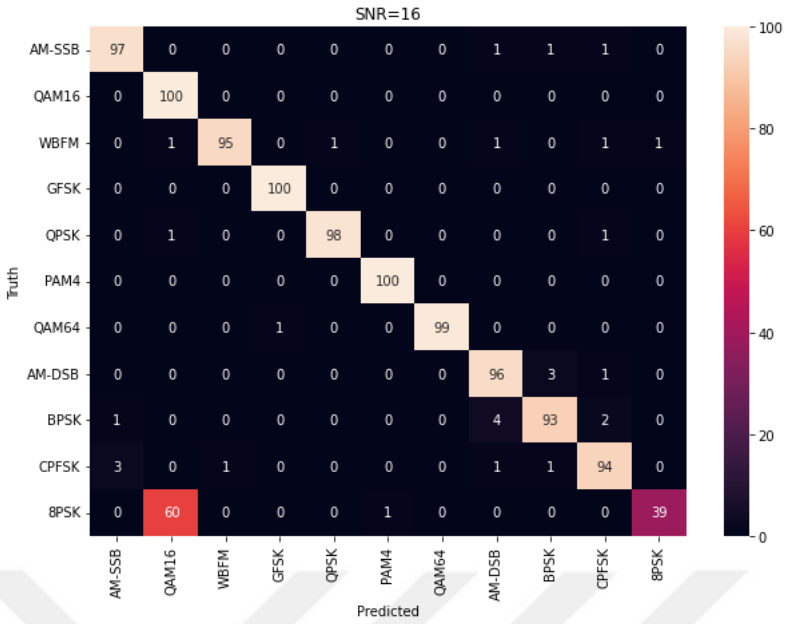
4.3.19. SNR 16 dB Değeri İçin Genel Sınıflandırma Raporu ve Hata Matrisi

Tablo 4.20: SNR 16 dB değeri için modele ait modülasyon sınıflandırma raporu.

Classification report:

	precision	recall	f1-score	support
AM-SSB	0.96	0.97	0.97	100
QAM16	0.62	1.00	0.76	100
WBFM	0.99	0.95	0.97	100
GFSK	0.99	1.00	1.00	100
QPSK	0.99	0.98	0.98	100
PAM4	0.99	1.00	1.00	100
QAM64	1.00	0.99	0.99	100
AM-DSB	0.93	0.96	0.95	100
BPSK	0.95	0.93	0.94	100
CPFSK	0.94	0.94	0.94	100
8PSK	0.97	0.39	0.56	100
accuracy			0.92	1100
macro avg	0.94	0.92	0.91	1100
weighted avg	0.94	0.92	0.91	1100

Tablo 4.20'ye bakıldığında SNR 16 dB değeri için doğru olarak sınıflandırılan modülasyonların doğruluk değeri %92 olarak görülmektedir. Model SNR 16 dB değerinde, %100 f1 skoru ile en iyi GFSK ve PAM4 modülasyonlarını, en az da %56 f1 skoru ile 8PSK modülasyonunu tanımaktadır. Şekil 4.26'ya bakıldığında modelin, en fazla karışıklığı 8PSK modülasyonunu tanımada yaşadığı görülmektedir. Hata matrisi, SNR 16 dB değerinde modelin en az 8PSK modülasyonunu tanıdığını doğrulamaktadır.



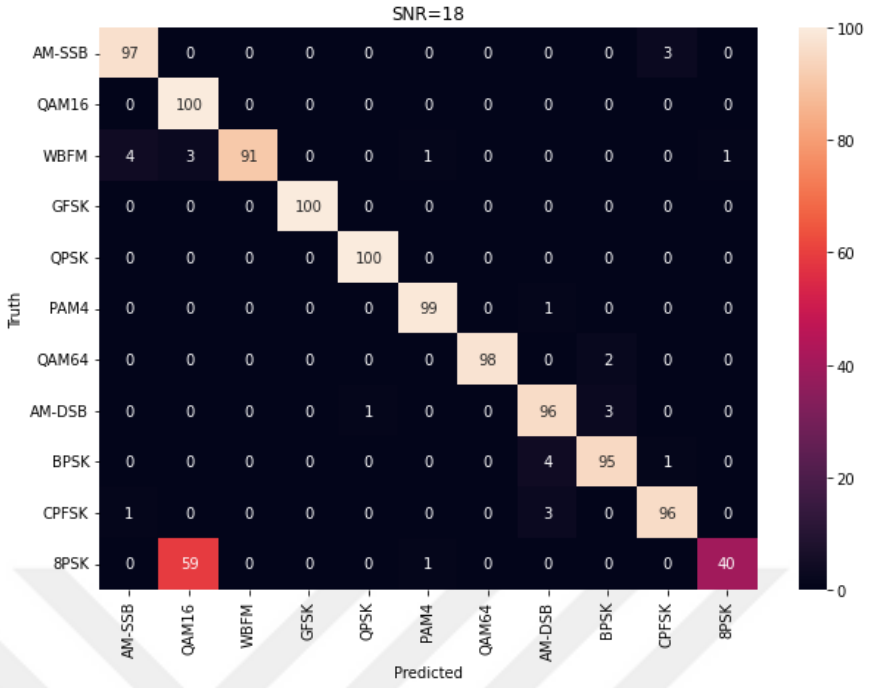
Şekil 4.26: SNR 16 dB değeri için modele ait modülasyon sınıflandırma hata matrisi.

4.3.20. SNR 18 dB Değeri İçin Modele Ait Genel Sınıflandırma Raporu ve Hata Matrisi

Tablo 4.21: SNR 18 dB değeri için modele ait modülasyon sınıflandırma raporu.

Classification report:

	precision	recall	f1-score	support
AM-SSB	0.95	0.97	0.96	100
QAM16	0.62	1.00	0.76	100
WBFM	1.00	0.91	0.95	100
GFSK	1.00	1.00	1.00	100
QPSK	0.99	1.00	1.00	100
PAM4	0.98	0.99	0.99	100
QAM64	1.00	0.98	0.99	100
AM-DSB	0.92	0.96	0.94	100
BPSK	0.95	0.95	0.95	100
CPFSK	0.96	0.96	0.96	100
8PSK	0.98	0.40	0.57	100
accuracy			0.92	1100
macro avg	0.94	0.92	0.92	1100
weighted avg	0.94	0.92	0.92	1100



Şekil 4.27: SNR 18 dB değeri için modele ait modülasyon sınıflandırma hata matrisi.

Tablo 4.21'e bakıldığında SNR 18 dB değeri için doğru olarak sınıflandırılan modülasyonların doğruluk değeri %92 olarak görülmektedir. Model SNR 18 dB değerinde, %100 f1 skoru ile en çok QPSK ve GFSK modülasyonlarını, en az da %57 f1 skoru ile 8PSK modülasyonunu tanımaktadır. Şekil 4.27'ye bakıldığında modelin, en fazla karışıklığı 8PSK modülasyonunu tanımada yaşadığı görülmektedir. Hata matrisi, SNR 18 dB değerinde modelin en az 8PSK modülasyonunu tanıdığını doğrulamaktadır.

5. TARTIŞMA VE SONUÇ

Bu tez çalışmasında, derin öğrenme algoritmaları ve RadioML 2016.10A veri seti kullanılarak otomatik modülasyon sınıflandırma probleminin çözümüne yönelik bir CNN modeli geliştirilmiştir. RadioML 2016.10A veri seti içerisindeki modülasyon sinyallerinin FSST yöntemi ile zaman-frekans görüntüleri alınarak özellikleri çıkartılmıştır. FSST görüntülerinden oluşan yeni veri seti, geliştirilen CNN modeline uygun bir girdi haline getirilmiştir. Geliştirilen CNN modelinin eğitim sınıfı için ayrılan veri seti üzerinden farklı epoch değerlerinde eğitilmesiyle en iyi performansı sağladığı parametreler tespit edilmiştir.

Otomatik modülasyon tanıma için geliştirilen CNN modeli, modülasyon türlerine göre hem genel olarak hem de 20 farklı SNR değeri için ayrı ayrı sınıflandırılmış ve performansı değerlendirilmiştir. Genel sınıflandırmaya göre CNN modeli %87 doğruluk oranında modülasyonları tanıyarak yüksek bir performans göstermiştir. Modelin %94 f1 skoru ile en çok PAM4 modülasyonlarını en az da %81 f1 skoru ile 8PSK modülasyonlarını tanıdığı belirlenmiştir.

CNN modelinin SNR bazlı sınıflandırılmasındaki sonuçları da ayrı ayrı incelenmiş ve hangi modülasyon türü için hangi SNR değerinde nasıl sonuç verdiği ayrıntılı olarak incelenmiştir. SNR bazlı incelemelerde genel olarak 8PSK modülasyonu düşük SNR değerlerinde iyi bir şekilde sınıflandırılırken yüksek SNR değerlerinde model 8PSK modülasyonunu tanımakta zorlanmaktadır. SNR 10 dB değerinde genel olarak birçok modülasyonun tanınması zorlaşmaktadır. Diğer tüm SNR değerlerinde ise modelin modülasyon tanıma performansının oldukça iyi olduğu gözlemlenmiştir.

Bu tez çalışmasında elde edilen sonuçlar doğrultusunda, derin öğrenme algoritmaları kullanılarak otomatik modülasyon tanıma işleminin başarılı sonuçlar verdiği görülmüştür. Ayrıca zaman-frekans analizi yöntemleri ile ham veri seti içerisindeki modülasyon sinyallerine ait daha keskin ve konsantre görüntüler elde edilerek özelliklerin çok iyi bir şekilde çıkartılabildiği de görülmüştür. Önerilen CNN modeli otomatik modülasyon tanıma alanında kullanılarak daha farklı yöntemlerin geliştirilmesi için yol gösterici olabilir.

KAYNAKLAR

[1]. Şengür, A., 2011, Sayısal modülasyonlu haberleşme işaretlerinden Wigner-Ville zaman-frekans dağılımlarına dayalı öznitelik çıkarımı, *İTÜ Dergisi/D Mühendislik*, 10 (1), 3-10.

[2]. Ali, A., 2013, *Bilişsel İletişim Sistemleri İçin Otomatik Modülasyon Tanıma,* Yüksek Lisans, İstanbul Üniversitesi Fen Bilimleri Enstitüsü.

[3]. Yıldırım, M., Sokullu, R. and Pehlivan, S., 2020, Deep Learning for Communication Systems, *European Journal of Science and Technology*, (18), 1012-1025.

[4]. Helhel, S., 2019, *Analog Haberleşme:Haberleşme Kuramı 1,* Birsen, İstanbul, ISBN: 9789755116525.

[5]. Azzouz, E.E. and Nandi A.K., 1996, *Automatic Modulation Recognition of Communications Signals*, Kluwer Academic, ISBN: 978-1-4419-5166-3.

[6]. Çukur, H. and Serbes, A., 2019, Bilişsel Radyo Uygulamaları için Otomatik Modülasyon Sınıflandırma Algoritmaları Araştırması, *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 25 (4), 1-15.

[7]. Dobre, O.A., Abdi, A., Bar-Ness, Y. and Su, W., 2007, A Survey of Automatic Modulation Classification Techniques: Classical Approaches and New Trends, *IET Communication.*, 1 (2), 137-156.

[8]. Panagiotou, P., Anastasopoulos, A. and Polydoros, A., 2000, Likelihood ratio tests for modulation classification, *in Proc. IEEE MILCOM*, 670-674.

[9]. Hameed, F., Dobre, O.A. and Popescu, D.C., 2009, On the likelihood-based approach to modulation classification, *IEEE Transactions on Wireless Communications*, 8 (12), 5884-5892.

[10]. Huang, C.Y. and Polydoros, A., 1995, Likelihood methods for MPSK modulation classification, *IEEE Transactions on Communications*, 43 (2/3/4), 1493-1504.

[11]. Wei, W. and Mendel, J.M., 2000, Maximum-likelihood classification for digital amplitude-phase modulations, *IEEE transactions on Communications*, 48 (2), 189-193.

[12]. Sills, J.A., 1999, Maximum-likelihood modulation classification for PSK/QAM, *in Proc. IEEE MILCOM*, 57-61.

[13]. Xu, J.L., Su, W. and Zhou, M., 2011, Likelihood-Ratio Approaches to Automatic Modulation Classification, *IEEE Transactions on Systems, Man, and Cybernetics-Part C (Applications and Reviews)*, 41 (4), 455-469.

[14]. Beidas, B.F. and Weber, C.L., 1995, Higher-order correlation-based approach to modulation classification of digitally frequency-modulated signals, *IEEE Journal on Selected Areas in Communications.*, vol. 13 (1), 89-101.

[15]. Lopatka, J. and Pedzisz, M., 2000, Automatic modulation classification using statistical moments and a fuzzy classifier, *ICSP2000 Proceedings*, 21-25 August 2000 Beijing, ISBN: 0-7803-5747-7, 1500-1506.

[16]. Swami. A. and Sadler. B.M., 2000, Hierarchical digital modulation classification using cumulants, *IEEE Transactions on communications*, 48 (3), 416-429.

[17]. Wong, M.L.D. and Nandi, A.K., 2004, Automatic digital modulation recognition using artificial neural network and genetic algorithm, *Signal Processing*, 84 (2), 351-365.

[18]. Wu, H.C., Saquib, M. and Yun. Z., 2008, Novel automatic modulation classification using cumulant features for communications via multipath channels, *IEEE Transactions on Wireless Communications*, 7 (8), 3098-3105.

[19]. Shermeh, A.E. and Ghazalian, R., 2010, Recognition of communication signal types using genetic algorithm and support vector machines based on the higher order statistics, *Digital Signal Processing*, 20 (6), 1748-1757.

[20]. Aslam, M.W., Zhu, Z. and Nandi, A.K., 2012, Automatic Modulation Classification Using Combination of Genetic Programming and KNN, *IEEE Transactions on wireless communications*, 11 (8), 2742-2750.

[21]. Ho, K.C., Prokopiw, W. and Chan, Y., 2000, Modulation identification of digital signals by the wavelet transform, *IEE Proceedings-Radar Sonar and Navigation*, 147 (4), 169-176.

[22]. Hassan, K., Dayoub, I., Hamouda, W. and Berbineau, M., 2010, Automatic Modulation Recognition Using Wavelet Transform and Neural Networks in Wireless Systems, *EURASIP Journal on Advances in Signal Processing*, 532898 (2010), 1-13.

[23]. Dobre, O.A., Bar-Ness, Y. and Su, W., 2003, Higher-order cyclic cumulants for high order modulation classification". *IEEE Military Communications Conference*, 13-16 October 2003 Boston, ISBN: 0-7803-8140-8, 112-117.

[24]. Dobre, O.A., Bar-Ness, Y. and Su, W., 2004, Robust QAM modulation classification algorithm using cyclic cumulants, *IEEE Wireless Communications and Networking Conference*, 21-25 March 2004 Atlanta, ISBN: 0-7803-8344-3, 745-748.

[25]. Fehske, A., Gaeddert, J. and Reed, J.H., 2005, A new approach to signal classification using spectral correlation and neural networks, *First IEEE International Symposium on New Frontiers in Dynamic Spectrum Access Networks*, 8-11 November 2005 Baltimore, ISBN:1-4244-0013-9, 144-150.

[26]. Ramkumar, B., 2009, Automatic modulation classification for cognitive radios using cyclic feature detection, *IEEE Circuits and Systems Magazine*, 9 (2), 27-45.

[27]. Dobre, O.A., Abdi, A, Bar-Ness, Y. and Su, W., 2010, Cyclostationarity-based modulation classification of linear digital modulations in flat fading channels, *Wireless Personal Communications*, 54 (4), 699-717.

[28]. Dobre, O.A. and Inkol, R., 2012, Blind signal identification: Achievements, trends, and challenges, *9th International Conference on Communications*, 21-23 June 2012 Bucharest, ISBN:978-1-4577-0058-3, 349-352.

[29]. Satija, U., Ramkumar, B. and Manikandan, M.S., 2017, A novel sparse classifier for automatic modulation classification using cyclostationary features, *Wireless Personal Communications*, 96 (3), 4895-4917.

[30]. Mobasseri, B.G., 2000, Digital modulation classification using constellation shape, *Signal processing*, 80 (2), 251-277.

[31]. Ahmadi, N. and Berangi, R., 2008, Modulation classification of QAM and PSK from their constellation using Genetic Algorithm and hierarchical clustering, *3rd International Conference on Information and Communication Technologies: From Theory to Applications*, 7-11 April 2008 Damascus, ISBN:978-1-4244-1751-3, 1-5.

[32]. Hsue, S.Z. and Soliman, S.S., 1990, Automatic modulation classification using zero crossing, *IEE Proceedings F (Radar and Signal Processing)*, 137 (6), 459-464.

[33]. Satija, U., Mohanty, M. and Ramkumar, B., 2015, Automatic modulation classification using S-transform based features, *2nd International Conference on Signal Processing and Integrated Networks*, 19-20 February 2015 Noida, ISBN:978-1-4799-5991-4, 708-712.

[34]. Chollet, F., 2019, *Python ile Derin Öğrenme*, Buzdağı Yayınevi, Ankara, ISBN: 978-605-69024-2-0.

[35]. Lecun, Y., Bottou, L., Bengio, Y. and Haffner, P., 1998, Gradient-based learning applied to document recognition, *Proceedings of the IEEE*, 86(11), 2278-2324.

[36]. Önder, M., Akan, A. and Doğan, H., 2016, Advanced Neural Network Receiver Design to Combat Multiple Channel Impairments, *Turkish Journal of Electrical Engineering and Computer Sciences*, 24(4), 3066-3077.

[37]. Chikha, W.B., Dayoub, I., Hamouda, W. and Attia, R., 2014, Modulation Recognition for MIMO Relaying Broadcast Channels with Direct Link, *IEEE Wireless Communications Letters*, 3(1), 50-53.

[38]. O'Shea, T. J., Corgan, J. and Clancy, T.C., 2016, Convolutional Radio Modulation Recognition Networks, *In Proceedings of the International Conference on Engineering Applications of Neural Networks*, 2 September 2016 Aberdeen, Springer, ISBN: 978-3-319-44187-0, 213-226.

[39]. West, N.E. and O'Shea, T., 2017, Deep Architectures for Modulation Recognition, *In Proceedings of the 2017 IEEE International Symposiumon Dynamic Spectrum Access Networks (DySPAN)*, 6–9 March 2017 Piscataway, 1-6.

[40]. O'Shea, T. J., Roy, T. and Clancy, T. C., 2017, Over the Air Deep Learning Based Radio Signal Classification, *IEEE Journal of Selected Topics in Signal Processing,* 23 January 2018, ISSN: 1932-4553, 168-179.

[41]. Liu, X., Yang, D. and Gamal, A.E., 2017, Deep neural network architectures for modulation classification, *2017 51st Asilomar Conference on Signals, Systems, and Computers,* 29 Oct.-1 Nov. 2017 Pacific Grove, ISSN: 2576-2303, 915-919.

[42]. Zhang, D., Ding, W., Zhang, B., Xie, C., Li, H., Liu, C. and Han, J., 2018, Automatic Modulation Classification Based on Deep Learning for Unmanned Aerial Vehicles, Sensors, 18(3), 924.

[43]. Önder, M., 2015, *Yazılım Tabanlı İletişim Sistemlerinde Modülasyon Tekniklerinin Gerçeklenmesi ve Uygulamaları,* Doktora, Fen Bilimleri Enstitüsü.

[44]. Mohammad, U., and Sorour, S., 2018, Adaptive Task Allocation for Mobile Edge Learning, 2019 IEEE Wireless Communications and Networking Conference Workshop (WCNCW), 15-18 April 2019 Marrakech, ISBN:978-1-7281-0922-0, 1-6.

[45]. Elbaz, D. and Zibulevsky, M., 2018, End to End Deep Neural Network Frequency Demodulation of Speech Signals, *Proceedings of the 2018 Future of Information and Communication Conference (FICC),* 6 April 2017, Springer, Cham, 1-11.

[46]. Mohammad, A. S., Reddy, N., James, F. and Beard, C., 2018, Demodulation of faded wireless signals using deep convolutional neural networks, *2018 IEEE 8th Annual Computing and Communication Workshop and Conference (CCWC),* 8-10 Jan. 2018 Las Vegas, ISBN: 978-1-5386-4649-6, 969-975.

[47]. Ramjee, S., Ju, S., Yang, D., Liu, X., Gamal, A. E. and Eldar, Y. C., 2019, Fast Deep Learning for Automatic Modulation Classification, *IEEE Mach. Learn. Commun. Emerg. Technol. Initiative,* 16 January 2019 Online.

[48]. Yashashwi, K., Sethi, A. and Chaporkar, P., 2019, A Learnable Distortion Correction Module for Modulation Recognition, *IEEE Wireless Communications Letters, 8(1),* 77-80.

[49]. Mendis, G. J., Wei, J. and Madanayake, A., 2019, Deep Learning Based Radio-Signal Identification With Hardware Design, *IEEE Transactions on Aerospace and Electronic Systems,* 55(5), 2516-2531.

[50]. Wang, H., Wu, Z., Ma, S., Lu, S., Zhang, H., Ding, G. and Li, S., 2019, Deep Learning for Signal Demodulation in Physical Layer Wireless Communications: Prototype Platform, Open Dataset, and Analytics, *IEEE Access,* 7, 30792-30801.

[51]. Thakur, G., 2014, The Synchrosqueezing transform for instantaneous spectral analysis, *Excursions in Harmonic Analysis,* 29 April 2014 Berlin, Springer, ISBN: 9783319201870, 397-406.

[52]. Kong, G. and Koivunen, V., 2019, Radar Waveform Recognition Using Fourier-Based Synchrosqueezing Transform and CNN, *2019 IEEE 8th International Workshop on Computational Advances in Multi-Sensor Adaptive Processing (CAMSAP),* 15-18 December 2019 Le goiser, ISBN: 978-1-7281-5550-0, 664-668.

[53]. Kong, G., Jung, M. and Koivunen, V., 2020, Waveform Recognition in Multipath Fading Using Autoencoder and CNN with Fourier Synchrosqueezing Transform, *2020 IEEE International Radar Conference (RADAR),* 28-30 April 2020, ISBN:978-1-7281-6814-2, 612-617.

[54]. Zhang, S., Pavel, S.R. and Zhang, Y.D., 2021, Crossterm-Free Time-Frequency Representation Exploiting Deep Convolutional Neural Network, *Signal Processing,* 192(6), 108372.

[55]. Verstraete, D., Ferrada, A., Droguett, E.L., Meruane, V. and Modarres, M., 2017, Deep Learning Enabled Fault Diagnosis Using Time-Frequency Image Analysis of Rolling Element Bearings, *Shock and Vibration,* 2017, 1-17.

[56]. Pham, T.D., 2021, Time-frequency time-space LSTM for robust classication of physiological signals, *Scientific Reports,* 11(1), 6936.

[57]. Oberlin, T., Meignen, S., and Perrier, V., 2014, The Fourier based synchrosqueezing transform, *2014 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP),* 4-9 May 2014 Florence, ISBN:978-1-4799-2893-4, 315-319.

[58]. Deepsig Inc. RF Datasets For Machine Learning, https://www.deepsig.ai/datasets, Ziyaret tarihi: 19 Aralık 2021.

[59]. O'Shea, T.J and West, N.M., 2016, Radio Machine Learning Dataset Generation with GNU Radio, *Proceedings of the GNU Radio Conference*, 1(1).

EKLER

EK 1. Geliştirilen CNN Modelinin Çizdirilmesi

