

KOCAELİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTRONİK VE HABERLEŞME MÜHENDİSLİĞİ
ANABİLİM DALI

YÜKSEK LİSANS TEZİ

BİLİŞSEL RADYO SİSTEMLERİNDE KÜMELEME VE DERİN
ÖĞRENME İLE MODÜLASYON SINIFLANDIRMA

TOLGA DEMİRCİ

KOCAELİ 2020

KOCAELİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTRONİK VE HABERLEŞME MÜHENDİSLİĞİ
ANABİLİM DALI

YÜKSEK LİSANS TEZİ

BİLİŞSEL RADYO SİSTEMLERİNDE KÜMELEME VE DERİN
ÖĞRENME İLE MODÜLASYON SINIFLANDIRMA

TOLGA DEMİRCİ

Dr. Öğr. Üyesi Sultan ALDIRMAZ ÇOLAK

Danışman, Kocaeli Üniversitesi


Dr. Öğr. Üyesi Sıtkı ÖZTÜRK

Jüri Üyesi, Kocaeli Üniversitesi

Dr. Öğr. Üyesi Köksal HOCAOĞLU

Jüri Üyesi, Gebze Teknik Üniversitesi

Tezin Savunulduğu Tarih: 06.02.2020



ÖNSÖZ VE TEŞEKKÜR

Bu tez çalışmasında, kablosuz haberleşme sistemlerinden bilişsel radyolarda (cognitive radio, CR) modülasyon sınıflandırma problemine çözüm olarak kümeleme ve derin öğrenme temelli iki modülasyon sınıflandırma yöntemi geliştirilmiştir. CR'lerde birincil kullanıcıların (primary user, BK) ve ikincil kullanıcıların (secondary user, İK) farklı modülasyon türleri kullandığı kabulü altında, bir CR sistemi önerilmektedir. Önerilen modülasyon sınıflandırma sistemiyle, spektral verimi artırmak, bant genişliğini verimli kullanmak ve sistemin doğru kullanıcılara servis sağlaması amaçlanmaktadır.

Çalışmalarında her zaman yanımda olan sayın hocam Dr. Sultan ALDIRMAZ ÇOLAK'a teşekkür ediyorum. Çalışmalarında destek olan sayın Dr. Ali EKŞİM'e ve çalışmalarında her zaman yanımda olan sevgili Tuğba MEYDANLI'ya teşekkürlerimi sunarım. Bu alanda çalışmakta olan araştırmacılara faydalı bir çalışma olmasını temenni ederim.

Şubat-2020

Tolga DEMİRCİ

İÇİNDEKİLER

ÖNSÖZ VE TEŞEKKÜR	i
İÇİNDEKİLER	ii
ŞEKİLLER DİZİNİ.....	iv
TABLolar DİZİNİ	vi
SİMGELER VE KISALTMALAR DİZİNİ.....	vii
ÖZET.....	viii
ABSTRACT	ix
GİRİŞ	1
1. TEZİN ÖNEMİ VE LİTERATÜRDEKİ ÇALIŞMALAR	3
2. KABLOSUZ HABERLEŞME SÖNÜMLEME MODELERİ	7
2.1. AWGN Kanal	7
2.2. Rayleigh Dağılımı	8
2.3. Nakagami-m Dağılımı	8
2.4. Rician Dağılımı	9
2.5. Genelleştirilmiş Gamma Dağılımı.....	10
2.6. Kaskad Rayleigh Dağılımı	11
3. BİLİŞSEL RADYO SİSTEMLERİ.....	12
3.1. CR Sistemi Tasarımı	15
3.2. Önerilen Modülasyon Tanıma Modeli	17
4. MODÜLASYON SINIFLANDIRMA SİSTEMLERİ	18
4.1. Sentetik İşaret Üretme Sistemi	18
4.2. İstatistiksel Kümeleme ile Modülasyon Sınıflandırma Sistemi	19
4.2.1. K-Ortalama algoritması	19
4.2.2. Sistem modeli	22
4.2.3. K-Ortalama yöntemi ile PSK-QAM modülasyon sınıflandırma sistemi	23
4.2.4. K-Ortalama modülasyon sınıflandırma sisteminin sınıflandırma başarımları.....	29
4.3 Derin Öğrenme Ağı ile Modülasyon Sınıflandırma Sistemi	32
4.3.1. CNN	32
4.3.2. Derin öğrenme.....	32
4.3.3. Derin öğrenme ağının tasarımı	33
4.3.4. Derin öğrenme ağının kullanımı.....	33
4.3.5. Derin öğrenme ağının katmanları.....	34
4.3.6. Derin öğrenme ağının eğitim süreci	34
4.3.7. Derin öğrenme ağı girdileri	35
4.3.8. Derin öğrenme ağının sınıflandırma başarımları	36
4.3.9. AWGN kanalından alınan işaretler ile eğitilen derin öğrenme ağının karıştırma matrisi.....	38
4.3.10. Sönümlemeli kanala maruz kalan modüleli işaretler ile eğitilen derin öğrenme ağının karıştırma matrisi	42
4.4. Modülasyon Sınıflandırma Sistemlerinin Sonuçları	43
5. HABERLEŞME FİZİKSEL KATMAN GÜVENLİĞİ	47

5.1. Kanal Modelleri İçin Haberleşme Güvenliği Ölçüt Hesaplamaları	48
5.1.1. Gizlilik kapasitesi	48
5.1.2. SPSC.....	49
5.1.3. SOP.....	49
5.2. Haberleşme Kanallarında Fiziksel Güvenlik Benzetimi	51
5.2.1. Noktadan noktaya haberleşme kanalı.....	52
6. SONUÇLAR VE ÖNERİLER	57
KAYNAKLAR	60
KİŞİSEL YAYIN VE ESERLER	65
ÖZGEÇMİŞ	66



ŞEKİLLER DİZİNİ

Şekil 2.1.	Alıcı-verici sistem diyagramı.	7
Şekil 3.1.	CR döngüsü.	13
Şekil 3.2.	CR türleri ve spektrumda yerleşimleri.	15
Şekil 3.3.	CR sistem diyagramı.	16
Şekil 3.4.	Spektrum dağıtıcı işaret tespiti, modülasyon sınıflandırma süreçleri.	16
Şekil 4.1.	Sentetik işaret üretici akış şeması.	20
Şekil 4.2.	K-Ortalama algoritmasının aşamaları	21
Şekil 4.3.	Modülasyon sınıflandırma algoritması akış şeması.	22
Şekil 4.4.	K-Ortalama PSK-QAM modülasyon sınıflandırıcı sisteminin blok şeması	24
Şekil 4.5.	(a) BPSK, (b) 4-PSK, (c) QPSK, (d) 8-PSK, (e) 16-PSK, (f) 8-QAM ve (g) 16-QAM işaretlerinin yıldız diyagramları.	25
Şekil 4.6.	(a) BPSK, (b) 4-PSK, (c) QPSK, (d) 8-PSK, (e) 16-PSK, (f) 8-QAM ve (g) 16-QAM işaretlerinin K-Ortalama yöntemi ile kümelenmesi SNR = 5 dB.	26
Şekil 4.7.	(a) BPSK, (b) 4-PSK, (c) QPSK, (d) 8-PSK, (e) 16-PSK, (f) 8-QAM ve (g) 16-QAM g) işaretlerinin K-Ortalama yöntemi ile kümelenmesi SNR = 15 dB.	28
Şekil 4.8.	K-Ortalama Temelli PSK/QAM Modülasyon Sınıflandırıcısının SNR'ye karşı sınıflandırma başarımı	29
Şekil 4.9.	K-Ortalama Temelli PSK/QAM Modülasyon Sınıflandırıcısının merkez frekansı $f_c = 100$ Hz için frekans kaymasına karşı sınıflandırma başarımı.	31
Şekil 4.10.	Derin öğrenme ağı diyagramı.	33
Şekil 4.11.	AWGN kanaldan alınan işaretler ile eğitilmiş derin öğrenme ağının değişen modülasyon tipi, modülasyon dereceleri ve SNR değerleri için modülasyon sınıflandırma başarımı.	39
Şekil 4.12.	AWGN kanaldan alınan işaretlerde işaretleri ile eğitilmiş derin öğrenme ağının merkez frekansı $f_c = 100$ Hz için değişen modülasyon tipi, modülasyon dereceleri ve frekans kayması değerleri için modülasyon sınıflandırma başarımı (SNR = 10 dB).	41
Şekil 4.13.	Sönülmlemeye maruz kalan modüleli işaretler ile eğitilmiş derin öğrenme ağının $f_c = 100$ Hz için değişen modülasyon tipi, modülasyon dereceleri ve SNR değerleri için modülasyon sınıflandırma başarımı (SNR = 10 dB).	41
Şekil 4.14.	Sönülmlemeye maruz kalan modüleli işaretler ile eğitilmiş derin öğrenme ağının değişen modülasyon tipi, modülasyon dereceleri ve frekans kayması değerleri için modülasyon sınıflandırma başarımı (SNR = 10 dB).	43
Şekil 5.1.	Noktadan noktaya kanal modeli.	47

Şekil 5.2.	Rayleigh kanal modelinde gerçekleştirilen iletim için (a) SPSC ve (b) SOP	54
Şekil 5.3.	Nakagami-m kanal modelinde gerçekleştirilen iletim için (a) SPSC ve (b) SOP ($m = 2$).....	54
Şekil 5.4.	Rician kanal modelinde gerçekleştirilen iletim için(a) SPSC ve (b) SOP.....	55
Şekil 5.5.	Kaskad Rayleigh kanal modelinde gerçekleştirilen iletim için (a) SPSC ve (b) SOP.	55
Şekil 5.6.	Kaskad Nakagami-m kanal modelinde gerçekleştirilen iletim için (a) SPSC ve (b) SOP ($m = 2$).	55
Şekil 5.7.	Kaskad Rician kanal modelinde gerçekleştirilen iletim için (a) SPSC ile (b) SOP.	56
Şekil 5.8.	Genelleştirilmiş Gamma kanalda (m,n) sönmleme katsayıları için (a) SPSC ve (b) SOP.	56



TABLolar DİZİNİ

Tablo 1.1. Referans alınan modülasyon sınıflandırma çalışmaları ve sınıflandırma başarımları	5
Tablo 2.1. Nakagami-m özel durumları.	9
Tablo 2.2. Genelleştirilmiş Gamma dağılımının özel durumları.....	10
Tablo 4.1. İşaret üretici parametreleri.	18
Tablo 4.2. SNR'si 10 dB AWGN kanaldan iletilen test işaretleri için K-Ortalama modülasyon sınıflandırma başarımının karıştırma matrisi sonuçları (%) matrisi.....	30
Tablo 4.3. SNR'si 20 dB AWGN kanaldan iletilen test işaretleri için K-Ortalama modülasyon sınıflandırma başarımının karıştırma matrisi sonuçları (%) matrisi.....	30
Tablo 4.4. Derin öğrenme ağının katmanları.....	36
Tablo 4.5. Derin öğrenme modülasyon sınıflandırma sistemi parametreleri	37
Tablo 4.6. SNR'si 10 dB AWGN kanalda iletilen test işaretleri için derin öğrenme ağı tabanlı modülasyon sınıflandırma başarımının karıştırma matrisi sonuçları (%).	38
Tablo 4.7. SNR'si 20 dB AWGN kanalda iletilen test işaretleri için derin öğrenme ağı tabanlı modülasyon sınıflandırma başarımının karıştırma matrisi sonuçları (%).	38
Tablo 4.8. SNR'si 10 dB sönümlmeli kanalda iletilen test işaretleri için derin öğrenme ağı tabanlı modülasyon sınıflandırma başarımının karıştırma matrisi sonuçları (%).	42
Tablo 4.9. SNR'si 10 dB sönümlmeli kanalda iletilen test işaretleri için derin öğrenme ağı tabanlı modülasyon sınıflandırma başarımının karıştırma matrisi sonuçları (%).	42
Tablo 4.10. Tezdeki sistemlerin literatürdeki sistemler ile karşılaştırılması.....	45
Tablo 5.1. Benzetimde ele alınan kanal modelleri ve parametreleri.	51
Tablo 5.2. Farklı SNRy değerleri için kanalların SPSC değerleri.....	52
Tablo 5.3. Farklı SNRy değerleri için kanalların SOP değerleri.....	52

SİMGELER VE KISALTMALAR DİZİNİ

Kısaltmalar

AWGN	: Additive White Gaussian Noise (Eklenir Beyaz Gauss Gürültüsü)
CDF	: Cumulative Distribution Function (Kümülatif Dağılım Fonksiyonu)
CNN	: Convolutional Neural Network (Konvolüsyonel Yapay Sinir Ağları)
CR	: Cognitive Radio (Bilişsel Radyo)
FSK	: Frequency Shift Keying (Frekans Kaydırmalı Anahtarlama)
IQ	: In Phase and Quadrature (Eş Fazlı ve Dik Fazlı)
PDF	: Probability Distribution Function (Olasılık Dağılım Fonksiyonu)
PSK	: Phase Shift Keying (Faz Kaydırmalı Anahtarlama)
PU	: Primary User (Birincil Kullanıcı)
QAM	: Quadrature Amplitude Modulation (Dikgen Genlik Modülasyonu)
RRC	: Root Raised Cosine (Kök Yükseltilmiş Kosinüs)
SC	: Secrecy Capacity (Gizlilik Kapasitesi)
SNR	: Signal to Noise Ratio (İşaret Gürültü Oranı)
SOP	: Secrecy Outage Probability (Gizlilik Kesinti Olasılığı)
SPSC	: Probability of Strictly Positive Secrecy Capacity (Kesin Pozitif Gizlilik Kapasitesi Olasılığı)
SSB	: Single Side Band (Tek Taraflı Bant)
WLAN	: Wireless Local Area Network (Kablosuz Yerel Bölge Ağları)
WRAN	: Wireless Regional Area Network (Kablosuz Bölgesel Alan Ağları)

BİLİŞSEL RADYO SİSTEMLERİNDE KÜMELEME VE DERİN ÖĞRENME İLE MODÜLASYON SINIFLANDIRMA

ÖZET

Bu tezde, bilişsel radyolarda (cognitive radio, CR) kullanılmak üzere iki farklı modülasyon sınıflandırma sistemi geliştirilmiştir. İlk sistemde K-Ortalamlar (K-Means) kümeleme algoritması kullanılırken, ikinci sistemde derin öğrenme ağı kullanılmıştır. Bu iki sistemin farklı işaret gürültü oranı (signal-to-noise ratio, SNR) değerleri için sınıflandırma başarımları hesaplanmıştır. Bu iki sistem karşılaştırılarak yöntemin güçlü ve zayıf yönleri ele alınmıştır. Literatürdeki modülasyon sınıflandırma yöntemleri ile karşılaştırılarak çalışmanın literatüre katkısı ile gelecek çalışmalarda gerçekleştirilebilecek eklemeler ele alınmıştır. Haberleşme kanallarının fiziksel katman güvenliğinin sağlanabilmesi için farklı sönümlenme ve kanal modelleri için değişen SNR değerlerinde pozitif gizlilik kapasitesi olasılığı (probability of strictly positive secrecy capacity, SPSC) ve gizlilik kesinti olasılığı (secrecy outage probability, SOP) değerlerinin benzetimleri gerçekleştirilmiştir. Nakagami-m kanalının $m = 2$ değeri için, diğer kanallara kıyasla daha güvenli olduğu sonucuna ulaşılmıştır.

Anahtar Kelimeler: Bilişsel Radyo, Fiziksel Katman Güvenliği, Modülasyon Sınıflandırma, Derin Öğrenme, Kümeleme.

MODULATION CLASSIFICATION IN COGNITIVE RADIO SYSTEMS USING CLUSTERING AND DEEP LEARNING

ABSTRACT

In this thesis, two modulation classification systems are developed to be used in cognitive radio network systems. At the first system, K-Means clustering algorithm is used. At the second system, a deep learning network is used. Both weak and strong aspects of the two systems are compared and studied. Successful classification rates of the two systems are calculated for varying signal to noise ratio (SNR) values. Modulation classification systems in the literature are compared, possible future works for the study are discussed. In order to have physical layer security of communication systems for different fading models and SNR values, probability of secrecy capacity (SPSC) and secrecy outage probability (SOP) are simulated. It is concluded that Nakagami-m channel, is more secure than the other channels for $m = 2$.

Keywords: Clustering, Cognitive Radio, Deep Learning, Modulation Classification, Physical Layer Security.

GİRİŞ

Gelişen kablosuz haberleşme sistemlerinde her yeni teknolojiyle bant genişliğine olan ihtiyaç önemli derecede artmaktadır. Bant genişliğine olan talebin artmasına karşın frekans spektrumunda bu yüksek talebi karşılayacak spektrum bandı bulunmamaktadır. Spektrumda kullanımda olan bantların var olan kullanıcıları etkilemeden çalışan, kablosuz haberleşme sistemlerinin bir alt dalı olan bilişsel radyo (cognitive radio, CR) sistemleri ise bu amaçla önerilmektedir. CR’de spektrum bandı kullanım önceliğine sahip olan birincil kullanıcılar (primary user, BK) ile düşük önceliğe sahip ikincil kullanıcıların (secondary user, İK) sınıflandırılması CR’de karşılaşılan önemli problemlerden biridir. Kullanıcılar, doğru sınıflandırılmak kaydıyla kullanıcılara sahip oldukları spektrum bantları doğru ve güvenli bir şekilde tahsis edilmeli, böylece güvenli erişim sağlanabilmesi için kullanıcıların modüleli işaretlerinin sınıflandırılması gerekmektedir. Bu tezde CR’de karşılaşılan, kullanıcı işaretlerinin sınıflandırılması problemine çözüm olarak iki farklı modülasyon sınıflandırma sistemi geliştirilmiştir. Modülasyon tipi ve derecesinin sınıflandırma başarımları, farklı işaret gürültü oranı (signal-to-noise ratio, SNR) değerleri için elde edilmiştir.

Tezde haberleşme kanallarının güvenliğinin belirlenmesi hedeflenmiş olup fiziksel katman güvenliği ölçütleri farklı kanallar ve farklı SNR değerleri için hesaplanmıştır. Bu sayede kanalın fiziksel katmanının en güvenli olduğu kanal şartları ve SNR değerleri elde edilmiştir. Fiziksel katman güvenliği hesaplamalarından gizlilik kesinti olasılığı (secrecy outage probability, SOP) ve pozitif gizlilik kapasitesi olasılığı (probability of strictly positive secrecy capacity, SPSC) ifadeleri Rayleigh, Nakagami-m, Rician, kaskad Rayleigh, kaskad Nakagami-m, kaskad Rician için kanal modelleri için benzetim ile MATLAB ortamında elde edilmiştir.

Tezin 1. Bölüm’ünde literatür analizi, 2. Bölüm’ünde ise kullanılan kanal modelleri hakkında bilgi verilmiştir. 3. Bölüm’de CR’ler hakkında bilgi verilmiştir. Haberleşme sistemlerinde CR’nin önemi ve literatürde bu konuda gerçekleştirilmiş çalışmalar incelenmiştir. Bu tezin literatürdeki çalışmaların içindeki yeri ve literatüre olan katkısı üzerinde durulmuştur. 4. Bölüm’de ise modülasyon sınıflandırma sistemleri

tasarlanmış ve bu sistemlerin sonuçları karşılaştırılmıştır. Tezde kullanılmak üzere farklı modülasyon tiplerinde ve derecelerinde -kanal sönümlemesine uğramış olan- sentetik kanal sönümlemeli işaret üretme sistemi geliştirilmiştir. Tezde kullanılan işaretler MATLAB benzetim programı kullanılarak hazırlanmıştır. İki farklı modülasyon sınıflandırma algoritması geliştirilmiştir. İlk olarak kümeleme yöntemi olan K-Ortalama algoritması kullanılmıştır. İkinci olarak MATLAB'ın derin öğrenme ağları araç kutusu kullanılarak modülasyon sınıflandırma yapılmıştır. Bu iki sistemin sınıflandırma başarımları farklı SNR ve frekans kayması şartlarında hesaplanmış ve karşılaştırılmıştır. 5. Bölüm'de fiziksel katman güvenliği ele alınmıştır. Literatürde kullanılan çeşitli kanal modellerinde fiziksel katman güvenliği parametrelerinin benzetimleri gerçekleştirilmiştir. Bu benzetimler, farklı SNR değerleri için elde edildikten sonra -çeşitli kanallar içinden- hangi kanalın güvenli olduğunun bulunması için -elde edilen hesaplamaların- hangi kanal sönümlerinde ve hangi SNR değerlerinde geçerli olduğu kıyaslanmıştır. Sonuç bölümünde elde edilen sonuçlar tartışılmıştır. Yüksek modülasyon dereceleri için derin öğrenme yöntemi ile K-Ortalama algoritmasından elde edilen sonuçlar kıyaslandığında derin öğrenme modeliyle kümülant, yapay sinir ağları ve kümeleme yöntemlerinden daha yüksek sınıflandırma başarımları elde edildiği görülmüştür.

1. TEZİN ÖNEMİ VE LİTERATÜRDEKİ ÇALIŞMALAR

CR, az kullanılan veya kullanılmayan frekans bantlarının verimli bir şekilde kullanılmasını sağlayan bir teknolojidir [1]. Kablosuz haberleşme sistemlerinde CR, spektrumdaki frekans bantlarının izlenerek spektrumdaki kullanılmayan veya az kullanılan bantlardan faydalanılabilmesini hedeflemektedir [2]. CR'ler spektrumu, lisanslı kullanıcıları olan BK'ler ile lisanssız kullanıcılar olan İK'ler arasında, BK'lere öncelik vererek paylaşmaktadır [3]. Bunu sağlamak için spektrumda İK'lere frekans bantlarının tahsis edilmesinin ardından BK'lerin tekrar frekans bandını kullanması durumunda çeşitli yöntemler ile İK'lerin erişimi sonlandırılarak BK'lere erişim sağlanmaktadır [4]. Bu kararın alınabilmesi için, spektrum bandını kullanan BK'ler ile İK'lerin işaretlerinin sınıflandırılması büyük önem taşımaktadır. Bu tezde BK ile İK'lerin farklı modülasyon tiplerini kullandığı kabul edilmektedir. Bu kabul altında BK ile İK'nin sınıflandırılması hedeflenmiştir. Modülasyon sınıflandırma, haberleşme sistemlerinden CR'lerde önemli bir yere sahiptir [4]. Literatürde işaretin modülasyon kestirimi ile ilgili çeşitli çalışmalar bulunmaktadır. Gerçek hayat senaryolarında çok yönlü sönümlenme, frekans seçimli sönümlenme ve kanallar arası zaman farkı bu işlemin performansının düşmesine yol açan en önemli etkenlerdendir. Literatürde [5]'te analog modülasyonların destek vektör makineleri (support vector machine, SVM) ile modülasyonları sınıflandırılmıştır. Eklenir beyaz Gauss gürültüsü (additive white Gaussian noise, AWGN) kanalında -7 ve 16 dB SNR için sırasıyla %74 ve %100 ortalama sınıflandırma başarımıyla gerçekleştirilmiştir. Benzer şekilde sayısal modülasyonlar için [6]'da M-dikgen genlik modülasyonunu (quadrature amplitude modulation, QAM) işaretlerin sınıflandırılması gerçekleştirilmiştir. Tablo 1.1'de görüldüğü üzere [6] çalışmasında eksiltici kümeleme (subtractive clustering) algoritması kullanılmıştır. 4, 16, 32 ve 64-QAM modülasyonları için; 0 dB SNR'de sırasıyla %85, %70, %60; 10 dB SNR'de bu modülasyonların tümünde %100 sınıflandırma başarımlarına ulaşılmıştır. [7]'de sayısal modüleli Doppler kaymasına uğramış işaretlerin derin öğrenme ağlarıyla modülasyon sınıflandırılması gerçekleştirilmiştir. AWGN kanalından alınan işaretlerde 100 Hz Doppler kayması ve -5 ile 15 dB arası SNR için 2-faz kaydırmalı anahtarlama (phase shift keying, PSK),

QPSK, 8-PSK, 16-QAM ve 64-QAM modülasyonları için %99 ile %100 arası ortalama sınıflandırma başarımıyla sınıflandırmıştır. [8]'de ise işaretin işaret gücü bilgisi kullanılarak kanal durum bilgisi olmadan modülasyon sınıflandırma gerçekleştirilmiştir. Bu sınıflandırma için kör kestirim, SVM ve yüksek dereceli istatistikler kullanılmıştır. AWGN kanalından alınan işaretlerde -10 ve 15 dB SNR için sırasıyla %55 ve %100 ortalama sınıflandırma başarımı elde edilmiştir. [9]'da 16-QAM modüleli işaretler, AWGN kanalından alınan işaretlerde -3 ve 7 dB SNR için sırasıyla %97 ve %99 ortalama sınıflandırma başarımı ile sınıflandırılmıştır. [10]'da analog ve sayısal modülasyonlar için lineer olmayan veri çıkarım dönüşümleriyle modülasyon sınıflandırma yapılmıştır. Bu sınıflandırma; BPSK, QPSK, 8-PSK modülasyonların AWGN kanalından alınan işaretlerde SNR 0-40 dB arasında, %20 ile %85 arası sınıflandırma başarımı ile gerçekleştirilmiştir. [11]'de 16-PSK ile 16-QAM modülasyonların sınıflandırılması bant genişliği sınırlı sistemler için ise modülasyon sınıflandırma yöntemi geliştirilmiştir. AWGN kanalından alınan işaretlerde SNR 0 ile 8 dB arası için %67 ile %100 arası sınıflandırma başarımı elde edilmiştir. Uydu sistemleri için ise düşük SNR şartlarında [13]'te özellik sözlüğü (feature dictionary) yöntemi ile modülasyon sınıflandırma yapılmıştır. PSK, frekans kaydırmalı anahtarlama (frequency shift keying, FSK), QAM, tek taraflı bant (single side band, SSB) modüleli işaretler AWGN kanalından alınan işaretlerde -20 ile 40 dB arası SNR için sırasıyla %18 ve %80 ortalama sınıflandırma başarımı ile sınıflandırılmıştır. Literatürdeki bahsedilen çalışmaların aksine bu tezde işaretin örnekleri haricinde bir bilgi kullanılmadan kör kestirim yoluyla modülasyon sınıflandırma gerçekleştirilmektedir. Bunun için kümeleme ve derin öğrenme ile M-QAM ve M-PSK sınıflandırma sistemi ile gerçekleştirilmektedir. Literatürdeki çalışmaların çoğunda modülasyon türleri için ayrı ayrı sınıflandırma başarımları bilgisi bulunmamaktadır. [12]'de, BPSK, QPSK, 8-PSK, 16-QAM ve 64-QAM modülasyonları için, -2,5 dB SNR'de sırasıyla %98, %80, %70, %47 ve %25 ve 10 dB SNR'de tüm modülasyon türleri için %100 sınıflandırma başarımına ulaşılmıştır. Modülasyon sınıflandırma başarımları bu çalışmalardan, [6] ve [12]'de ayrı ayrı verilmiştir.

Tablo 1.1. Referans alınan modülasyon sınıflandırma çalışmaları ve sınıflandırma başarımları.

Referans	Kanal	SNR (dB) [min, max]	Sınıflandırılan Modülasyon Türleri	Uygulanan Sınıflandırma Methodu	Uygulanan Yöntem Hakkında Açıklamalar	Ortalama Sınıflandırma Başarımı (%) [min, max]
[5]	AWGN	[-7,16]	AM, FM	SVM	Makine öğrenmesi, frekans histogramı	[74, 100]
[6]	AWGN	[-5,15]	4, 16, 32, 64-QAM	Eksiltici kümeleme algoritması	Parçacık sürü optimizasyonu	[60, 85]
[7]	AWGN, Doppler etkisi	[-5,5]	BPSK, QPSK, 8-PSK, 16-QAM, 64-QAM	Derin öğrenme	Anlık genlik, faz ve frekans bilgileriyle ve kümülant değerleriyle derin öğrenme ağı eğitimi	[99, 100]
[8]	Çok yönlü sönmülme	[-10,15]	BPSK, QPSK, 8-PSK, 16-QAM	SVM	Beklenti maksimizasyonu ve Gauss Karışım Modeli ile kanal durum bilgisi hesaplamaları	[5, 100]


Tablo 1.1. (Devam) Referans alınan modülasyon sınıflandırma çalışmaları ve sınıflandırma başarımları.

Referans	Kanal	SNR (dB) [min, max]	Sınıflandırılan Modülasyon Türleri	Uygulanan Sınıflandırma Methodu	Uygulanan Yöntem Hakkında Açıklamalar	Ortalama Sınıflandırma Başarımı (%) [min, max]
[9]	AWGN	[-3,7]	16-QAM	Kümülant	Kanal durumu bilgisine sahip olduğu varsayımıyla Genelleştirilmiş olabilirlik oran testi,	[97, 99]
[10]	AWGN	[0,40]	BPSK, QPSK, 8-PSK	Yapay sinir ağı	Lineer ve lineer olmayan veri dönüşümü	[20, 85]
[11]	AWGN	[0,8]	16-PSK, 16-QAM	Olabilirlik fonksiyonu (likelihood function)	Veri birleştirme ve ortalama olabilirlik oran testi	[67, 100]
[12]	AWGN	[-5,10]	PSK, FSK, QAM, SSB	CNN	Kümülantlar ve güç spektral yoğunluğu ile CNN eğitimi	[18, 80]
[13]	AWGN	[-2.5, 40]	BPSK, QPSK, 8-PSK, 16-QAM, 64-QAM	Yapay sinir ağı	Kümülantlar , Döngüsel Özilinti fonksiyonu	[64, 100]

2. KABLOSUZ HABERLEŞME SÖNÜMLEME MODELERİ

Kablosuz haberleşme sistemlerinin matematiksel modellemeleri gerçekleştirilirken alıcıda alınan işaretlerinin doğru modellenmesi büyük önem taşımaktadır [14]. Alınan işaretlerin doğru modellenebilmesi için işaretin maruz kaldığı sönmlemeler çeşitli istatistiksel dağılımlara göre incelenmektedir. Bu bölümde, tezde kullanılan olasılık dağılım fonksiyonları (probability distribution function, PDF) ve kümülatif dağılım fonksiyonları (cumulative distribution function, CDF) verilmiştir.

Telsiz haberleşme sistemlerinde alıcı anten boyutları, alıcı-verici çiftinden birinin veya her ikisinin birden hareketli olma durumu, alıcı-verici çifti arasında doğrudan görüş hattının olup olmaması durumlarında kanallar, farklı istatistiksel özellikler göstermektedir. Bu istatistiksel özelliklerle kanalların farklı sönmleme modelleri elde edilmektedir. Bu kanallardan bazıları ise geliştirilmiş kanal olma özelliğine sahiptir.



Şekil 2.1. Alıcı-verici sistem diyagramı.

2.1. AWGN Kanal

Tek vericili ve tek alıcılı bir sistem modeli Şekil 2.1'de verilmektedir. $u(t)$, işaretin birim dürtü yanıtı $g(t)$ olan düz sönmlemeli bir kanaldan iletilmektedir. Alıcıda alınan işarete AWGN, $n(t)$ eklenmektedir. $n(t)$, güç spektral yoğunluğu $\frac{N_0}{2}$ olan gürültü sinyalidir.

$$y(t) = g(t)u(t) + n(t). \quad (2.1)$$

Kanal etkisi,

$$g = \alpha e^{j\theta},$$

şeklinde ifade edilsin. Alıcıda alınan işaret sayısallaştırılıp bir korelatörden geçirildikten sonra alınan işaret

$$y = \alpha e^{j\theta} u + n, \quad (2.2)$$

şeklinde ifade edilebilir [14].

2.2. Rayleigh Dağılımı

Olasılık teorisi ve istatistikte Rayleigh dağılımı, bir devamlı olasılık dağılımıdır. Negatif olmayan değerlere sahip olan bu dağılım, rastgele değişkenler için geçerli bir dağılım çeşididir. Aynı zamanda 2 derece serbestliğe sahip olan Chi dağılımına da eşittir [15].

Rayleigh dağılımı, tüm vektörlerin toplamının yönsel bileşenlerine bağlı olduğu durumlarda gözlemlenmektedir. Gezgin radyo kanallarında Rayleigh dağılımı; düz sönümlenmeli bir işaretin alınan zarfının istatistiksel olarak zamanla değişen yapısını gözlemlenmek için kullanılmaktadır. Rayleigh kanallar için alınan işaret zarfının dağılımı, bileşenlerinden hiçbirinin doğrudan görüş-hatlı olmadığı durum için tanımlanmaktadır. Yayınım hattında doğrudan görüş-hattı (line of sight, LoS) bulunmamaktadır. Sadece saçılmış ve yansımış işaretler alıcıya ulaşmaktadır [14].

Rassal değişken $x > 0$ ve ölçek parametresi $\sigma > 0$ olmak üzere Rayleigh dağılımlı X rastgele değişkeninin PDF ifadesi,

$$f(x) = \frac{x}{\sigma^2} e^{-\frac{x^2}{2\sigma^2}}, \quad (2.3)$$

şeklindedir. CDF ifadesi ise,

$$F(x) = 1 - e^{-\frac{x^2}{2\sigma^2}}, \quad (2.4)$$

şeklinde ifade edilebilmektedir.

2.3. Nakagami-m Dağılımı

Nakagami-m dağılımı, Rayleigh dağılımından daha sert olan sönümlenmeli kanal durumlarını modellemede kullanılmaktadır. Rayleigh dağılımı, Nakagami-m dağılımının özel bir durumudur. Aynı şekilde Rician sönümlenmesi de Nakagami-m

sönümlemesinden elde edilebilmektedir. Hızlı sönümlemenin daha genel bir durumu olarak Nakagami-m sönümlemesi örnek gösterilebilir. Rassal değişken $x > 0$, ölçek parametresi $m \geq 0,5$ ve varyans parametresi $\Omega > 0$ olmak üzere Nakagami-m dağılımlı değişkenin PDF ifadesi,

$$f(x; m, \Omega) = \frac{2m^m}{\Gamma(m)\Omega^m} x^{2m-1} e^{-\frac{m}{\Omega}x^2}, \quad (2.5)$$

şeklindedir. CDF ifadesi ise,

$$F(x; m, \Omega) = P\left(m, \frac{m}{\Omega}, x^2\right) = \frac{\gamma\left(m, \frac{m}{\Omega}, x^2\right)}{\Gamma(m)}, \quad (2.6)$$

şeklinde ifade edilebilir. (2.6)'da P , düzeltilmiş tamamlanmamış Gamma fonksiyonudur [15]. γ , alt tamamlanmamış Gamma fonksiyonudur. (2.5)'te Γ , tam Gamma fonksiyonudur. Tablo 2.1'de Nakagami-m dağılımın özel durumları görülmektedir. Gamma fonksiyonları, kanal sönümlerinin PDF ve CDF ifadelerinin hesaplanmasında kullanılmaktadır. Özellikle Gamma ifadesinin kullanıldığı, genelleştirilmiş Gamma kanalının PDF ve CDF ifadesinde kullanılmıştır.

Tablo 2.1. Nakagami-m özel durumları.

Özel Durum	Kanal Modeli
$m = 1$	Rayleigh
$m = 0,5$	Tek taraflı Gaussian
$m \rightarrow \infty$	İmpuls

Eşitlik (2.5) ve (2.6)'da kullanılan $\gamma(.,.)$ ve $\Gamma(.,.)$ sırasıyla (2.7) ve (2.8)'deki gibidir [15]:

$$\gamma(a, x) = \int_0^x t^{a-1} e^{-t} dt, \quad n, x \in \mathbb{R}, \quad (2.7)$$

$$\Gamma(a, x) = \int_x^\infty t^{a-1} e^{-t} dt, \quad n, x \in \mathbb{R}. \quad (2.8)$$

2.4. Rician Dağılımı

Haberleşme kanallarının etkin gücü olan bileşenlerinden en az birinin doğrudan görüş hatta sahip olduğu kanallar için Rician dağılımı, alınan işaret zarfının dağılımını tanımlamaktadır. Böyle bir durumda farklı açılardan gelen çoklu rastgele yol bileşenleri, etkin işaretin üzerine eklenmektedir. Etkin işaret zayıfladıkça alınan işaretin zarfı, Rayleigh dağılımına dönüşmektedir [1]. Rassal değişken $x > 0$ ve sabit katsayılar $v \geq 0$ ve $\sigma \geq 0$ olarak alınmıştır. PDF,

$$f(x) = \frac{x}{\sigma^2} e^{-\frac{(x^2+v^2)}{2\sigma^2}} I_0\left(\frac{xv}{\sigma^2}\right), \quad (2.9)$$

ile hesaplanmaktadır. CDF ise,

$$F(x) = 1 - Q_1\left(\frac{v}{\sigma}, \frac{x}{\sigma}\right), \quad (2.10)$$

eşitliği ile hesaplanmaktadır. Burada Q_1 , Marcum Q fonksiyonudur [58]. Marcum Q fonksiyonu,

$$Q_M(a, b) = \int_b^\infty x \left(\frac{x}{a}\right)^{M-1} e\left(-\frac{x^2+a^2}{2}\right) I_{M-1}(ax) dx, \quad (2.11)$$

şeklinde tanımlanmaktadır [15]. Burada I_{M-1} , $M - 1$ 'inci dereceden değiştirilmiş birinci tür Bessel fonksiyonudur [16].

2.5. Genelleştirilmiş Gamma Dağılımı

Genelleştirilmiş Gamma Dağılımı; diğer dağılımların kendisinden elde edilebilmesinden dolayı, yüksek öneme sahip istatistiksel bir dağılımdır. Genelleştirilmiş Gamma dağılımı kullanılarak Tablo 2.2'de görüldüğü gibi- Weibull, Gamma, Nakagami-m, üstel, Rayleigh, log-normal dağılımlar elde edilebilmektedir [17].

Rassal değişken $x > 0$, şekil parametresi $a > 0$, sabit katsayılar $d > 0$ ve $p > 0$ için dağılımın PDF ifadesi,

$$f(x) = \frac{(p/a)^d x^{d-1} e^{-(x/a)^p}}{\Gamma(d/p)}, \quad (2.12)$$

CDF ifadesi ise,

$$F(x) = \frac{\gamma(d/p, (x/a)^p)}{\Gamma(d/p)}, \quad (2.13)$$

şeklindedir. (2.12)'deki γ , tamamlanmamış (incomplete) Gamma fonksiyonudur; (2.13)'teki Γ , tam (complete) Gamma fonksiyonudur.

Tablo 2.2. Genelleştirilmiş Gamma dağılımının özel durumları.

Özel Durum	Sonuç
$d = p$	Weibull dağılımına dönüşmektedir.
$p = 1$	Gamma dağılımına dönüşmektedir.
Normalize edilmiş varyans $d/p = 0$	Log-normal dağılıma dönüşmektedir.

2.6. Kaskad Rayleigh Dağılımı

Kaskad Rayleigh dağılımı, birden fazla Rayleigh kanalının art arda kaskad eklenmesi ile oluşmaktadır. Bu dağılım, araçlar arası haberleşme sistemlerinin modellenmesinde kullanılmaktadır [18]. Rassal değişken $x > 0$, rassal değişkenin ortalaması \bar{x} ve yayılım parametresi $\Omega > 0$ için; x 'in PDF ifadesi [18]:

$$f(x) = \frac{2}{x} K_0 \left(2\sqrt{x/\bar{x}} \right), \quad (2.14)$$

olarak hesaplanmaktadır. CDF ifadesi ise:

$$F(x) = 1 - 2\sqrt{x/\bar{x}} K_1 \left(2\sqrt{x/\bar{x}} \right), \quad (2.15)$$

şeklindedir. (2.15)'teki K_n ; n 'inci dereceden, ikinci tür değiştirilmiş Bessel fonksiyonudur. Bu fonksiyon,

$$K_n(x) = \frac{\pi}{2} \frac{I_{-n}(x) - I_n(x)}{\sin(n\pi)}, \quad (2.16)$$

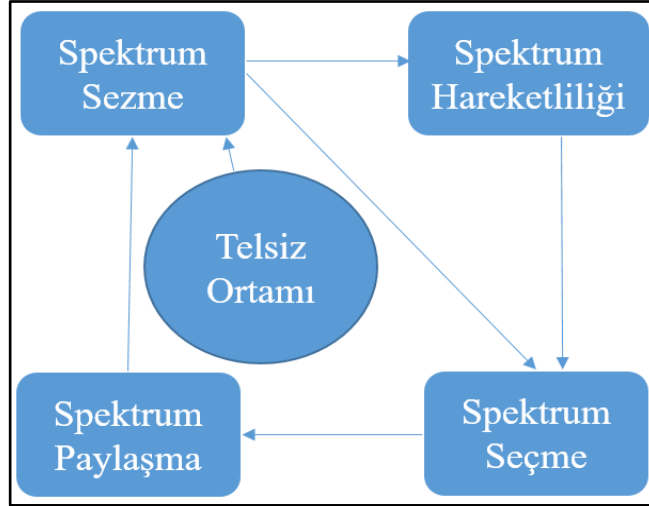
şeklinde tanımlanmıştır. (2.16)'deki $I_n(z)$ fonksiyonu, birinci tür değiştirilmiş Bessel fonksiyonudur. Bu fonksiyon ise,

$$I_n(z) = \frac{1}{2\pi i} \oint e((z/2)(t + 1/t)) t^{-n-1} dt, \quad (2.17)$$

şeklinde tanımlanmıştır [16].

3. BİLİŞSEL RADYO SİSTEMLERİ

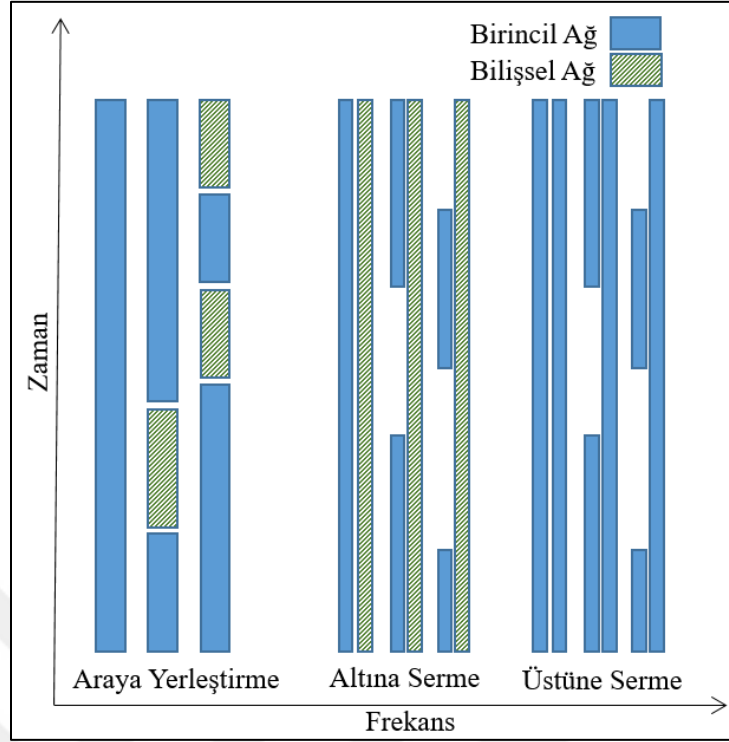
CR sistemleri, kısıtlı frekans spektrumu bantlarının verimli kullanılması amacıyla önerilmektedir. CR'ler, spektrumu iki tür kullanıcının paylaşmasına olanak sağlayan sistemlerdir [19]. BK, spektrum bandının lisanslı sahibi olan kullanıcıdır ve spektrum bandının tam erişimine sahiptir. İK ise spektrum bandının sahibi olmayan, lisanssız kullanıcıdır [20]. CR'ler; Şekil 3.1'deki gibi CR döngüsüne göre spektrumun hareketliliğini sezmektedir ve spektrum bantlarını BK ve İK'lere paylaşmaktadır. Bir CR sistemi -sistemin CR kurallarına uygun bir şekilde- BK'ler, İK'ler, birincil baz istasyonu, ikincil baz istasyonu ve spektrum dağıtıcısından oluşmaktadır [21]. Erişim yetkisi yönünden BK ve İK olarak iki kullanıcı tipi bulunmaktadır. Sistemde BK'lerin, İK'lere göre erişim yetkisi yüksektir. Eğer bant kullanım dışı ve BK veya İK, banda erişmek için servis talebinde bulunursa kullanıcılara erişim sağlanmaktadır. Pratikte CR'ler; kablosuz yerel bölge ağlarında (wireless local area networks, WLAN), TV yayın bantlarında ve lisanslanmamış bantlarda IEEE 802.15 standardına göre telsiz haberleşme sistemlerinin entegrasyonu için önerilmektedir [22]. Dünya genelinde kullanılan ilk CR standardı IEEE 802.22 kablosuz bölgesel alan ağları (wireless regional area networks, WRAN) olarak tanımlanmıştır. Bu teknoloji kapsamında VHF/UHF TV bantları, CR telsiz haberleşmesi için ayrılmıştır. Bu standardın amacı, kullanılmayan frekans bantlarının telsiz haberleşmesi için kullanılmasıdır [23]. CR'ler, spektrumu kontrol etmek için dört temel işleve sahiptir. Bunlar; spektrum algılama, spektrum yönetimi, spektrum taşınması ve spektrum paylaşımıdır [24]. Bu işlevlerin pratikte elde edilmesi, pahalı elektronik sistemlere ve yüksek işlem gücüne gereksinim duymaktadır [25]. CR'ler, BK'lerin frekans bantlarını kullanmadığı durumlarda -BK'leri olumsuz etkilememek şartıyla- İK'lerin de frekans bantlarını kullanmasını sağlayan kablosuz haberleşme sistemleridir [26]. Spektrum atama, CR'lerdeki başlıca problemlerden bir tanesidir. Sistemin çalışması sırasında spektrum bandının, BK veya İK tarafından kullanımda olup olmadığı tespit edilerek -kullanım izinlerine göre- kullanıcılar bantlara atanmaktadır [27].



Şekil 3.1. CR döngüsü.

İK'ler üç farklı CR yönteminden birini kullanarak spektruma erişebilmektedir. Bu yöntemler ise Şekil 3.2'deki gibi altına serme (underlay), üstüne serme (overlay) ve araya yerleştirme (interweave) olmak üzere üç yöntem bulunmaktadır [28]. Şekil 3.2'de spektrum etkinliği BK için mavi renkle, İK için yeşil renkle ifade edilmiştir. Şekil 3.2'de araya yerleştirme BK ve İK'den yalnızca birinin spektrum bantlarını kullanabildiği görülmektedir [29]. Aynı zamanda altına serme yaklaşımında İK'nin her zaman aktif olabileceği, üstüne serme yaklaşımında ise BK ile aynı bantları aynı zamanda kullanabildiği görülmektedir [30]. CR'lerde, -kullanıcılara spektrumu dağıtma yöntemlerinden biri olan- altına serme yönteminde İK'nin BK'ye yaptığı girişim seviyesi ölçülmektedir. Ölçülen girişim değeri, belirlenen eşik seviyesinin altındayken İK'nin haberleşmesine izin verilmektedir [31]. Üstüne serme yaklaşımında İK, BK'nin mesajlarını dinlemektedir. Bu yaklaşımda elde edilen mesajları, BK ile girişimi azaltmak veya BK alıcısına göndermek için kullanmaktadır. İK, röle olarak hem kendi işaretini hem de BK'nin işaretini göndermektedir [32]. BK'nin spektrumu nadiren kullandığı durumlar için önerilen araya serme yaklaşımında İK'ler sürekli spektrumu izlemektedir ve BK etkinliğini tespit etmektedir [29]. İK, BK'nin etkin olmadığı zamanlarda spektrum boşluklarını sezerek iletim gerçekleştirmektedir. Tezde önerilen modülasyon sınıflandırma sistemleri; altına serme, üstüne serme ve araya yerleştirme yaklaşımlarından bağımsız olarak BK ve İK'nin farklı modülasyonları kullandığı kabulü ile alınan işaretlerin modülasyonlarını sınıflandırarak BK ve İK'leri sınıflandırabilecek şekilde geliştirilmiştir.

CR'ler, spektrum kaynaklarının devamlı izlenmesini gerektirmektedir. CR; kullanıcılarının ihtiyaç ve taleplerine göre spektral özelliklerini yeniden düzenleyebilme yeteneğine sahip olmalıdır [33]. Örneğin, gecikmeye hassas olan uygulamalarda, veri gönderme hızının hata oranından daha önemli olması durumunda CR'lerde daha yüksek spektral verime ulaşılabilmesini sağlamaktadır. Hata oranının önemli olduğu uygulamalarda ise düşük hata oranına sahip modülasyonlar seçilerek iletişimin sürdürülebilmesi mümkündür [32]. Aynı zamanda BK'nin işaret bilgisinin bilindiği CR uygulamalarında, modülasyon bilgisinin bilinmesi sonucunda alıcı verici eşleşmesinin önemli derecede kolaylaştırılması mümkündür [15]. Bu kullanıcıları devamlı izlenmenin sonucu olarak, BK ve İK'lere adil ve verimli bir şekilde spektrum dağıtılmaktadır [20]. CR'lerde kullanıcıların farklı modülasyon tipleri veya derecelerine sahip olması, BK ve İK'lere farklı servis sunmanın ve kullanıcıları sınıflandırmanın bir yoludur. Bu sayede BK'ler ile İK'lerin farklı modülasyonları kullandığı bilinen alınan işaretlerin modülasyonları sınıflandırılarak BK ve İK'lerin sınıflandırılması mümkündür [21]. Literatürde CNN ile modülasyon tipleri sınıflandırılmıştır. CNN gibi makine öğrenmesi temelli yöntemler, CR'lerde BK ve İK'lerin sınıflandırılması problemine çözüm olarak önerilmektedir. Sistemin BK ve İK'leri sınıflandırma başarımının önemli ölçüde eğitim sürecinin uzunluğu, eğitim veri setinin ve eğitilen ağı büyüklüğüne bağlı olması, eğitim veri setinin ve ağı büyüklüğünün artması ile sistemin eğitilmesi için gereken işlem gücünün önemli derecede artması gibi belirli sınırlandırmalara sahiptir [22]. CR'lerde, alınan işaretlerin frekans kanalları kümelenecek işaretlerin modülasyonlarının sınıflandırılması, SVM kullanılarak [26]'da gerçekleştirilmiştir. Benzer şekilde [29]'da CR'lerde kullanıcıları sınıflandırmak için -hızlı öğrenen SVM yöntemi kullanılarak spektrum tespitiyle- bir modülasyon sınıflandırma sistemi tasarlanmıştır. [30]'da ise sınırlı spektrum kaynaklarının verimli kullanılabilmesi için spektrum atama algoritmasındaki esnekliğin ve kaynak atama veriminin artırılmasına yönelik -genetik algoritmalarla- spektrum kaynaklarının tahsis edilmesi gerçekleştirilmiştir. Spektrum kaynaklarının

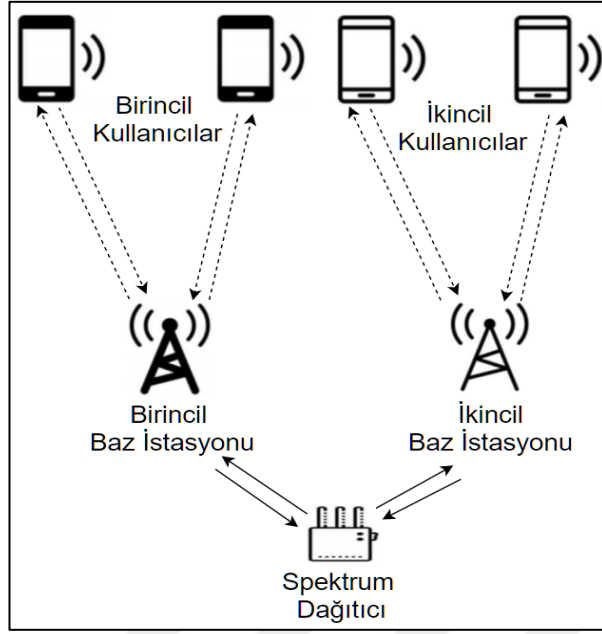


Şekil 3.2. CR türleri ve spektrumda yerleşimleri.

kullanıcılara dağıtılması ile ilgili iletim zamanının dikkate alınmasıyla kullanıcıların sınıflandırılmasına etkisi ise [31]'de incelenmiştir. Bu tezde ise spektrumun kullanıcılara dağıtılması için kullanıcıların modülasyonlarını dikkate alarak kümeleme ve derin yapay sinir ağları ile kullanıcıların spektruma atanmasının sağlandığı bir CR sistemi önerilmiştir. Bu tezde ise spektrumun kullanıcılara verimli bir şekilde dağıtılabilmesi için İK ve BK'nin modülasyonlarının dikkate alınarak sınıflandırıldığı bir CR sistemi önerilmiştir.

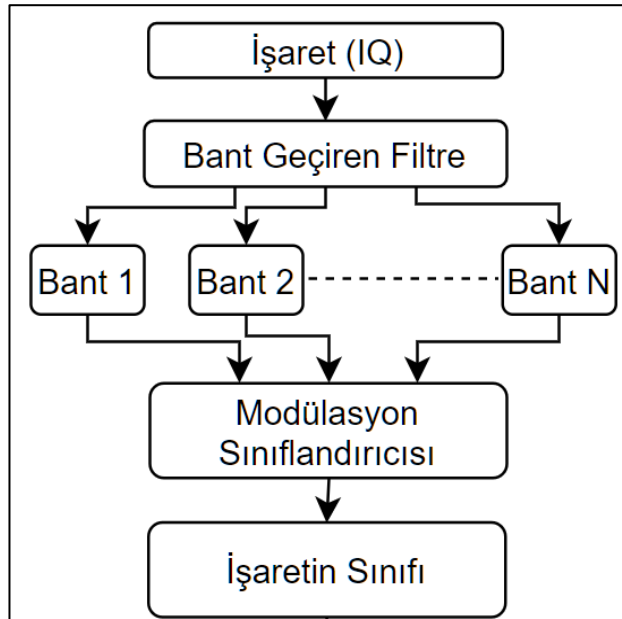
3.1. CR Sistemi Tasarımı

Sistemin elemanları olan, birden fazla sayıdaki BK ve İK'ler, birincil ve ikincil baz istasyonları ve spektrum paylaştırıcısı Şekil 3.3'te gösterilmiştir [15]. Verilen sistemde spektrum paylaştırıcısı, Şekil 3.3'te gösterilen sisteme uygun bir şekilde iletilmiştir [7]. İletilen modüleli işarete kanal etkileri eklendikten sonra alıcıya ulaştığı kabul edilmektedir [8]. Sistem almış olduğu, karmaşık eş fazlı ve dik fazlı (in-phase and quadrature, IQ) işaretleri işleyerek Şekil 3.4'te modülasyon tipini belirlemektedir.



Şekil 3.3. CR ağı sistem diyagramı.

İşaretin kullanıcı tipi tespit edildikten sonra BK ya da İK olduğuna karar verilmekte, bu karara göre de erişimi sağlanmakta veya engellenmektedir. Bu sistemde spektrum dağıtıcı, orta frekansta almış olduğu işareti -sadece önceden belirlenmiş spektrum bantlarında- bant geçirici filtrelerden geçirerek almaktadır ve her adımda yalnızca belirli bir frekans bandını kontrol etmektedir.



Şekil 3.4. Spektrum dağıtıcı işaret tespiti, modülasyon sınıflandırma süreçleri.

3.2. Önerilen Modülasyon Tanıma Modeli

Bu tezde K-Ortalama ve derin öğrenme ile 2 farklı modülasyon sınıflandırma sistemi geliştirilmiştir. K-Ortalama yöntemiyle AWGN kanaldan alınan işaretler için sınıflandırma gerçekleştirilmiştir. Derin öğrenme sisteminde hem AWGN kanaldan alınan hem de sönümlenmeli kanaldan alınan işaretler için sınıflandırma yapılmıştır.



4. MODÜLASYON SINIFLANDIRMA SİSTEMLERİ

CR'lerde, farklı kullanıcı türlerinde kullanıcıların öncelik derecesine göre farklı modülasyonlar kullanılabilirdiği için işaretin modülasyonunu sınıflandırarak kullanıcıların ayırt edilebilmesi mümkündür. Bu bölümde modülasyon sınıflandırma konusu ele alınarak iki modülasyon sınıflandırma sistemi önerilmiştir. Bu iki yöntemden ilkinde kümeleme, K-Ortalama algoritması kullanılmıştır. İkinci sistemde ise derin öğrenme ağı tasarlanmıştır. Ardından bu ağ eğitilerek sınıflandırma gerçekleştirilmiştir. Gerçekleştirilen sınıflandırma sistemlerinin farklı senaryolardaki sınıflandırma başarımları hesaplanarak bu sistemler birbirleri ile karşılaştırılmıştır.

4.1. Sentetik İşaret Üretme Sistemi

Tez kapsamında incelenen modülasyon sınıflandırma sistemlerini test etmek için; modülasyon derecesine, modülasyon tipine, SNR değerine, kanal tipine, darbe şekillendirme filtre katsayısına, örnekleme oranına ve örnek sayısına göre sentetik kayıtlar üretilmektedir. Üretilen kayıtlar Matlab ortamında üretilen işaretlerde Tablo 4.1'de ele alınan parametreler sunulmaktadır. Kayıt üretici algoritmasında Şekil 4.1'deki algoritma kullanılmaktadır.

Tablo 4.1. İşaret üretici parametreleri.

Parametreler	Parametre Değerleri
Modülasyon Derecesi (M)	{2, 4, 8, 16}
Modülasyon Tipi	'PSK', 'QAM'
Kanal İsmi	'AWGN', 'Rayleigh', 'Nakagami-m', 'Rician'
Rayleigh kanal parametreleri	Ölçek parametresi $\sigma > 0$
Nakagami-m kanal parametreleri	Şekil parametresi: $m \geq 0,5$ Yayılm parametresi: $\Omega > 0$
Rician kanal ise kanal parametreleri	Referans noktası ile iki değişkenli dağılımın merkezi arası uzaklık: $v \geq 0$ Sabit katsayı: $\sigma \geq 0$
Darbe Şekillendirme Filtre Türü	Kök Yükseltilmiş Kosinüs
Darbe Şekillendirme Filtre Katsayısı (α)	{0,25, 0,5, 0,75}
Örnekleme Frekansı	8000 Hz
Örnek Sayısı	1024
Merkez Frekans (fc) (Hz)	100

İşaret üreticide öncelikle rastgele örnekler Tablo 4.1’de verilen parametrelere uygun bir şekilde verilen örnek sayısı $[0, M - 1]$ aralığında üretilmektedir. Örnekler verilen katsayıda kök yükselen kosinüs şekillendirme filtresinden geçirilmektedir. Ardından kanal sönümlemesi uygulanmaktadır. Sınıflandırmada kullanılan tüm işaretler normalize edilmiştir.

4.2. İstatistiksel Kümeleme ile Modülasyon Sınıflandırma Sistemi

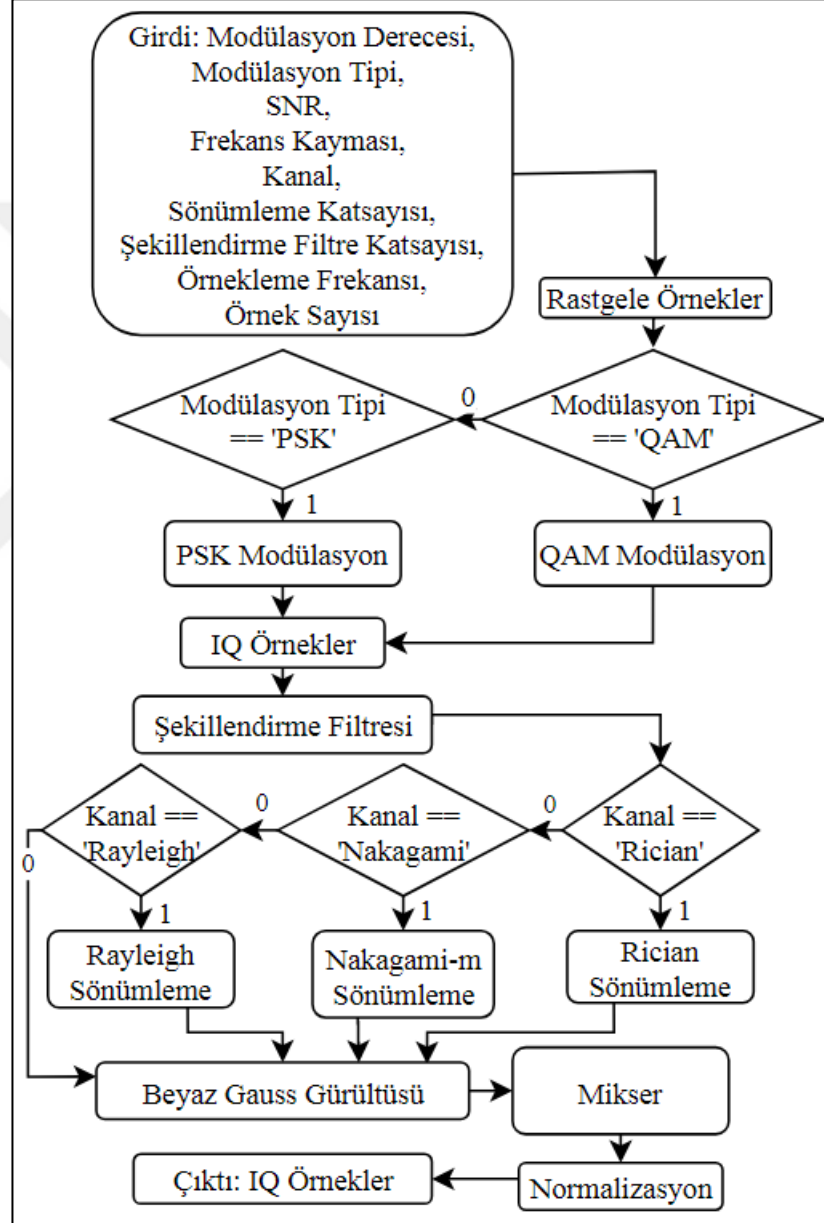
Tez çalışması sürecinde K-Ortalama algoritmasını kullanarak bir modülasyon tanıma algoritması tasarlanmış ve sınıflandırma başarımı çeşitli SNR değerleri ve kanal sönümlenmeleri için benzetim yoluyla elde edilmiştir. Bu sistem modülasyon tiplerinden PSK ve QAM modülasyonları değişen modülasyon dereceleri için sınıflandırılabilir.

4.2.1. K-Ortalama algoritması

Büyük boyutlardaki verilerden küçük bir kısmının çıkarılarak gizli kalmış bilgilerin kullanılmasına veri madenciliği denmektedir. Veri madenciliği uygulamalarında kullanılan, veri analizi için çok çeşitli algoritmalar bulunmaktadır. Bu algoritma sınıflarından bazıları kümeleme, birliktelik ve sınıflandırma olarak ifade edilebilmektedir [38]. K-Ortalama aşamaları Şekil 4.2’de gösterilmiştir. En yaygın kullanılan gözetimsiz öğrenme yöntemlerinden biri olan K-Ortalama’nın atama mekanizması ile, her verinin sadece bir kümeye ait olabilmesine izin verilmektedir [34]. Bu nedenle keskin bir kümeleme algoritmasıdır. Merkez noktanın kümeyi temsil etmesi ana fikrine dayalıdır ve eşit büyüklükte küresel kümeleri bulmaya eğilimlidir [35]. Bu yöntemin amacı, yapılan bölümlenme işleminin sonucu olarak elde edilen kümelerin kümeler arası benzerliklerinin maksimum ancak küme içi benzerliklerinin minimum olmasını sağlamaktır [36].

K-Ortalama uygulanması kolaylığından ötürü en sık kullanılan kümeleme algoritmalarından biridir. Büyük ölçekli verileri hızlı ve etkin şekilde kümeleyebilmektedir [37]. K, algoritmaya başlamadan önce ihtiyaç duyulan sabit küme sayısını ifade etmektedir. Tekrarlı bölümleyici yapısı ile K-Ortalama algoritması, her verinin ait olduğu kümeye olan uzaklıkları toplamını küçültmektedir [38]. K-Ortalama algoritması karesel hatayı en küçük yapacak olan K adet kümeyi tespit

etmeye çalışmaktadır [39]. K-Ortalama algoritması bir iteratif yaklaşım ile genelde iyi bir çözüm verdiği için yaygın olarak tercih edilmektedir [38]. Her bir veri n-boyutlu reel vektör olmak üzere bir $\{v_1, v_2, \dots, v_N\}$ veri kümesi ve K bölünecek küme sayısı olarak verilmektedir. K-Ortalama kümeleme, karesel hatayı en aza indirmek için N tane veriyi K adet $\{S_1, S_2, \dots, S_K\}$ kümeye bölümlenmeyi amaçlamaktadır [38]. En düşük hata değerine sahip kümeleme, en iyi sonucu vermektedir.



Şekil 4.1. Sentetik işaret üretici akış şeması.

Başka bir deyişle,

$$\mu_i = \frac{1}{|S_j|} \sum_{x_i \in S_j} v_i, \quad (3.1)$$

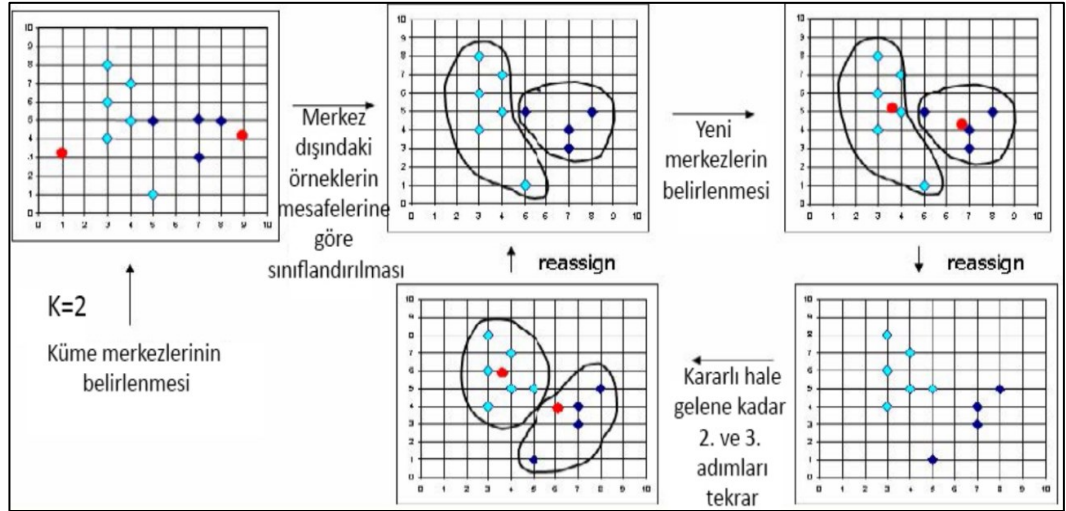
burada μ_i , S_j 'deki noktaların ortalamasıdır.

K-Ortalama küme hata değeri, nesnelerin buldukları kümenin merkez noktalarına olan uzaklıklarının karelerinin toplamı ile hesaplanmaktadır. Bunun için,

$$\text{argmin} \sum_{j=1}^K \sum_{x_i \in S_j} \|v_i - \mu_j\|^2, \quad (3.2)$$

ifadesinin bulunması amaçlanmaktadır [40].

K-Ortalama algoritmasının çalışma mekanizmasına göre öncelikle her kümenin merkez noktasını veya ortalamasını temsil etmek üzere K adet nesne rastgele seçilmektedir. Kalan diğer nesneler, kümelerin ortalama değerlerine olan uzaklıkları dikkate alınarak en benzer oldukları kümelere dâhil edilmektedir [50]. Daha sonra her bir kümenin ortalama değeri hesaplanarak yeni küme merkezleri belirlenmektedir ve nesnelerin merkeze uzaklıkları tekrar incelenmektedir. Herhangi bir değişim olmayıncaya kadar algoritmanın akışı tekrarlamaya devam etmektedir [31]. K-Ortalama algoritması Şekil 4.2'de gösterildiği gibi 4 adımdan oluşmaktadır:



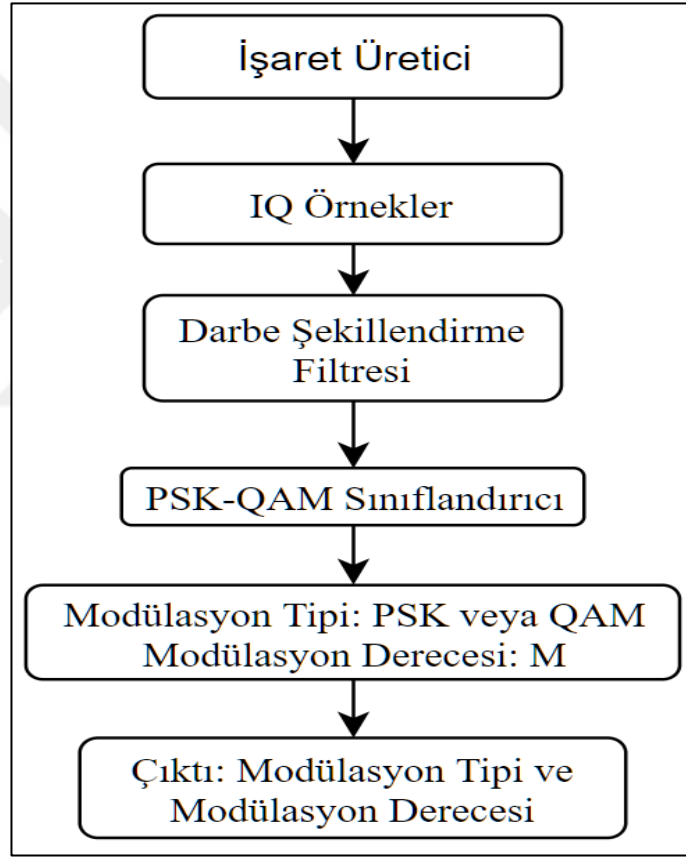
Şekil 4.2. K-Ortalama algoritmasının aşamaları.

İlk olarak küme merkezleri belirlenmektedir. Küme merkezi dışındaki noktalar, birbirlerine olan mesafelerine göre kümelere ayrılmaktadır. Yapılan kümeleme işlemine göre yeni merkezler belirlenmektedir veya eski merkezler yeni merkezlere

kaydırılmaktadır. Kararlı hâle gelinene kadar adımlar tekrarlanmaktadır. Son olarak K-Ortalama kümeleri ve merkezleri elde edilmektedir.

4.2.2. Sistem modeli

Modülasyon sınıflandırma sistemi Şekil 4.3'te gösterilen sistem modeline göre tasarlanmıştır. Modülasyon sınıflandırma sistemi PSK-QAM sınıflandırıcıdan oluşmaktadır. Alınan IQ işaret örnekleri işaretin alıcı darbe şekillendirme filtresinde örnek başına sembol oranı 1'e düşürüldükten sonra PSK-QAM sınıflandırıcıda modülasyon derecesi ve modülasyon tipi elde edilmektedir.



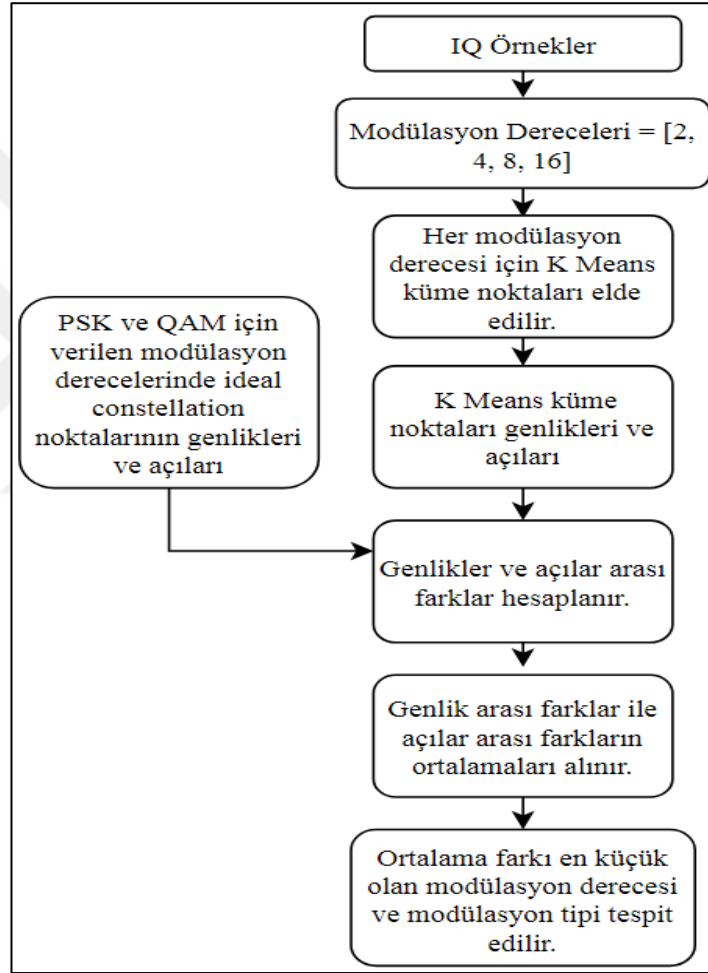
Şekil 4.3. Modülasyon sınıflandırma algoritması akış şeması

4.2.3. K-Ortalama yöntemi ile PSK-QAM modülasyon sınıflandırma sistemi

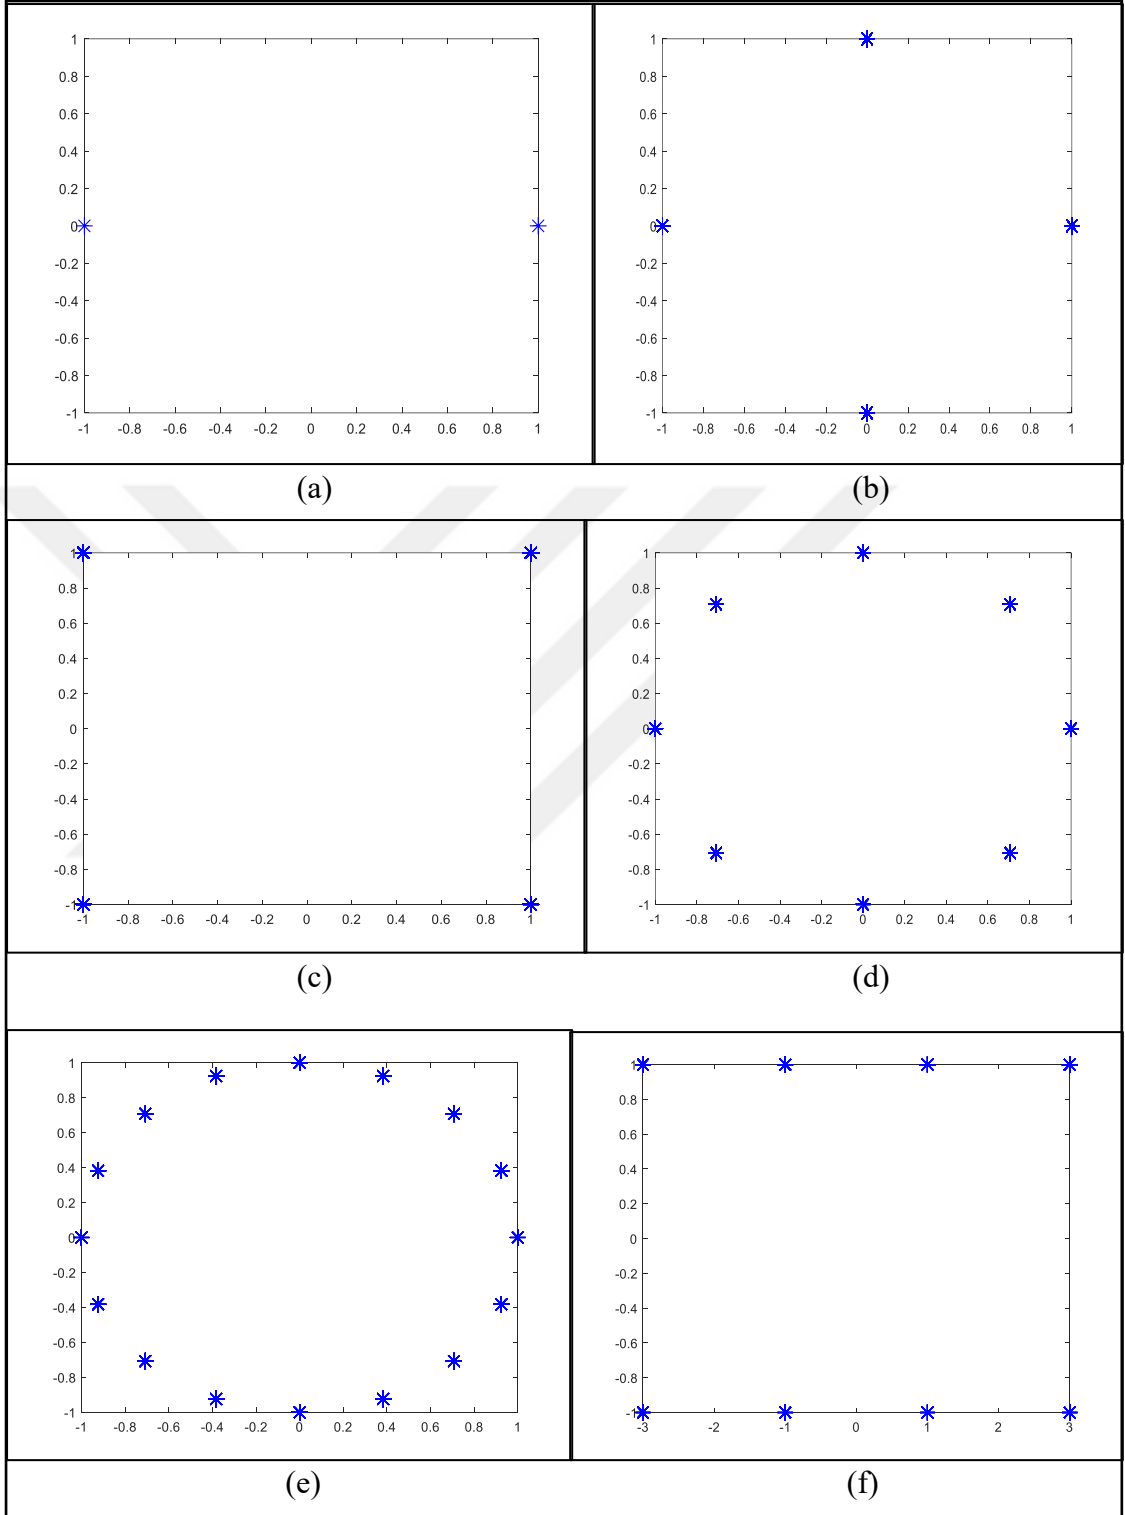
PSK/QAM sınıflandırıcı algoritması temel olarak işaretin K-Ortalama hesaplamasını gerçekleştirmektedir. Şekil 4.4'teki gibi alınan işaretinin örnekleri alınarak örneklerin istatistiksel özellikleri çıkartılmaktadır. Bir taraftan da ideal bir işaret üretilmektedir. Ardından ideal işaretin özellikleri ile alınan işaretinin özellikleri karşılaştırılmaktadır. Karşılaştırma sonucunda ideal işarete en yakın olan modülasyon tipi ve derecesine sahip olan modülasyon kestirilmektedir. Sistemde öncelikle her sembol başına yalnızca bir işaret düşecek şekilde, merkez frekansı sıfırda olacak şekilde IQ işaret alınmaktadır. İstenen modülasyon dereceleri de alınarak bu modülasyon derecelerinde K-Ortalama kümeleri ve küme merkezleri verilen IQ işaret için elde edilmektedir. Bu kümelerin ve küme merkezlerinin elde edilmesi her modülasyon derecesi için ayrı ayrı gerçekleştirilmektedir. Her modülasyon derecesi için küme merkezlerinin genlikleri ve açıları elde edilmektedir. Bu değerlerin aralarındaki farklar her modülasyon derecesi için ve her modülasyon tipi için hesaplanmaktadır. Dolayısıyla, hesaplanan farkların ortalaması alınmaktadır. Ortalama farkı en az olan modülasyon tipi ve derecesi modülasyon sınıflandırma sonucu olmaktadır. Modülasyon sınıflandırma için önerilen algoritmanın akışı Şekil 4.1'de verilmektedir. K-Ortalama yöntemi ile PSK ile QAM işaretlerin sınıflandırıldığı bu yöntemin sınıflandırma başarımı sentetik işaretler kullanılarak ölçülmüştür ve değişen SNR değerleri, modülasyon tipleri ve modülasyon dereceleri için sınıflandırma başarımları hesaplanarak diğer yöntemler ile karşılaştırılmıştır. Aynı zamanda bu yöntemin karıştırma matrisi de hesaplanarak modülasyon tiplerinden ve modülasyon derecelerinden hangilerinin birbirlerine en çok karıştırıldığı ve sistemin genel sınıflandırma başarımı hesaplanmıştır. K-Ortalama algoritması ile işaretlerin yıldız diyagramlarının kümelenmesi her modülasyon derecesi ve türü için gerçekleştirilmiştir. BPSK, 4-PSK, QPSK, 8-PSK, 16-PSK, 8-QAM ve 16-QAM modüleli işaretlerin K-Ortalama algoritması ile kümeleme işlemi ile elde edilen yıldız diyagramları Şekil 4.5'te gürültüsüz yıldız diyagramları görülmektedir. K-Ortalama yöntemi ile kümeleme sonunda elde edilen yıldız diyagramları, SNR = 5 dB için Şekil 4.8'de ve SNR = 15 dB için Şekil 4.9'da gösterilmiştir. Burada SNR değeri düşük olmasına karşın işaretlerin dağılmış yıldız diyagramı noktalarından K-Ortalama küme merkez noktalarının tespiti ile işaretlerin

yıldız diyagramı noktalarından daha düzenli bir duruma getirilmiş ve işaretin modülasyonunun sınıflandırılabilmesi sağlanmıştır.


SNR arttıkça kümelerin merkezleri arasındaki mesafenin de arttığı görülmektedir. Yıldız diyagramlarından görüldüğü üzere modülasyon derecesinin artmasıyla işaretlerin K-Ortalama yöntemi ile elde edilen kümelerinin aralarındaki mesafelerin de küçülmesi ve noktaların birbirlerine yaklaşmasından dolayı hesaplamaların sınıflandırma başarı mı küçük K değerleri için yüksek olarak elde edilmektedir.



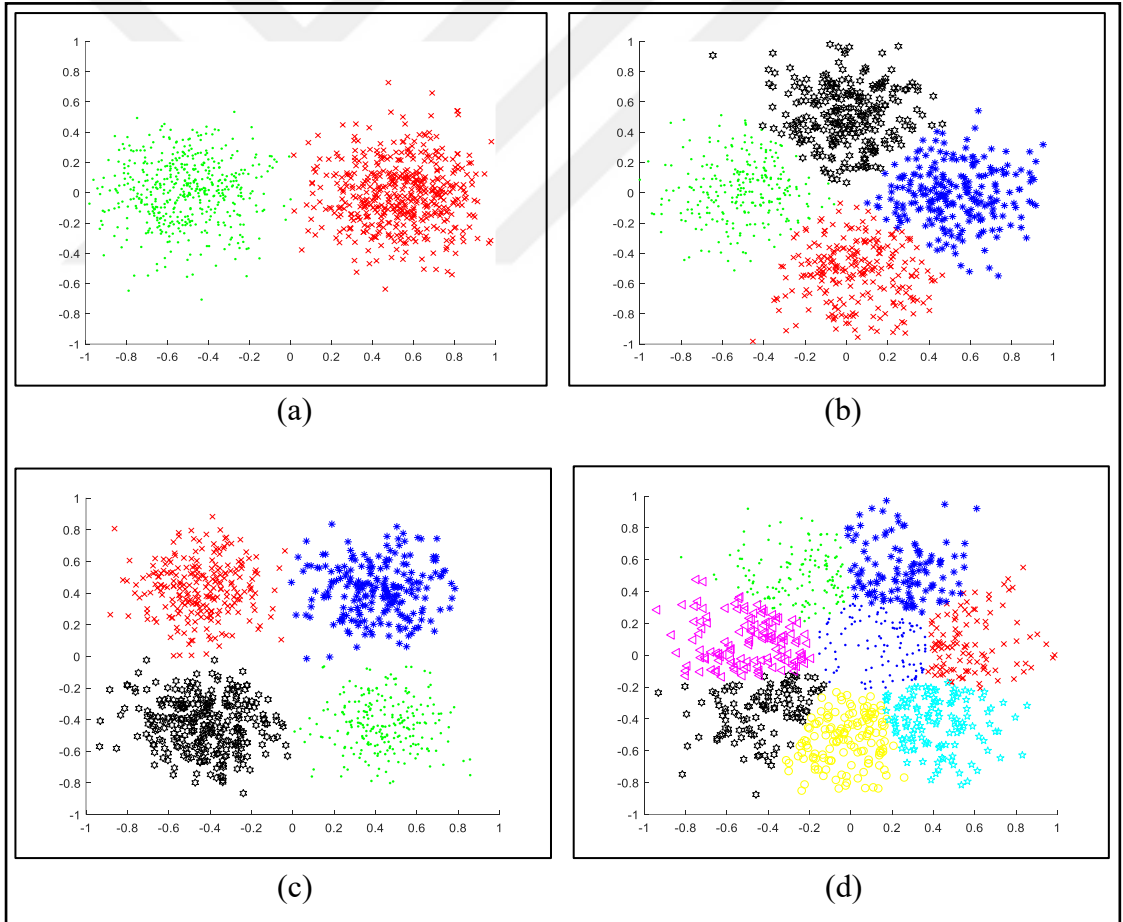
Şekil 4.4. K-Ortalama PSK-QAM modülasyon sınıflandırıcı sisteminin blok şeması.



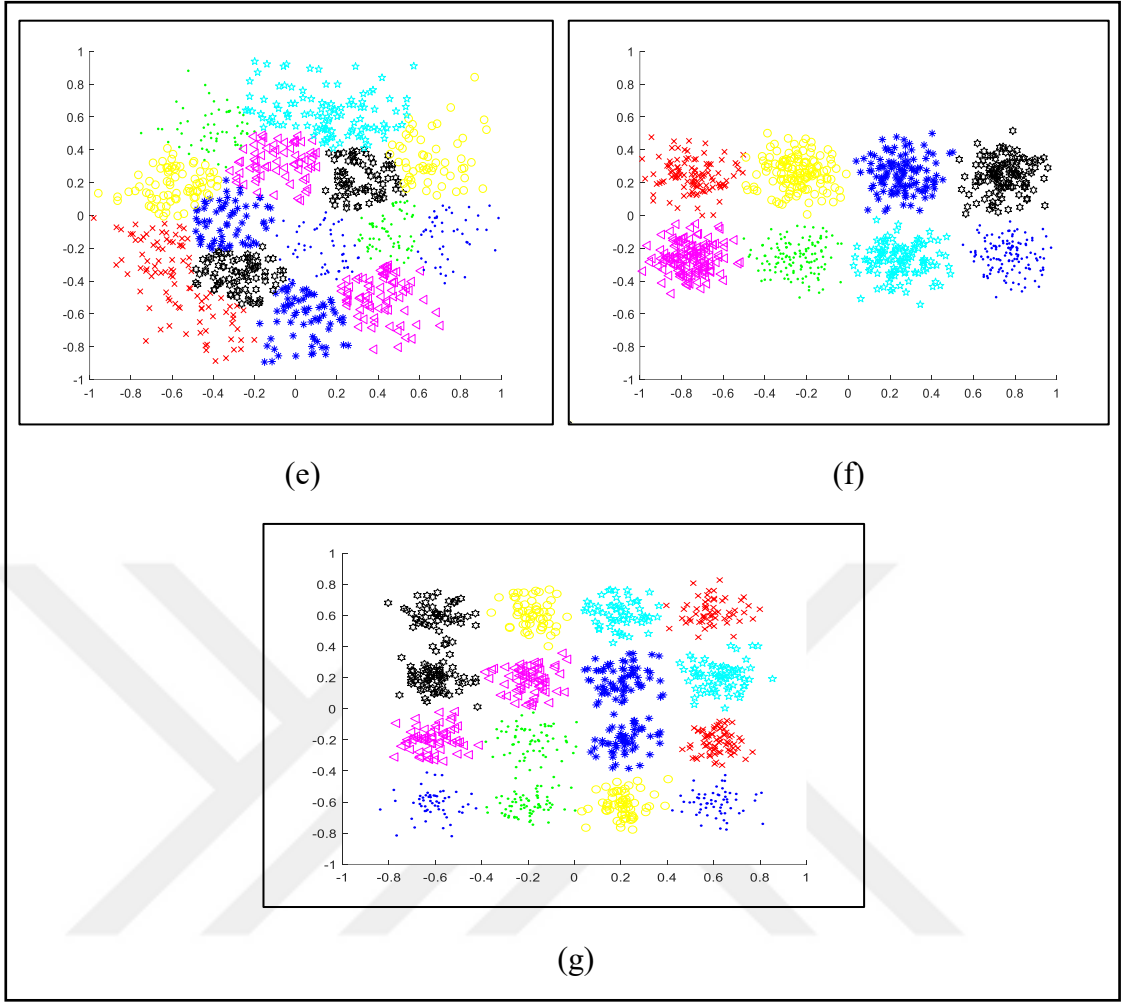
Şekil 4.5. (a) BPSK, (b) 4-PSK, (c) QPSK, (d) 8-PSK, (e) 16-PSK, ve (f) 8-QAM ve (g) 16-QAM işaretlerinin yıldız diyagramları.



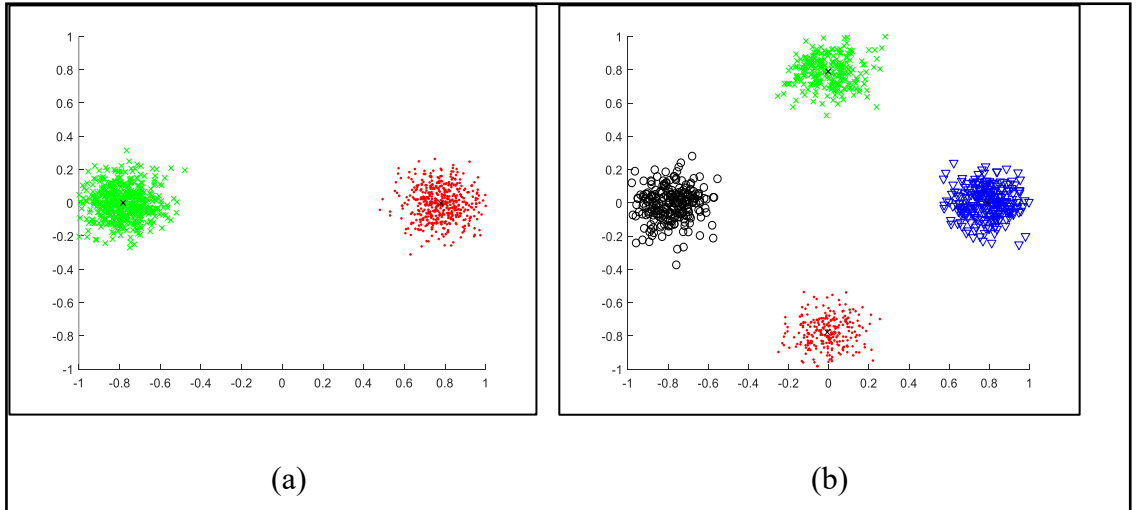
Şekil 4.5. (Devam) (a) BPSK, (b) 4-PSK, (c) QPSK, (d) 8-PSK, (e) 16-PSK, ve (f) 8-QAM ve (g) 16-QAM işaretlerinin yıldız diyagramları.



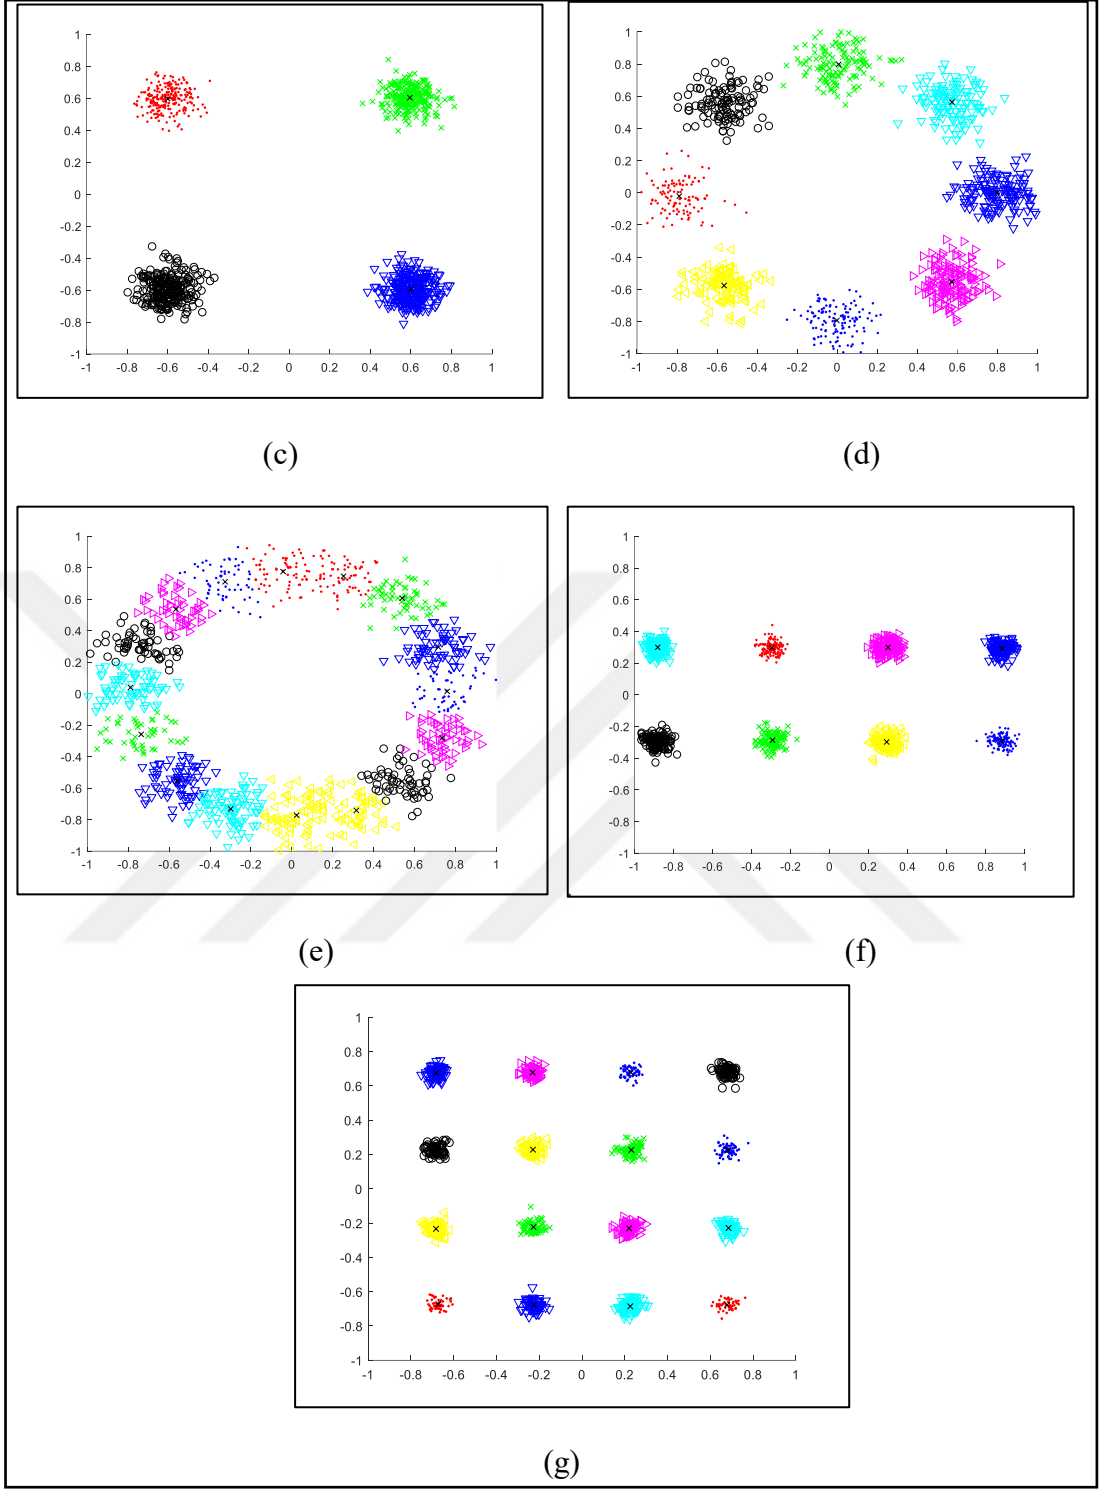
Şekil 4.6. (a) BPSK, (b) 4-PSK, (c) QPSK, (e) 16-PSK, (f) 8-QAM ve (g) 16-QAM işaretlerinin K-Ortalama yöntemi ile kümelenmesi SNR = 5 dB.



Şekil 4.6. (Devam) (a) BPSK, (b) 4-PSK, (c) QPSK, (e) 16-PSK, (f) 8-QAM ve (g) 16-QAM işaretlerinin K-Ortalama yöntemi ile kümelmesi SNR = 5 dB.



Şekil 4.7. (a) BPSK, (b) 4-PSK, (c) QPSK, (d) 8-PSK, (e) 16-PSK, (f) 8-QAM ve (g) 16-QAM g işaretlerinin K-Ortalama yöntemi ile kümelmesi SNR = 15 dB.




Şekil 4.7. (Devam) (a) BPSK, (b) 4-PSK, (c) QPSK, (d) 8-PSK, (e) 16-PSK, (f) 8-QAM ve (g) 16-QAM g işaretlerinin K-Ortalama yöntemi ile kümelmesi SNR = 15 dB..

4.2.4. K-Ortalama modülasyon sınıflandırma sisteminin sınıflandırma başarımları oranları

K-Ortalama modülasyon sınıflandırma sistemi SNR 0-30 dB aralığındaki sentetik işaretler ile test edilerek farklı modülasyonlar için sınıflandırma başarımları Şekil 4.8'deki gibi elde edilmiştir.

K-Ortalama temelli modülasyon sınıflandırıcısının SNR değerlerine göre sınıflandırma başarımları hesaplanmıştır. Elde edilen hesaplamalara göre SNR'nin artması ile işaretlerin modülasyon tipi ve derecesinin tespitinin kolaylaştığı gözlenmiştir. SNR değerinin yükselmesinin işareti daha net bir yıldız diyagramına sahip olmasını sağlayacağından işaretlerin sınıflandırılmaları da kolaylaşmaktadır. Elde edilen sonuçlardan çıkan başka bir sonuç da modülasyon sınıflandırması için modülasyon derecesinin artması ile modülasyon sınıflandırma zorlaşmaktadır. Buna istisna olarak 16-QAM verilebilir. Bunun sebebi ise 16-QAM işaretlerin kümelendiği noktaların diğer modülasyonlara göre daha farklı kümelenmesidir. Özellikle 8-QAM modüledi işaretlerin yüksek gürültü şartlarında yıldız diyagramı şekillerinin BPSK işaretlere benzemesinden dolayı karışması söz konusu olmaktadır.

K-Ortalama modülasyon sınıflandırıcı sistemin karıştırma matrisi de hesaplanmıştır. Karıştırma matrisi bir sınıflandırma sisteminde sınıflandırma sonucu ile gerçek



Şekil 4.8. K-Ortalama Temelli PSK/QAM Modülasyon Sınıflandırıcısının SNR'ye karşı sınıflandırma başarımları.

sınıfların karşılaştırıldığı matristir. Tablo 4.2’de görüldüğü gibi birbirlerine karıştırılan modülasyon seviye ve tiplerinden en çok karıştırılan modülasyonun 16-PSK ve ardından 16-QAM olduğu görülmektedir. Bunun sebebi ise modülasyon derecesinin yüksek olmasından dolayı işaretin daha kolay bozulmasıdır. Algoritma, yıldız diyagramı şeklindeki noktaların genliği ve açılarını kullandığı için gürültü durumunda sembollerin birbirlerine karışma ihtimali artmaktadır. Bu yüzden, modülasyon derecesinin artması, modülasyon sınıflandırmayı zorlaştırmaktadır. K-Ortalama modülasyon sınıflandırma sisteminin sınıflandırma başarımları 10 dB SNR’de üretilen test işaretleri için ortalama %73,4 sınıflandırma başarımları elde edilmiştir.

Tablo 4.2. SNR’si 10 dB AWGN kanaldan iletilen test işaretleri için K-Ortalama modülasyon sınıflandırma başarımlarının karıştırma matrisi sonuçları (%).

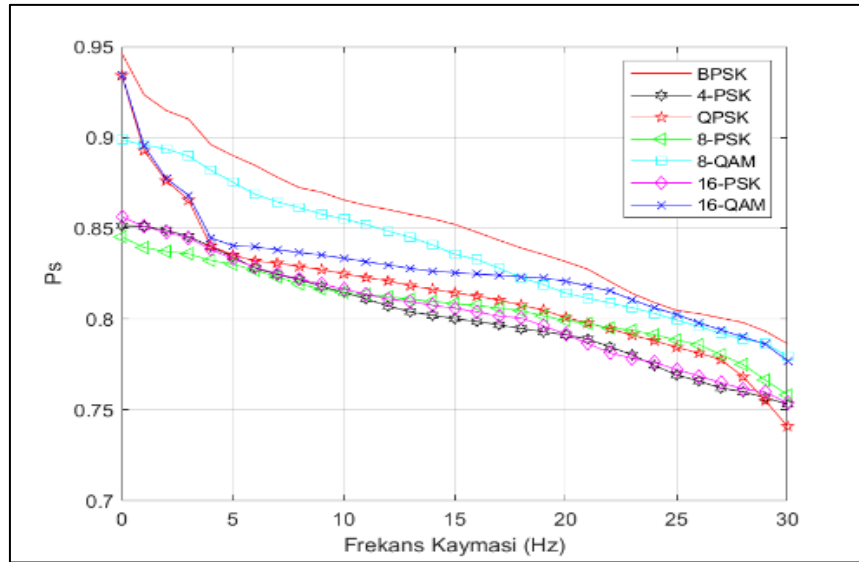
		BPSK	4-PSK	QPSK	8-PSK	16-PSK	8-QAM	16-QAM
Gerçek Sınıf	BPSK	0,89	0,01	0	0	0	0,05	0
	4-PSK	0,01	0,85	0,01	0,01	0	0	0,02
	QPSK	0	0,01	0,89	0	0	0	0
	8-PSK	0,01	0,13	0,07	0,75	0,11	0,1	0,01
	16-PSK	0,03	0,04	0,06	0,04	0,40	0,2	0,02
	8-QAM	0,07	0	0	0,09	0,06	0,72	0,01
	16-QAM	0,1	0	0,08	0,12	0,08	0	0,60
		Tahmin Edilen Sınıf						

Tablo 4.3. SNR’si 20 dB AWGN kanaldan iletilen test işaretleri için K-Ortalama modülasyon sınıflandırma başarımlarının karıştırma matrisi sonuçları (%).

		BPSK	4-PSK	QPSK	8-PSK	16-PSK	8-QAM	16-QAM
Gerçek Sınıf	BPSK	0,97	0,01	0	0,02	0	0,13	0
	4-PSK	0	0,95	0,01	0,01	0	0,02	0,02
	QPSK	0	0,01	0,93	0	0	0,01	0
	8-PSK	0	0,03	0,07	0,95	0,06	0	0,01
	16-PSK	0	0,02	0,06	0,02	0,60	0	0,02
	8-QAM	0,02	0	0	0	0,12	0,84	0,01
	16-QAM	0,01	0	0,05	0,07	0,06	0	0,8
		Tahmin Edilen Sınıf						

Tablo 4.2 ve Tablo 4.3'deki sistemin karıştırma matrisinde görüldüğü üzere BPSK ile 8-QAM işaretlerin birbirlerine önemli ölçüde karıştırılmaktadır. Bu durumun sebebi ise düşük SNR değerlerinde BPSK işaretlerin yıldız diyagramlarının 8-QAM işaretlerin yıldız diyagramlarına benzemesidir. 8-QAM'in dikdörtgen şekle sahip olması, düşük SNR'de BPSK'ye benzemesine yol açmaktadır. Benzer şekilde 4-PSK'nın 16-PSK işaretler ile karıştırıldığı görülmüştür. Bunun sebebi ise düşük SNR'de 4 ve 16-PSK işaretlerin benzer dairesel yıldız diyagramına sahip olmasıdır. Karıştırma matrisinden elde edilebilecek bir başka sonuç, QPSK işaretlerin 16-QAM işaretler ile yüksek oranda karışma oranına sahip olmasıdır. Bu karışma durumunun sebebi ise QPSK ile 16-QAM'in benzer karesel yıldız diyagramına sahip olmasıdır. Bu yüzden K-Ortalama kümeleri, birbirlerine çok yakın bulunmaktadır.

K-Ortalama sisteminin 0-30 Hz aralığında frekans kayması için sınıflandırma başarımı AWGN kanaldan alınan işaretler için Şekil 4.9'da gösterilmiştir. Artan frekans kayması ile sistemin sınıflandırma başarımlarının düştüğü görülmektedir. Frekans kayması ile tüm modülasyon tipleri için sınıflandırma başarımında yaklaşık %5 düşüş olmuştur. Frekans kaymasının artmasıyla işaretin fazı değişmektedir; dolayısıyla yıldız diyagramlarında bozulmalar gerçekleşmektedir. Şekil 4.9'a göre PSK modülasyonun QAM modülasyona kıyasla frekans kayması ile sınıflandırma başarımının daha fazla düştüğü görülmektedir. Bunun sebebi ise frekans kayması ile



Şekil 4.9. K-Ortalama Temelli PSK/QAM Modülasyon Sınıflandırıcısının merkez frekansı $f_c = 100$ Hz için frekans kaymasına karşı sınıflandırma başarımı.

faz deęerinin deęişmesidir. Bu yüzden PSK modüleli işarelerin yüksek frekans kayması ile sınıflandırılması zorlaşmaktadır.

4.3. Derin Öğrenme Ağı ile Modülasyon Sınıflandırma Sistemi

CR ağının bünyesinde sınıflandırıcı modülü görevini yapan derin öğrenme ağı çok sayıda gizli katmana sahip konvolüsyonel sistemde sınıflandırma görevini gerçekleştirmektedir.

4.3.1. CNN

Son zamanlarda görüntü işleme, medikal uygulamalar, yüz tanıma, ses sınıflandırma, nesne tespiti gibi alanlarda sıklıkla kullanılan CNN, veri tipi ızgara düzene sahip olan sinir ağlarını işlemek için kullanılan bir yapay sinir ağı türüdür [41]. Konvolüsyonel sinir ağlarında kullanılan ızgara yapısına sahip olan verilere tek boyutlu zaman serisi verileri ve iki boyutlu görüntü verileri örnek gösterilebilir. Bu sistemlerde kullanılan konvolüsyonel sinir ağlarının diğer makine öğrenme türlerine kıyasla önemli ölçüde başarılı olduğu görülmüştür [42]. Konvolüsyonel sinir ağlarında kullanılan konvolüsyon işlemi özelliklerin çıkarılmasında görev almaktadır [42]. Özellik çıkarımı ise düşük düzey, orta düzey ve yüksek düzey olarak üç düzeyde çıkartılmaktadır [43].

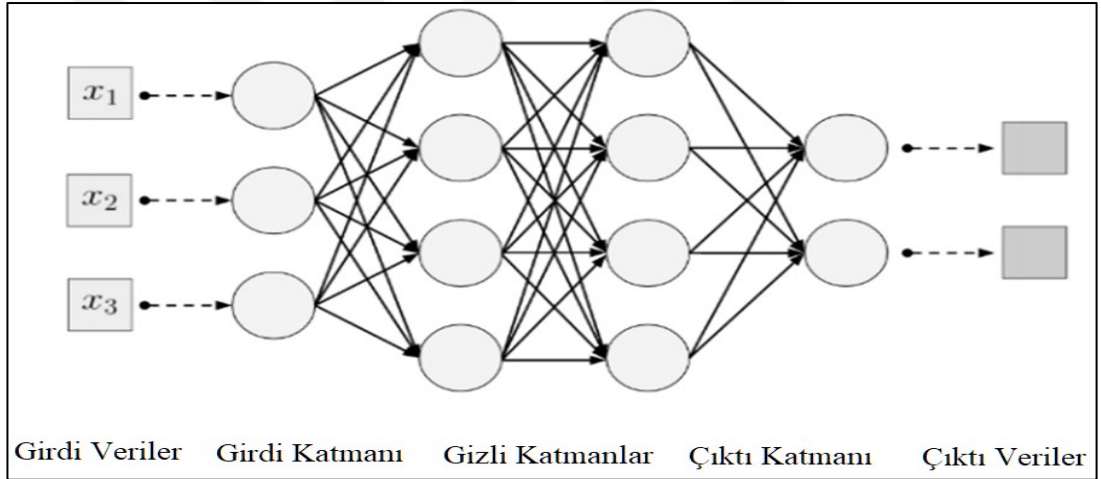
4.3.2. Derin öğrenme

Derin öğrenme bir makine öğrenmesi yöntemidir. Bilgisayarların insana bezer bir şekilde hiyerarşik bir şekilde düzenlenmiş kavramlardan yararlanarak öğrenmesine dayalıdır [44].

Derin öğrenme, diğer makine öğrenme yöntemlerinin aksine özellik çıkarma özelliğine sahiptir [45]. Özellik çıkartma ise kullanımda olan veri setinin içinde hangi özelliklerin kullanılacağına karar verme yeteneğidir. Diğer makine öğrenmesi uygulamalarında bu yöntem, sistemin tasarımcısının veri setini inceleyerek veri setinin içindeki uygun özellikleri tespit etmesi ile gerçekleştirilmektedir [46]. Derin öğrenme algoritmalarında özellik çıkartma otomatik olarak gerçekleştirilmektedir.

4.3.3. Derin öğrenme ağının tasarımı

Tezde 24 katmana sahip bir konvolüsyonel derin öğrenme ağı kullanılmaktadır [47]. Sistemin derin öğrenme ağı Şekil 4.10'da gösterilmiştir. Ağın girdileri BK ve İK'lerin IQ işaretlerinin yıldız diyagramları, çıktıları modülasyon isimlerini belirten etiketlerdir. Verilen ağda, eğitim için, 1024x2 boyutunda IQ işareti ve IQ işaretin sınıfı kullanılmaktadır. Derin öğrenme ağının katmanları, Tablo 4.3'te gösterilmiştir. Ağ, verilen görüntüsüne göre işareti eğitim sırasında üretilmiş olan görüntülerine bağlı olarak sınıflandırmaktadır [48]. Sistemde IQ işaretlerin yıldız diyagramlarının görüntülerinin kullanılmasının sebebi ise derin öğrenme uygulamalarında kullanılan görüntü işleme algoritmalarının katkıları ile sistemin eğitim ve sınıflandırma süreçlerindeki sınıflandırma başarımını artırmaktır [49].



Şekil 4.10. Derin öğrenme ağı diyagramı.

4.3.4 Derin öğrenme ağının kullanımı

Eğitilmiş derin öğrenme ağı, spektrum dağıtıcısının bünyesinde var olan spektrum bantlarının dağıtılması amacıyla Tablo 4.3'teki gibi ağın katmanlarındaki adımları gerçekleştirmektedir. İşaretler birincil ve ikincil baz istasyonlarından alınmaktadır. Sıfır merkez frekansta işaret bant geçirici filtrelerden geçirilerek kullanımda olan CR protokolünün gerektirdiği bant genişliğinde filtrelenmektedir. Filtrelenmiş bantlardaki işaretler derin öğrenme ağında sınıflandırılmaktadır. Sınıflandırma sonucunda işaretler, BK veya İK'ye ait işaret olarak iki gruba ayrılmaktadır.

4.3.5. Derin öğrenme ağının katmanları

Derin öğrenme ağı çok sayıda katmandan oluşmaktadır. Ağ, görüntü işleme yeteneğinden faydalanmak amacıyla Tablo 4.1'deki özelliklere sahip 1024x2 IQ işareti alınmaktadır ve modülasyon tipi çıkış olarak verilmektedir. Ağın katmanları Tablo 4.3'te, parametreleri ise Tablo 4.4'teki gibidir. Sistemin eğitim süreci boyunca katmanların ağırlıkları, konvolüsyon filtreleri alınan sonuçlara göre derin öğrenme ağı tarafından iyileştirilmektedir. Katsayıların iyileştirilmesi için Adam algoritması kullanılmıştır. Adam algoritması pratikte diğer optimizasyon algoritmalarına kıyasla literatürde çok boyutlu veri setlerinde daha yaygın bir şekilde kullanıldığı için tercih edilmiştir [41].

4.3.6. Derin öğrenme ağının eğitim süreci

Derin öğrenme ağının eğitimi için kullanılan veriler; BK işaretleri ve İK işaretleridir. Üretilen IQ işaretleri sistemin eğitim verileri olarak kullanılmıştır. Sistemin eğitimi sürecinde aşırı öğrenme problemi ile karşılaşmamak için birer saat uzunluğunda, birer saniye uzunluğunda IQ işaretler Şekil 4.3'te sunulan yapı ile üretilmiştir. İlk olarak rastgele bitler üretilmektedir. Semboller verilen modülasyon tipleri ve dereceleri için modüle edilmektedir. Elde edilen işaretin örnekleri öğrenme sürecinin iyileştirilmesi amacıyla rastgele sırada karıştırılmaktadır. Modüle edilmiş işaretler, darbe şekillendirme filtresinden geçirilmektedir. İşaretler Rayleigh, Nakagami ve Rician sönümleme kanalından geçirilerek sönümlendirilmektedir. İşaretlere sembol gecikmesi ve çoklu yol etkileri eklenerek modüle edilmiş işaretlere kanal etkisi uygulanmıştır. En son olarak sıfır ortalamalı Gauss gürültüsü eklenmektedir.

Sistemi eğitmek için eğitim veri seti boyutu hesaplanmaktadır ve modülasyon tiplerine göre isimlendirilmektedir. Test, onaylama ve derin öğrenme ağının ayarlanması amacıyla BK ve İK işaretlerinin toplamından %60'ı eğitim veri seti, %20'si onaylama veri seti ve %20'si test veri seti olarak veri setleri oluşturulup onaylama ve test veri setleri eğitim dışı tutularak yalnızca onaylama ve test amacıyla kullanılmıştır. Eğitim sürecinde onaylama işlemi eğitim sırasında her yinelemede bir gerçekleştirilmektedir. Bunun sebebi ise onaylama sınıflandırma başarımlarını hesaplamak ve bu değeri eğitim sınıflandırma başarımları ile karşılaştırarak, aşırı veya az öğrenme olup olmadığı tespit edilerek, parametreleri ayarlanarak derin öğrenme ağının

düzeltilmesidir. Eğitim sürecince onaylama verisi kullanılarak sistemin sınıflandırma başarımları hesaplanmaktadır ve eğitim veri seti kullanılarak elde edilmiş olan sınıflandırma başarımları değerleri ile karşılaştırılarak ağın parametreleri düzenlenmektedir. Eğitim veri setinin sınıflandırma başarımları değerleri ile onaylama veri setinin sınıflandırma başarımlarının değerlerinin arasındaki farkın büyük olması derin öğrenme ağının ayarlanması gerektiğine işaret etmektedir. İşaretlerin SNR'sinin düşük olması, veri setinin büyüklüğünün yetersiz olması gibi sebepler sistemin sınıflandırma başarımlarının düşük olmasına sebep olmaktadır. Bu problemlere çözüm olarak eğitim sınıflandırma başarımları ve onaylama sınıflandırma başarımlarının takip edilmesi bu parametrelerin ideal aralıklarının bulunmasını sağlamaktadır. Derin öğrenme ağını her yinelemede onaylayabilmek için Tablo 4.4'teki gibi 1024 tane örnek Tablo 4.1'de gösterildiği gibi hazırlanmıştır. Bunların üzerine arka plan gürültüsü de onaylama ve test amacıyla hazırlanmıştır. Bu veriler tabloda verilen sayıda örnek sayısının parçalara ayrılarak farklı gürültü, zamanlama kayması ve çoklu yol etkisi uygulanmıştır. Bu veriler eğitim sürecinden ayrı tutularak yalnızca onaylama ve test amacıyla kullanılmıştır.

4.3.7. Derin öğrenme ağı girdileri

Derin öğrenme ağını eğitmek için IQ işaretlerin yıldız diyagramları kullanılmaktadır. Eğitim için verilen BK ve İK işaretleri alınarak derin öğrenme ağına verilmiştir. Derin öğrenme ağına girdi olarak işaretin yıldız diyagramının kullanılması sebebi ise işaretin frekans düzlemine taşınması durumunda faz bilgisinin kaybedilmesidir. Tezdeki modülasyon tiplerinden birinin de PSK olmasından dolayı frekans düzlemi yerine zaman düzleminde işaretler alınmıştır. Sınıflandırma başarımlarını hesaplamak için test ve onaylama için ayrı IQ işaretler hazırlanmıştır. Test ve onaylama işaretleri BK ve İK işaretlerinden oluşmaktadır ve Tablo 4.3'te belirtilen özelliklere ve uzunluğa sahiptir. Eğitim sürecinde bir yineleme 100 iterasyonda gerçekleşmektedir. Yinelemelerin sayısı ise deneme yanılma yoluyla sınıflandırma başarımlarının yükselme oranına göre ve onaylama işaretinin sınıflandırma başarımlarına göre seçilmiştir. Onaylama işaretinin sınıflandırma başarımlarının yaklaşık 25 yinelemeden sonra yakınsamasından dolayı eğitim yineleme sayısında gerçekleştirilmiştir. Eğitim Tablo 4.3'te verilen parametrelere göre gerçekleştirilmiştir. Eğitim sürecinin tamamlanmasının ardından test işaretleri ile ağ test edilmiştir. Test

sürecinin tamamlanmasının ardından test sonuçlarından ağın sınıflandırma başarımları elde edilmiştir. Derin öğrenme ağına eğitimi sürecinde örnek çeşitliliğini sağlamak için işaret tabloda verilen sayıdaki örnekler sayısında parçalara ayrılmıştır.

Tablo 4.4. Derin öğrenme ağına katmanları.

Katman Numarası	Katman İçeriği
1	Girdi katmanı (IQ işaretin yıldız diyagramı görüntüsü)
2	Konvolüsyon 2D katmanı (Filtre boyutu:3, Filtre sayısı:12)
3	Batch normalizasyon katmanı
4	Relu katmanı
5	Max pooling 2D katmanı (Havuz boyutu: 3, Stride uzunluğu: 2)
6	Konvolüsyon 2D katmanı (Filtre boyutu: 3, Filtre sayısı:24)
7	Batch normalizasyon katmanı
8	Relu katmanı
9	Max pooling 2D katmanı (Havuz boyutu: 3, Stride uzunluğu: 2)
10	Konvolüsyon 2D katmanı (Filtre boyutu: 3, Filtre sayısı: 48)
11	Batch normalizasyon katmanı
12	Relu katmanı
13	Max pooling 2D katmanı (Havuz boyutu: 3, Stride uzunluğu: 2)
14	Konvolüsyon 2D katmanı (Filtre boyutu: 3, Filtre sayısı: 48)
15	Batch normalizasyon katmanı
16	Relu katmanı
17	Konvolüsyon 2D katmanı (Filtre boyutu: 3, Filtre sayısı: 48)
18	Batch normalizasyon katmanı
19	Relu katmanı
20	Max pooling 2D katmanı (Havuz boyutu: [1 13], Stride uzunluğu: [1 1])
21	Dropout katmanı (Dropout olasılığı: 0,2)
22	Tam birleşme katmanı (Sınıf sayısı: 3)
23	Softmax katmanı
24	Ağırlıklandırılmış sınıflandırma katmanı

Sistemde işaretler Tablo 4.4'te verildiği gibi 1024 örneğe sahiptir. Seçilen parametreler bu durum için sınıflandırma başarımları en yüksek olacak şekilde tercih edilmiştir. Bu durumda işaret uzunluğu artırılarak sistemin sınıflandırma başarımları artırılabilir ancak bu yüksek işlem gücü ve bellek gerektirmektedir.

4.3.8. Derin öğrenme ağına sınıflandırma başarımları sonuçları

Derin öğrenme ağına 25 yineleme uzunluğundaki eğitim süreci ile verileri sınıflandırma yeteneği kazandırılmıştır. Derin öğrenme ağına modülasyon tanıma sistemi iki ayrı şekilde eğitilmiş ve test edilmiştir. İlkinde derin öğrenme ağı ile 0-30 dB arası SNR değerlerinde AWGN kanaldan alınan işaretler ile eğitilmiş ve bu özelliğe sahip 10 dB işaretler ile test edilerek her modülasyon tipi ve derecesinde verilen SNR değerleri için sınıflandırma başarımları ve karıştırma matris sonuçları elde

Tablo 4.5. Derin öğrenme modülasyon sınıflandırma sistemi parametreleri.

Özellik	Değer
Derin öğrenme ağının sınıfları	2-PSK, 4-PSK, QPSK, 8-PSK, 16-PSK, 8-QAM, 16-QAM
K-Ortalama K değeri	{2, 4, 8, 16}
Sembol uzunluğu Ts (saniye)	0,008
BK bit uzunluğu Tb (saniye)	0,002
İK bit uzunluğu Tb (saniye)	0,004
Örnekleme frekansı (Hz)	8000
Baud oranı (saniye başına sembol)	125
Eğitim IQ işaretinin uzunluğu, tüm sınıflar için (dakika)	60
Onaylama IQ işaretinin uzunluğu (dakika)	20
Test IQ işaretinin uzunluğu (dakika)	20
Rayleigh sönümlenmeli kanal skala parametresi	0,5
İşaret gürültü oranı (dB)	[0,30]
Derin öğrenme ağı girdi veri boyutu	256x256
Çerçeve uzunluğu (örnek)	1024
Atlama uzunluk oranı	0,01
Piksel derinliği (bitler)	16
Derin öğrenme filtre sayısı	24 ve 48
Derin öğrenme filtre boyutu	3
Max pooling havuz boyutu	3 ve 13
Dropout olasılığı	0,2
Derin öğrenme optimizasyon algoritması	Adam
Mini batch boyutu	128
Başlangıç öğrenme oranı	0,0003
Yineleme sayısı	25
Öğrenme oranı dropout faktörü	0,1
Öğrenme oranı dropout periyodu (iterasyon)	20

edilmiştir. İkinci sistemde ise derin öğrenme ağına Rayleigh, Nakagami-m ve Rician kanaldan geçirilmiş AWGN gürültü eklenmiş işaretler verilmiştir. Bu üretilen sönümleme kanallı işaretler ile derin öğrenme ağı eğitilmiş, aynı özelliğe sahip işaretler ile onaylanmış ve bu kanaldan geçmiş işaretler ve test edilmiş işaretler ile sınıflandırma başarımları, karıştırma matrisi çıktıları elde edilmiştir. Sonuç olarak AWGN kanalından alınan test işaretleri için BPSK, QPSK, 4-PSK, 8-PSK, 16-PSK ve 4-QAM, 8-QAM, 16-QAM için %85,8, onaylama sınıflandırma başarımları %85,3 elde edilmiştir. Sönümlenmeli kanallı test işaretleri ile %68,3 test sınıflandırma başarımları ve onaylama sınıflandırma başarımları %68,0 olarak elde edilmiştir.

4.3.9. AWGN kanalından alınan işaretler ile eğitilen derin öğrenme ağının karıştırma matrisi

Karıştırma matrisi tasarlanmış olan bu derin öğrenme ağında ise AWGN kanalından geçmiş, verilen modülasyonlara sahip işaretlerin modülasyonlarını sınıflandırma yeteneğini tespit etmek için hesaplanmıştır. Modülasyon dereceleri ve modülasyon tipleri için birbirlerine karıştırma oranları hesaplanmıştır. Doğru sınıflandırma başarımının sırasıyla BPSK, 8-QAM, 16-QAM için yapıldığı karıştırma matrisi Tablo 4.5'te görülmektedir.

Tablo 4.6. SNR'si 10 dB AWGN kanalda iletilen test işaretleri için derin öğrenme ağı tabanlı modülasyon sınıflandırma başarımının karıştırma matrisi sonuçları (%).

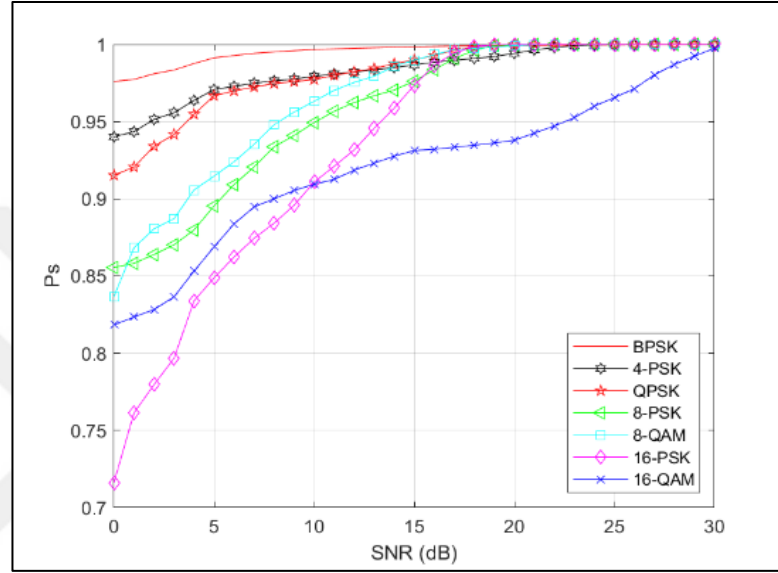
		BPSK	4-PSK	QPSK	8-PSK	16-PSK	8-QAM	16-QAM
Gerçek Sınıf	BPSK	0,97	0,01	0	0	0	0,01	0,01
	4-PSK	0,01	0,98	0,01	0,01	0	0	0,01
	QPSK	0	0,01	0,98	0,01	0,01	0,01	0,02
	8-PSK	0	0	0	0,97	0,01	0,02	0,01
	16-PSK	0	0	0,01	0,01	0,98	0,01	0
	8-QAM	0,02	0	0	0	0	0,98	0
	16-QAM	0	0	0,01	0	0	0	0,99
Tahmin Edilen Sınıf								

Tablo 4.7. SNR'si 20 dB AWGN kanalda iletilen test işaretleri için derin öğrenme ağı tabanlı modülasyon sınıflandırma başarımının karıştırma matrisi sonuçları (%).

		BPSK	4-PSK	QPSK	8-PSK	16-PSK	8-QAM	16-QAM
Gerçek Sınıf	BPSK	1	0	0	0	0	0	0
	4-PSK	0	1	0	0	0	0	0
	QPSK	0	0	0,99	0	0	0	0,01
	8-PSK	0	0	0	0,99	0,01	0	0
	16-PSK	0	0	0	0,01	0,99	0	0
	8-QAM	0	0	0	0	0	1	0
	16-QAM	0	0	0	0	0	0	0,99
Tahmin Edilen Sınıf								

Bu matriste satırlar gerçek sonuçları, sütunlar ise tahmin edilen sonuçları göstermektedir. Aynı sınıfa ait satır ve sütunların kesiştiği gir renkle gösterilen matris elemanı doğru sınıflandırma yüzdesinin göstermektedir.

Derin öğrenme ağlarından AWGN kanalından geçmiş işaretlerle eğitilmiş olan ağ, üretilen 0-30 dB aralığındaki SNR değerlerindeki işaretler ile test edilmiş ve elde edilen karıştırma matrisi ile hangi modülasyon derecesi ve modülasyon tiplerinin birbirleri ile karıştırılma oranları elde edilmiştir. Değişen SNR değerleri için ise sistemin sınıflandırma başarımları her modülasyon tipi ve derecesi için hesaplanarak Şekil 4.9’da sunulmuştur. Benzer olarak alıcı verici arasında oluşabilecek olası frekans




Şekil 4.11. AWGN kanaldan alınan işaretler ile eğitilmiş derin öğrenme ağının değişen modülasyon tipi, modülasyon dereceleri ve SNR değerleri için modülasyon sınıflandırma başarımları.

kayma değerleri durumunda sınıflandırma başarımları da AWGN kanalda iletilmiş işaretler için Şekil 4.12’de, sönmlemeye maruz kalan işaretler için Şekil 4.14’te yer almaktadır.


Elde edilen SNR- sınıflandırma başarımları hesaplamalarına göre modülasyon derecesinin artması genellikle modülasyon sınıflandırmasını zorlaştırmaktadır. Bunun sebebi ise artan modülasyon derecesi ile sınıflandırmanın zorlaşmasıdır. İşaretin bozulması sonucunda yıldız diyagramı şekillerinde bozulma kolaylaşmaktadır. AWGN kanaldan alınan işaretler için modülasyon sınıflandırma başarımları genel olarak sönmlemeye maruz kalan işaretlerden alınan sınıflandırma başarımlarına kıyasla daha yüksek olduğu gözlemlenmektedir. Bunun sebebi ise derin öğrenme ağının yalnızca AWGN kanaldan alınan işaretler ile eğitilmesi ve yalnızca AWGN kanaldan alınan

işaretler ile test edilmesidir. Elde edilen SNR-sınıflandırma başarımları eğrilerine göre sönümlenmeli kanallı sisteme kıyasla önemli derecede sınıflandırma başarımlarında genel bir yükselme görülmektedir. AWGN kanaldan alınan işaretlerin modülasyonlarını sınıflandırmanın daha kolay olduğu daha düşük SNR değerlerinde dahi yüksek sınıflandırma başarımları elde edildiği görülmektedir. AWGN kanaldan alınan işaretin modülasyon sınıflandırma başarımlarının düşük modülasyon dereceleri için SNR 3 dB ve yüksek modülasyon dereceleri için ise SNR 6 dB'ye kadar yükseldiği ve yüksek devam ettiği görülmektedir. Sönümlenmeli kanala maruz kalan modüleli işaretler için 0- 30 dB arası SNR için sınıflandırma başarımları Şekil 4.13'te görülmektedir. Derin öğrenme ağı modülasyon sınıflandırma sisteminin 0-30 Hz arası frekans kayması için sınıflandırma başarımları hesaplanmıştır ve AWGN kanaldan alınan işaretler için Şekil 4.12'de, sönümlenmeli kanala maruz kalan modüleli işaretler için Şekil 4.12'de gösterilmiştir. AWGN ve sönümlenmeli kanala maruz kalan modüleli işaretler kanalları için 10 Hz frekans kayması ile tüm modülasyon türleri için sınıflandırma başarımlarında %2 azalma görülmüştür. Frekans kaymasından dolayı sınıflandırma başarımları en fazla düşen modülasyon tipinin QPSK olduğu görülmüştür. Bunun sebebi ise QPSK modülasyonunun frekans kayması durumunda yıldız diyagramının BPSK, 4-PSK, 8-PSK ve 16-PSK ile karışmasıdır. AWGN kanaldan alınan işaretlerde frekans kaymasının modülasyon sınıflandırmaya olan etkisinin BPSK ve 8-QAM modülasyonlarda yüksek olduğu görülmektedir. Bunun sebebi ise BPSK ile 8-QAM modüleli işaretlerin yüksek gürültü şartlarında yıldız diyagramlarının birbirlerine benzemesidir. Benzer şekilde QPSK ile 4-PSK modülasyonlarının yüksek frekans kaymasında yıldız diyagramları dönmektedir ve sınıflandırıcı sisteminde birbirleriyle karışmaktadır. Bu yüzden bu iki modülasyon sınıfı, diğer modülasyonlara kıyasla frekans kaymasından daha fazla etkilenmektedir. Sönümlenmeli kanala maruz kalan modüleli işaretler için frekans kayması ile yıldız diyagramının dönmesinden dolayı PSK modüleli işaretler, sınıflandırmada birbirlerine karıştırılmaktadır. Sönümlenmeli kanala maruz kalan modüleli işaretler, işaretin fazının

frekans kaymasından dolayı bozulmasından dolayı modülasyon derecesiyle frekans kaymasının sınıflandırma başarımı doğru orantılı olduğu görülmektedir.



Şekil 4.12. AWGN kanaldan alınan işaretlerde işaretleri ile eğitilmiş derin öğrenme ağının merkez frekansı $f_c = 100$ Hz için değişen modülasyon tipi, modülasyon dereceleri ve frekans kayması değerleri için modülasyon sınıflandırma başarımı (SNR = 10 dB).



Şekil 4.13. Sönümlenmeye maruz kalan modüleli işaretler ile eğitilmiş derin öğrenme ağının $f_c = 100$ Hz için değişen modülasyon tipi, modülasyon dereceleri ve SNR değerleri için modülasyon sınıflandırma başarımı (SNR = 10 dB).

4.3.10. Sönümlenmeli kanala maruz kalan modüleli işaretler ile eğitilen derin öğrenme ağının karıştırma matrisi

Rayleigh, Nakagami-m ve Rician sönümlenmeli kanala maruz kalan modüleli işaretler ile eğitilmiş derin öğrenme ağının test verileri ile hangi oranda birbirlerine karıştırıldığı hesaplanarak matris olarak karıştırma matrisi hesaplanmıştır. Doğru sınıflandırma başarımlarının sırasıyla BPSK, 8-QAM, 16-QAM için yapıldığı karıştırma matrisi Tablo 4.8 ve Tablo 4.9'dan görülmektedir. Sönümlenmeli kanala maruz kalan işaretler için sınıfların birbirlerine AWGN kanaldan alınmış işaretler ile eğitilmiş derin öğrenme ağına kıyasla daha fazla birbirine karıştırıldığı ve sınıflandırma başarımlarının daha düşük olduğu gözlemlenmektedir.

Tablo 4.8. SNR'si 10 dB sönümlenmeli kanalda iletilen test işaretleri için derin öğrenme ağı tabanlı modülasyon sınıflandırma başarımının karıştırma matrisi sonuçları (%).

	Modülasyon	BPSK	4-PSK	QPSK	8-PSK	16-PSK	8-QAM	16-QAM
Gerçek Sınıf	BPSK	0,89	0,01	0,02	0,03	0,02	0,01	0,01
	4-PSK	0,03	0,91	0,01	0,01	0,01	0,01	0,01
	QPSK	0,031	0,01	0,89	0,03	0,02	0,01	0,02
	8-PSK	0,02	0,02	0,01	0,91	0,01	0,01	0,01
	16-PSK	0,01	0,01	0,01	0,01	0,97	0,01	0
	8-QAM	0,01	0,02	0,01	0,01	0,02	0,94	0
	16-QAM	0	0	0,01	0,09	0,01	0,01	0,97
Tahmin Edilen Sınıf								

Tablo 4.9. SNR'si 20 dB sönümlenmeli kanalda iletilen test işaretleri için derin öğrenme ağı tabanlı modülasyon sınıflandırma başarımının karıştırma matrisi sonuçları (%).

	Modülasyon	BPSK	4-PSK	QPSK	8-PSK	16-PSK	8-QAM	16-QAM
Gerçek Sınıf	BPSK	0,98	0,01	0	0	0,01	0	0,01
	4-PSK	0,01	0,96	0	0	0	0	0
	QPSK	0,01	0	0,96	0,02	0	0	0
	8-PSK	0	0,01	0	0,94	0	0,01	0
	16-PSK	0	0,01	0,01	0	0,98	0,01	0
	8-QAM	0	0,02	0,01	0	0,01	0,95	0
	16-QAM	0	0	0	0,02	0	0	0,99
Tahmin Edilen Sınıf								


Sınıflandırma başarımlarının sönümlenmeye maruz kalan işaretler için AWGN kanaldan alınan işaretlere göre daha düşük olmasının sebebi ise kanal sönümlenmeli kanalda iletilen işaretleri AWGN'ye kıyasla daha çok bozması ve yıldız diyagramını döndürmesinden kaynaklanmaktadır. Tezdeki sistemlerin literatürdeki sistemlerle

karşılaştırması Tablo 4.10’da sunulmuştur. Rayleigh, Nakagami-m ile Rician kanallar ile sönümlenmiş işaretler ile eğitilmiş derin öğrenme ağının sönümlenmeli kanalarda iletilen 0-30 dB arası SNR’si olan işaretler ile sınıflandırma başarımları sistem test edilerek hesaplanmıştır ve ’da gösterilmiştir. Düşük modülasyon dereceleri için sınıflandırma başarımları daha yüksektir ve SNR 5 dB ve üzerinde sınıflandırma başarımlarının artışı diğer SNR değerlerine kıyasla daha yüksektir. Yüksek modülasyon derecelerinde ise sınıflandırma başarımları artan SNR değerleri ile daha az bir şekilde artmaktadır. Elde edilen SNR sınıflandırma başarımları eğrilerine göre sönümlenmeli kanaldan iletilen işaretler ile eğitilen sisteme kıyasla önemli derecede sınıflandırma başarımlarında genel bir yükselme görülmektedir. AWGN kanalında sınıflandırmanın daha kolay olduğu daha düşük

SNR değerlerinde daha yüksek sınıflandırma başarımları elde edildiği görülmektedir. AWGN kanalından alınan işaretler için sınıflandırma başarımlarının düşük modülasyon dereceleri için SNR = 3 dB ve yüksek modülasyon dereceleri için ise SNR = 6 dB’ye kadar yükseldiği ve yüksek devam ettiği görülmektedir.

4.4. Modülasyon Sınıflandırma Sistemlerinin Sonuçları

Bu tezde iki modülasyon sınıflandırma sistemi geliştirilmiştir. İlk sistemde K-Ortalama algoritması kullanılarak sistem tasarlanmış ve sınıflandırma başarımları 0-30 dB arası SNR için ve 0-30 Hz arası frekans kayması için elde edilmiştir. AWGN



Şekil 4.14. Sönümlenmeye maruz kalan modüleli işaretler ile eğitilmiş derin öğrenme ağının değişen modülasyon tipi, modülasyon dereceleri ve frekans kayması değerleri için modülasyon sınıflandırma başarımları (SNR = 10 dB).

kanaldan alınmış işaretler ile SNR = 10 dB için ortalama %72 sınıflandırma başarımı elde edilmiştir. Literatürdeki sistemlerden [9] ve [11]'den daha yüksek performans elde edilmiştir. İkinci sistem olarak ise derin öğrenme ağı tasarlanmış ve eğitilmiştir. Derin öğrenme ağları için ise sınıflandırma başarımları; AWGN kanaldan alınmış işaretler ile 0-30 dB arası SNR için, 0-30 Hz arası frekans kayması için; sönümlemeye maruz kalan modüleli işaretlerde 0-30 dB arası SNR için, 0-30 Hz arası frekans kayması için elde edilmiştir. AWGN kanaldan alınmış işaretler ile 10 dB SNR'de %85,8 başarımlar elde edilmiştir. Literatürdeki benzer sistemlerden [6] ve [8]'deki sistemlerden daha yüksek başarımlar elde edilmiştir. Derin öğrenme ağı, Rayleigh, Nakagami-m ve Rician sönümlenmeli kanal şartlarında ve 10 dB SNR'de %68,3 başarımlar elde edilmiştir ve [8] ile [10]'daki çalışmalardan kanal sönümlemesi olmasına rağmen daha iyi performans elde edilmiştir.

K-Ortalama ile derin öğrenme modülasyon sınıflandırma sistemlerinin modülasyon sınıflandırma başarımlarının farklı kanallar için karşılaştırması yapılmıştır. Derin öğrenme ile eğitilen sistemler eğitim sürecinin ardından sistem, CR sisteminin işaret sınıflandırma modülünde derin öğrenme ağı gelen işaretleri alarak sınıflandıracak şekilde hazırlanmıştır. Sistemin başarımlarının sönümleme şartlarında çok değiştiği, kanal sönümlemesinin sınıflandırma başarımına yüksek modülasyon derecelerinde %20'ye yakın düşmeye yol açtığı gözlemlenmiştir. AWGN şartlarında SNR'nin 3 dB ve üzerinde düşük modülasyon dereceleri için yüksek başarımlar elde edildiği görülmüştür. Sönümleme şartları altında ise düşük modülasyon dereceleri için başarımların SNR 5 dB ve üzerinde yüksek sınıflandırma başarımı elde edildiği görülmektedir. Yüksek modülasyon dereceleri için ise SNR'nin artması ile AWGN kanalından alınmış işaretler ile lineer yakın, sönümlenmeli kanaldan iletilen işaretler için ise logaritmiğe benzer bir artış ile başarımlar artmaktadır. Frekans kayması için K-Ortalama sisteminde 10 Hz frekans kaymasının başarımlarında %5, derin öğrenme sistemlerinde ise %2 düşüşe yol açtığı görülmüştür. Bunun sebebi olarak derin öğrenme sistemlerinin frekans kayması bulunan işaret yıldız diyagramları ile eğitilmesidir. Bu sayede derin öğrenme sistemleri frekans kayması olan durumlarında K-Ortalama sistemi yerine tercih edilebilir. Modülasyon derecesinin artmasının başarımlar ile genellikle ters orantılı olduğu görülmüştür. Artan modülasyon derecesinin gürültü ve sönümleme etkileri sonucunda olası semboller arasındaki öklit uzaklığını

ciddi şekilde azaltması beklendiği gibi sınıflandırma başarımının düştüğü çıkarımına varılmıştır. Derin öğrenme ile modülasyon sınıflandırma sisteminin K-Ortalama modülasyon sınıflandırma sisteminin aksine 8-QAM modülasyonu çok iyi sınıflandırdığı, K-Ortalama yöntemi gibi BPSK ile çok karıştırmadığı görülmektedir.

Tablo 4.10. Tezdeki sistemlerin literatürdeki sistemler ile karşılaştırılması.

Referans	Kanal	SNR (dB) [min, max]	Sınıflandırılan Modülasyon Türleri	Uygulanan Sınıflandırma Methodu	Uygulanan Yöntem Hakkında Açıklamalar	Ortalama Sınıflandırma Başarımı (%) [min, max]
[5]	AWGN	[-7,16]	AM, FM	SVM	Makine öğrenmesi, frekans histogramı	[74, 100]
[6]	AWGN	[-5,15]	4, 16, 32, 64-QAM	Eksiltici kümeleme algoritması	Parçacık sürü optimizasyonu	[60, 85]
[7]	AWGN, Doppler etkisi	[-5,15]	BPSK, QPSK, 8-PSK, 16-QAM, 64-QAM	Derin öğrenme	Anlık; genlik, faz ve frekans bilgileriyle ve kümülant değerleriyle derin öğrenme ağı eğitimi	[99, 100]
[8]	Çok yollu sönmülme	[-10,15]	BPSK, QPSK, 8-PSK, 16-QAM	SVM	Beklenti maksimizasyonu ve Gauss Karışım Modeli ile kanal durum bilgisi hesaplamaları	[5, 100]

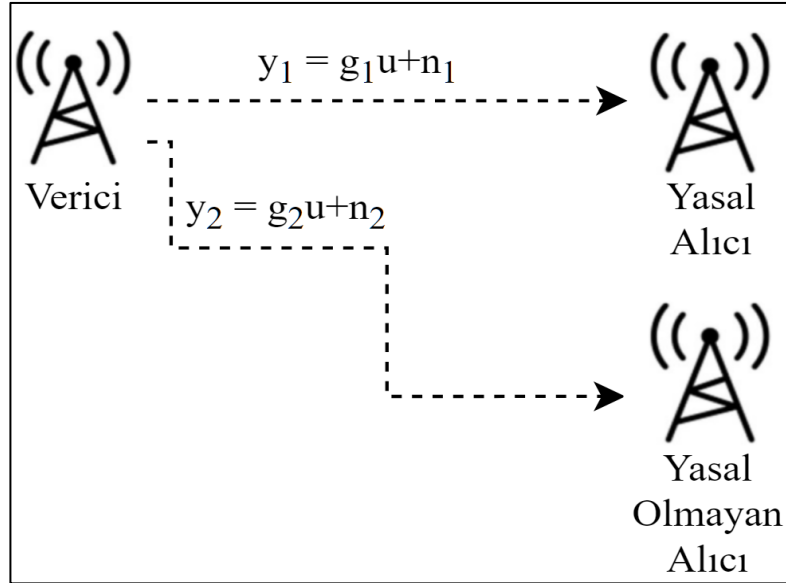
Tablo 4.10. (Devam) Tezdeki sistemlerin literatürdeki sistemler ile karşılaştırılması.

Referans	Kanal	SNR (dB) [min, max]	Sınıflandırılan Modülasyon Türleri	Uygulanan Sınıflandırma Methodu	Uygulanan Yöntem Hakkında Açıklamalar	Ortalama Sınıflandırma Başarımı (%) [min, max]
[9]	AWGN	[-3, 7]	16-QAM	Kümülant	Kanal durumu bilgisine sahip olduğu varsayımıyla Genelleştirilmiş olabilirlik oran testi,	[97, 99]
[10]	AWGN	[0,40]	BPSK, QPSK, 8-PSK	Yapay sinir ağı	Lineer ve lineer olmayan veri dönüşümü	[20, 85]
[11]	AWGN	[0,8]	16-PSK, 16-QAM	Olabilirlik fonksiyonu (likelihood function)	Veri birleştirme ve ortalama olabilirlik oran testi	[67, 100]
[12]	AWGN	[-5,10]	PSK, FSK, QAM, SSB	CNN	Kümülantlar ve güç spektral yoğunluğu ile CNN eğitimi	[18, 80]
[13]	AWGN	[-2.5, 40]	BPSK, QPSK, 8-PSK, 16-QAM, 64-QAM	Yapay sinir ağı	Kümülantlar , Döngüsel Özilinti Fonksiyonu	[64, 100]
Tez, K-Ortalama	AWGN , sönümleme	[0,30]	BPSK, QPSK, 4-PSK, 8PSK, 16PSK, 8-QAM, 16-QAM	K-Ortalama	Yıldız diyagramının kümelenmesi	[74, 100]
Tez, Derin öğrenme	AWGN , sönümleme	[0,30]	BPSK, QPSK, 4-PSK, 8PSK, 16PSK, 8-QAM, 16-QAM	Derin öğrenme	Derin öğrenme ile IQ işaretlerin sınıflandırılması	[72, 82]

5. HABERLEŐME FİZİKSEL KATMAN GÜVENLİĐİ

Kablosuz haberleşme sistemlerinde iletişim güvenliği büyük önem taşımaktadır. Günümüzde iletişim güvenliği ele alınırken haberleşme katmanları fiziksel katman ve üst katman olarak ele alınmaktadır. Fiziksel katman güvenliği ilk Shannon tarafından ifade edilmiştir [50]. Sonra haberleşme fiziksel katman gizliliği hesaplamalar için Şekil 5.1’de verilen sistem modeli için benzetim ve hesaplamalar Tablo 5.1’de verilen kanal modelleri için gerçekleştirilmiştir.

Tablo 5.1’de bir hat dinleme kanal modeli öne sürülmüştür [51]. Hat dinleme kanal modelinde bir verici, bir yasal alıcı ve bir yasal olmayan alıcı bulunmaktadır [18]. Amaç, işareti güvenli bir şekilde yasal alıcıya ulaştırmaktır [53]. Kriptografik sistemler güvenlik amacıyla yaygın olarak kullanılmaktadır ancak yalnız başına yeterli olmamaktadır ve bazı uygulamalarda kullanılamamaktadır [54]. Kanal kapasitesinin gizlilik ölçütlerinin en yüksek olacağı şekilde artırılması veya azaltılması ile kanalın fiziksel güvenliğinin sağlanması mümkündür [55].



Şekil 5.1. Noktadan noktaya kanal modeli.

5.1. Kanal Modelleri İçin Haberleşme Güvenliği Ölçüt Hesaplamaları

Haberleşme kanallarının fiziksel katman güvenliğinin sağlanabilmesi için haberleşme kanalının bilgi kuramı yönünden belirli ölçütleri sağlaması gerekmektedir [56]. Bu bölümde ilgili ölçütler açıklanmaktadır.

5.1.1. Gizlilik kapasitesi

Gizlilik kapasitesi ifadesi haberleşme kanalı fiziksel katman gizliliğinin hesaplanmasında kullanılan bilgi kuramı temelli önemli ölçütlerden bir tanesidir. Verici ile yasal alıcı arasındaki kanalın kapasiteleri verici ile yasal olmayan alıcının arasındaki kanalın kapasitelerinin farkı şeklinde hesaplanmaktadır.

Gizlilik kapasitesi C_s olacak şekilde, M temel kanal, W dinleyici kanal, N Gauss dağılımlı güç spektral yoğunluğu $\frac{N_0}{2}$ olan gürültü sinyali, γ SNR değeri, $\bar{\gamma}$ ise ortalama SNR değeri olmak üzere gizlilik kapasitesi (5.1)'de,

$$C_s = C_M - C_W, \quad (5.1)$$

şeklinde tanımlanmaktadır [18]. Burada kanal kapasitesi değerleri yerine konulduğunda,

$$C_s = \frac{1}{2} \log_2 \left(1 + \frac{1}{N_M} \right) - \frac{1}{2} \log_2 \left(1 + \frac{1}{N_W} \right), \quad (5.2)$$

ifadesine ulaşılır. (5.2)'de N_M yasal kanalın Gauss dağılımlı gürültü sinyali, N_W ise yasal olmayan kanalın Gauss dağılımlı gürültü sinyalidir [18]. (5.2)'deki ifade, logaritmik oran şeklinde düzenlenirse,

$$C_s = \frac{1}{2} \log_2 \left(\frac{\frac{N_M+1}{N_M}}{\frac{N_W+1}{N_W}} \right) = C_M - C_W. \quad (5.3)$$

biçimine kavuşur. (5.3)'tekinden farklı şekilde SNR cinsinden de kapasite,

$$C_s = \begin{cases} \log_2(1 + \gamma_M) - \log_2(1 + \gamma_W), & \gamma_M > \gamma_W \\ 0, & \gamma_M \leq \gamma_W \end{cases} \quad (5.4)$$

şeklinde ifade edilebilir [43]. (5.4)'te γ_M , yasal kanalın SNR değeri; γ_W ise, yasal olmayan kanalın SNR değeridir.

Ortalama gizlilik kapasitesi \bar{C}_s ise,

$$\bar{C}_s = E[C_s] = \int_0^\infty \int_0^\infty C_s(\gamma_M, \gamma_W) P(\gamma_M) P(\gamma_W) d\gamma_M d\gamma_W, \quad (5.5)$$

şeklinde bulunabilir, (5.5)'te $E[.]$ beklenen değer operatörüdür.

5.1.2. SPSC

SPSC, bilgi kuramı temelli fiziksel katman gizlilik kapasitesi ifadesinin pozitif olması olasılığıdır. Kablosuz haberleşme sistemlerinde fiziksel katman güvenliğinin hesaplanmasında kullanılmaktadır [18].

SPSC $P(C_s > 0)$ olacak şekilde,

$$P(C_s > 0) = P(\log_2(1 + \gamma_M) - \log_2(1 + \gamma_W) > 0), \quad (5.6)$$

elde edilir, dolayısıyla (5.6)'dan yola çıkarak,

$$P(C_s > 0) = P(\gamma_M > \gamma_W), \quad (5.7)$$

ve SNR değerlerinin oranı olarak ise,

$$P(C_s > 0) = \frac{\bar{\gamma}_M}{\bar{\gamma}_M + \bar{\gamma}_W}, \quad (5.8)$$

şeklinde hesaplanabilir [55]. (5.7) ve (5.8)'dekine benzer şekilde PDF ve CDF ifadeleri ile

$$P(C_s > 0) = \int_0^\infty F_{\gamma_M}(\gamma) f_{\gamma_W}(\gamma) d\gamma, \quad (5.9)$$

şeklinde hesaplanabilir. Burada y rassal değişken, $F(y)$, CDF, $f(y)$ ise PDF'sini göstermektedir [18].

5.1.3. SOP

SOP, gizlilik kapasitesi değerinin sıfırdan büyük bir sınır değer R_s 'den daha az olma olasılığını ifade eder. Gizlilik kapasitesi anlık olarak R_s 'den daha az ise temel kanal ile dinleyici bilgi kuramı temelli gizlilik kaybedilmiştir [43]. SOP,

$$P_{\text{out}}(R_s) = 1 - \int_0^\infty F_{\gamma_M}(\gamma) f_{\gamma_W}(\gamma) d\gamma, \quad (5.10)$$

şeklindedir (5.10)'un denk olduğu olasılık ifadesi,

$$P_{\text{out}}(R_s) = P(C_s < R_s) \quad (5.11)$$

ve

$$P(\gamma_M > \gamma_W) = \frac{\bar{\gamma}_M}{\bar{\gamma}_M + \bar{\gamma}_W}, \quad (5.12)$$

dir. (5.11) ve (5.12)'den yola çıkarak,

$$P(\gamma_M \leq \gamma_W) = 1 - P(\gamma_M > \gamma_W), \quad (5.13)$$

$$P(\gamma_M \leq \gamma_W) = 1 - \frac{\bar{\gamma}_M}{\bar{\gamma}_M + \bar{\gamma}_W}, \quad (5.14)$$

elde edilir. Burada (5.12) ve (5.13)'te toplam olasılık ifadesi kullanılırsa,

$$P_{\text{out}}(R_s) = P(C_s < R_s \mid \gamma_M > \gamma_W) P(\gamma_M > \gamma_W) + P(C_s < R_s \mid \gamma_M \leq \gamma_W) P(\gamma_M \leq \gamma_W), \quad (5.15)$$

olarak elde edilir [18]. (5.15)'te ifadenin logaritmik gösterimi kullanılmaktadır.

$$P(C_s < R_s \mid \gamma_M > \gamma_W) = P(\log_2(1 + \gamma_M), -\log_2(1 + \gamma_W) < R_s \mid \gamma_M > \gamma_W), \quad (5.16)$$

ve buna ek olarak (5.16)'da olasılık ifadesi düzenlenirse üstel ifade ile gösterilmesi için ise,

$$P(C_s < R_s \mid \gamma_M > \gamma_W) = P(\gamma_M < 2^{R_s}(1 + \gamma_W) - 1 \mid \gamma_M > \gamma_W), \quad (5.17)$$

İntegral şeklinde ifade edilirse,

$$P(C_s < R_s \mid \gamma_M > \gamma_W) = \int_0^\infty \int_{\gamma_W}^{2^{R_s}(1+\gamma_W)-1} p(\gamma_M, \gamma_W \mid \gamma_M > \gamma_W) d\gamma_W d\gamma_M, \quad (5.18)$$

İfade düzenlenirse,

$$P(C_s < R_s \mid \gamma_M > \gamma_W) = \int_0^\infty \int_{\gamma_W}^{2^{R_s}(1+\gamma_W)-1} p(\gamma_M, \gamma_W \mid \gamma_M > \gamma_W) d\gamma_W d\gamma_M, \quad (5.19)$$

$$P(C_s < R_s \mid \gamma_M > \gamma_W) = \int_0^\infty \int_{\gamma_W}^{2^{R_s}(1+\gamma_W)-1} \frac{p(\gamma_M)p(\gamma_W)}{P(\gamma_M > \gamma_W)} d\gamma_W d\gamma_M, \quad (5.20)$$

İntegral alındıktan sonra sonuç,

$$P(C_s < R_s \mid \gamma_M > \gamma_W) = 1 - \frac{\bar{\gamma}_M + \bar{\gamma}_W}{\bar{\gamma}_M + 2^{R_s} \bar{\gamma}_W} e^{\left(-\frac{2^{R_s}-1}{\bar{\gamma}_M}\right)}, \quad (5.21)$$

şeklinde elde edilir [51]. (5.21)'de $R_s > 0$ olduğu için,

$$P(C_s < R_s \mid \gamma_M \leq \gamma_W) = 1, \quad (5.22)$$

sonucuna ulaşılır. (5.22)'deki ifadeyi PDF ve CDF cinsinden elde etmek için ise,

$c = 2^{R_s} > 1$ ve $d = c - 1$ olarak alınır, SOP,

$$P_{\text{out}}(R_s) = P\{\log_2(1 + \gamma_M) - \log_2(1 + \gamma_W) \leq R_s\}. \quad (5.23)$$

SNR cinsinden farklı bir şekilde,

$$P_{\text{out}}(R_s) = P(\gamma_M < c\gamma_W + d), \quad (5.24)$$

gösterilebilir. İfade CDF'in integrali olarak,

$$P_{\text{out}}(R_s) = \int_0^{\infty} F_{\gamma_M}(c\gamma + d)f_{\gamma_W}(\gamma)d\gamma, \quad (5.25)$$

şeklinde bulunabilir [55].

5.2. Haberleşme Kanallarında Fiziksel Güvenlik Benzetimi

Şekil 5.1.'de verilen sistem modeli için benzetim ve hesaplamalar Tablo 5.1'de verilen kanal modelleri için gerçekleştirilmiştir.

Tablo 5.1. Benzetimde ele alınan kanal modelleri ve parametreleri.

Kanal	Kanal Adı	Kanal Parametreleri
1	Rayleigh	$\sigma = 1$
2	Nakagami-m	$m \geq 0,5, \Omega > 0$
3	Rician	$v \geq 0, \sigma \geq 0$
4	Kaskad Rayleigh	$\Omega = 0,5, K = 2$
5	Kaskad Nakagami-m	$m \geq 0,5, \Omega > 0, K = 2$
6	Kaskad Rician	$v \geq 0, \sigma \geq 0, K = 2$
7	Genelleştirilmiş Gamma	$(m,n) = (4,1), (3,1), (2,1), (1,1), (1,2), (1,3), (1,4)$

Benzetimi gerçekleştirilen fiziksel katman güvenliği ölçütleri ise SPSC ile SOP'tur. Gizlilik hesaplamasında kullanılan kanal model ve parametreleri, Şekil 5.1'de verilen sistem modeli için benzetim ve hesaplamalar Tablo 5.1'de verilen kanal modelleri için gerçekleştirilmiştir.

Tablo 5.1'deki gibidir. Yasal kanalın SNR değeri SNR_y ve yasal olmayan kanalın SNR değeri γ_E ile gösterilmektedir. Benzetimlerin tümünde SNR_y , 0'dan 30 dB'ye kadar benzetimlerde değiştirilmiştir.

5.2.1. Noktadan noktaya haberleşme kanalı

Haberleşme fiziksel katman güvenliği ölçütleri noktadan noktaya haberleşme kanalı için bir alıcı ve bir verici durumu için hesaplanmıştır. Bu kanalın sistem modeli Şekil 5.1’de verilmiştir. Benzer şekilde yasal olmayan aldığı işaretlerin SNR değerinin 4, 8 ve 12 dB değerleri için SOP ve SPSC benzetimleri gerçekleştirilmiştir. Düşük γ_E değerlerinde SOP değişiminin yüksek γ_E değerlerine göre SNR artışı ile daha yavaş artış gösterdiği gözlenmiştir. SPSC değerleri Tablo 5.2’de, SOP değerleri ise Tablo 5.3’te gösterilmiştir.

Tablo 5.2. Farklı SNR_y değerleri için kanalların SPSC değerleri.

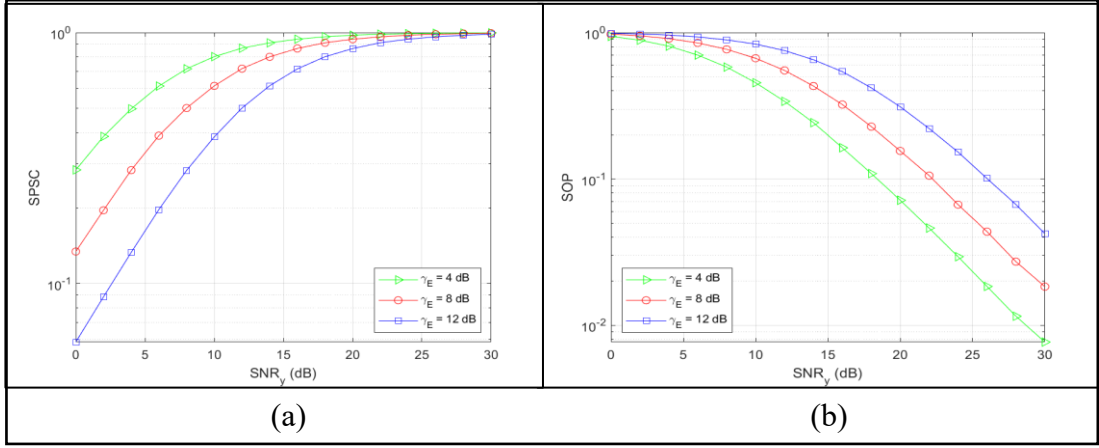
SNR _y (dB)	5	10	15	20	25	30
Rayleigh	0,167	0,388	0,667	0,862	0,951	0,984
Nakagami-m	0,267	0,425	0,608	0,758	0,860	0,920
Rician	0,164	0,386	0,669	0,866	0,954	0,984
Kaskad	0,253	0,422	0,612	0,774	0,887	0,948
Rayleigh						
Kaskad	0,412	0,455	0,571	0,677	0,774	0,842
Nakagami-m						
Kaskad Rician	0,251	0,426	0,612	0,777	0,888	0,948

Tablo 5.3. Farklı SNR_y değerleri için kanalların SOP değerleri.


SNR _y (dB)	5	10	15	20	25	30
Rayleigh	0,962	0,847	0,609	0,323	0,130	0,452
Nakagami-m	0,903	0,774	0,593	0,399	0,243	0,140
Rician	0,949	0,832	0,595	0,311	0,122	0,433
Kaskad Rayleigh	0,917	0,787	0,598	0,394	0,223	0,109
Kaskad	0,875	0,760	0,627	0,487	0,358	0,254
Nakagami-m						
Kaskad Rician	0,874	0,742	0,567	0,371	0,212	0,104

Şekil 5.2’de ise Rayleigh sönümlenmeli kanallar için (a) SPSC ve (b) SOP benzetim eğrileri gösterilmiştir. Bu şekilde SPSC ifadesinin artması kanalın fiziksel katman güvenliğinin daha fazla olduğunu göstermektedir. Burada SNR_y değerinin artması kanalın fiziksel katman güvenliği bakımından daha düşük SNR_y değerine sahip olan kanaldan daha güvenli olduğunu göstermektedir. Yasal olmayan kanalın SNR değerinin SNR_y’e oranının artması durumunda kanalın SPSC değeri düşmekte ve SOP değeri artmaktadır [55].

SOP'un artması, kanalın fiziksel katman güvenliğinin arttığını göstermektedir [18]. Düşük SOP şartlarında yasal olmayan kullanıcının haberleşmeyi dinleyebilmesi olasılığının da düşük olduğu anlamına gelmektedir. SNR_y'nin önemli olduğu kadar da yasal olmayan kanalın SNR değeri de büyük önem taşımaktadır. Yasal kanalın yüksek SNR değerine sahip olduğu şartlar göz önünde bulundurulduğunda yükselen SNR değerinin kanalın SOP'un artırdığı görülmektedir. SNR_y'nin artması yasal olmayan kullanıcının kanalı dinleyebilmesini kolaylaştırarak kanalın fiziksel katman güvenliğini düşürmektedir. Nakagami-m kanal şartlarında $m = 2$ için ise SPSC hesaplamaları Şekil 5.2.a.'da, SOP hesaplamaları ise Şekil 5.2.b'de görülmektedir. Benzer şekilde Rician kanal için ise SPSC değerleri hesaplanmıştır. Elde edilen sonuçlar, artan SNR değerleri için kanal güvenliğinin arttığını göstermektedir. Tablo 5.2'ye göre SNR_y = 10 dB için Rayleigh, Nakagami-m ve SPSC hesaplamaları Şekil 5.2.a'da, SOP hesaplamaları ise Şekil 5.2.b'de gösterilmiştir. Tablo 5.3'e göre SPSC ile SOP değerlerinin karşılaştırmasından yola çıkarak Nakagami-m kanal için en güvenli, ardından Rician ve en az güvenli kanalın ise Rayleigh kanalı olduğu görülmektedir. Noktadan noktaya kanal modelinde hesaplanan parametreler için Nakagami-m kanalın Rayleigh kanaldan fiziksel katman güvenliği bakımından daha güvenli olduğu, Rician kanalın ise Rayleigh kanaldan güvenli, Nakagami-m kanaldan az güvenli olduğu sonucuna ulaşılmaktadır. Kaskad Rayleigh, kaskad Nakagami-m ve kaskad Rician kanallar için fiziksel katman güvenliği ölçütlerinin farklı yasal ve yasal olmayan kanal SNR değerleri için SPSC eğrileri Şekil 5.5.a, Şekil 5.3.a ve Şekil 5.7.a'da; SOP eğrileri sırasıyla Şekil 5.5.b, Şekil 5.3.b ve Şekil 5.7.b'de verilmiştir. Bu hesaplamalara göre en güvenli olan kanalın kaskad Nakagami-m, ardından kaskad Rayleigh ve en az güvenli olan kanal ise kaskad Rician kanalı olduğu sonucuna ulaşılmıştır. Daha düşük SOP değerleri ile kaskad kanalın daha fazla sönmüleme gerçekleştirmesi ile kanalın daha güvenli olmasını sağlamaktadır. Bu sebepten ötürü yasal olmayan kanalın kapasitesi düşmektedir.

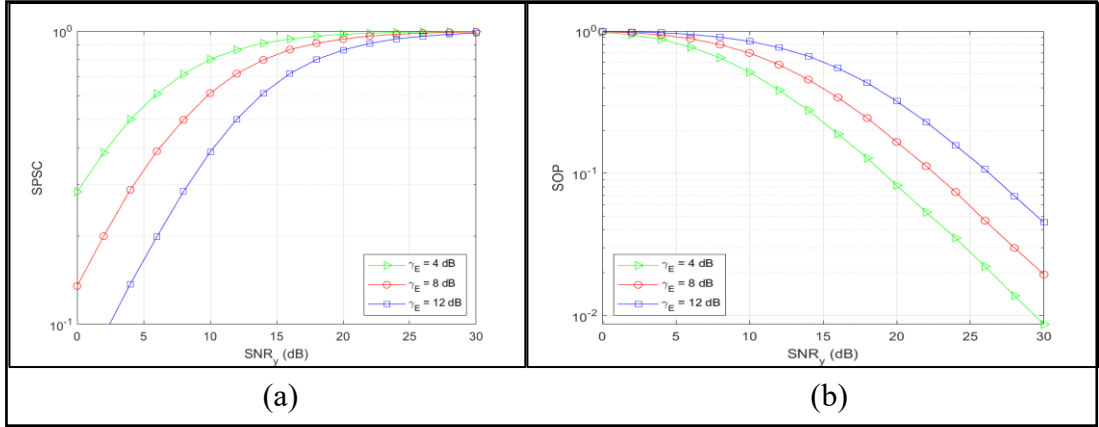


Şekil 5.2. Rayleigh kanal modelinde gerçekleştirilen iletim için (a) SPSC ve (b) SOP.




Şekil 5.3. Nakagami-m kanal modelinde gerçekleştirilen iletim için (a) SPSC ve (b) SOP ($m = 2$).

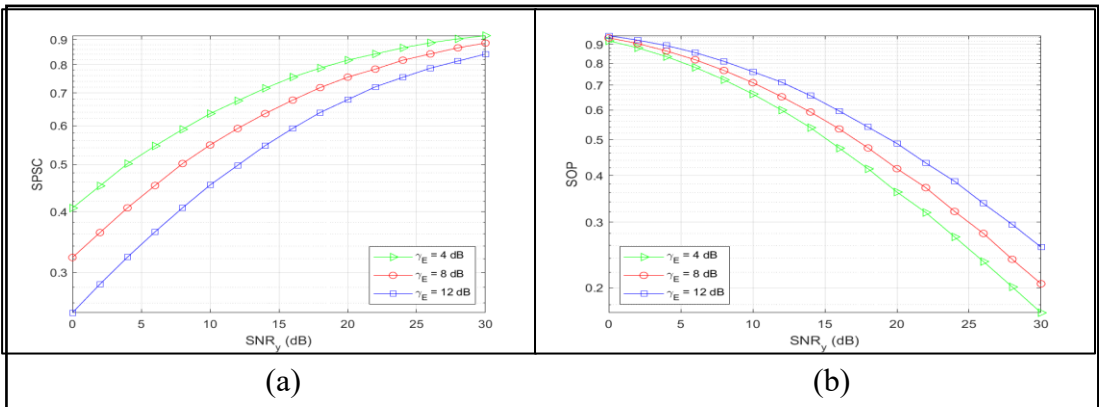
Genelleştirilmiş Gamma kanal için fiziksel katman güvenliği benzetimleri çeşitli sönümlenme parametrelerinde farklı SNR_y değerleri için SPSC ile SOP benzetimleri gerçekleştirilmiştir. Benzetim eğrileri Şekil 5.8’de, [52]’deki Genelleştirilmiş Gamma üzerine gibi elde edilmiştir. Genelleştirilmiş Gamma kanalın önemli olan özelliği ise Gamma, Nakagami-m, üstel, Rayleigh ve Weibull gibi diğer kanalların genellemesinde kullanılabilir olmasıdır. (m, n) sönümlenme parametreleri $m = 1$ iken Weibull, $n = 1$ iken Nakagami-m ve $m = n = 1$ iken de Rayleigh dağılıma dönüşmektedir [56]. Genelleştirilmiş Gamma kanalı için, farklı kanal sönümlenme parametreleri için elde edilen eğrilere göre fiziksel katman güvenliği değerleri elde edilmiştir.



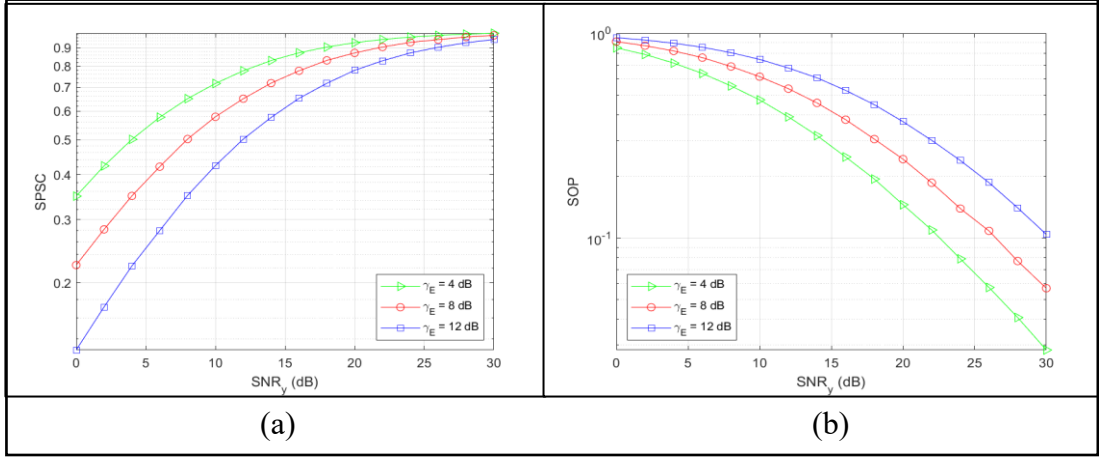
Şekil 5.4. Rician kanal modelinde gerçekleştirilen iletim için (a) SPSC ve (b) SOP.



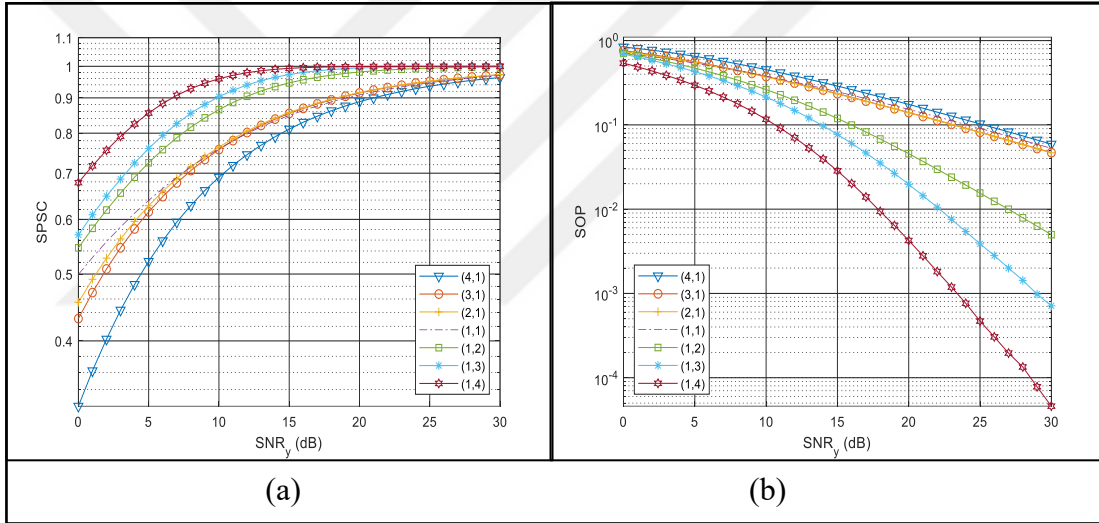
Şekil 5.5. Kaskad Rayleigh kanal modelinde gerçekleştirilen iletim için (a) SPSC ve (b) SOP.



Şekil 5.6. Kaskad Nakagami-m kanal modelinde gerçekleştirilen iletim için (a) SPSC ve (b) SOP ($m = 2$).



Şekil 5.7. Kaskad Rician kanal modelinde gerçekleştirilen iletim için (a) SPSC ve (b) SOP.



Şekil 5.8. Genelleştirilmiş Gamma kanalda (m, n) sönlüme katsayıları için gerçekleştirilen iletimde (a) SPSC ve (b) SOP.

6. SONUÇLAR VE ÖNERİLER

Tezde haberleşme sistemlerindeki artan bant genişliği ihtiyacını gidermek, spektral bantların daha verimli kullanılmasını sağlamak amacıyla kullanılan CR'lerde karşılaşılan modülasyon sınıflandırma problemi ele alınmıştır. Yüksek dereceli modülasyonları BK'lerin kullandığı yaklaşımı ile bir nevi kullanıcı sınıflandırma işlemi de yapılmaktadır. CR sistem modeli ve bu sistem modeli bünyesinde iki modülasyon tanıma sistemi tasarlanmış ve sınıflandırma başarımları test edilmiştir. İstatistiksel kümeleme yöntemi K-Ortalama algoritması kullanılarak modülasyon sınıflandırma algoritması geliştirilerek bu yöntem ile derin öğrenme ağı sistem karşılaştırılmıştır. K-Ortalama yöntemi ile AWGN kanalından alınmış işaretler ile SNR = 10 dB olmak üzere %73,4 başarımlar elde edilmiştir. Literatürdeki diğer çalışmalardaki sistemlerden [8] ve [10]'da benzer şartlarda daha yüksek performans elde edilmiştir. Derin öğrenme ile SNR = 10 dB olan AWGN kanalında iletilmiş işaretler ile %85,8 başarımlar elde edilmiştir. Literatürdeki sistemlerden [6] ve [8]'deki sistemlerden daha yüksek başarımlar elde edilmiştir. Derin öğrenme SNR = 10 dB olan Rayleigh, Nakagami-m ve Rician sönmülemeli kanal şartlarında %68,3 başarımlar elde edilmiştir ve literatürdeki yöntemlerden [8]'deki analitik hesaplama yönteminden, [10]'da makine öğrenmesi ile gerçekleştirilen sistemden ve [12]'deki konvolüsyononel yapay sinir ağları kullanılan çalışmaya kıyasla kanal sönmülemesi olmasına rağmen daha yüksek performans elde edilmiştir.

K-Ortalama yöntemi ile yüksek modülasyon derecelerinde daha düşük başarımlar elde edilirken derin öğrenme ile yüksek modülasyon derecelerinde yüksek başarımlar elde edilebilmektedir ancak derin öğrenme yönteminde 8-QAM modüli işaretler K-Ortalama yönteminden daha düşük başarımla sınıflandırılmaktadır. Yöntemlerden birinin kestirimde daha zayıf ve diğerinin daha kuvvetli olduğu durumlarda ise önerilen sistemde bu iki yöntemin beraber kullanılarak güçlü bir modülasyon kestirim yöntemi olarak elde edilebileceği ortaya çıkmıştır. Modülasyon derecesi, modülasyon tipi ve SNR'ye göre modülasyon sınıflandırma algoritmalarının başarımları hesaplanarak genel olarak artan modülasyon derecesinin modülasyon sınıflandırma

sürecini zorlaştırdığı sonucuna varılmıştır, bu tespitlerin istisnaları bulunmuştur. Sistem farklı kullanıcı sınıflarına ait belirli parça uzunluklarına sahip işaretler üretilmiş ve sistem eğitilmiştir. Eğitilen sistem önerilen CR sisteminin içinde çalışabilecek şekilde modülasyon sınıflandırma yeteneğine sahip olacak şekilde hazırlanmıştır. Elde edilen sistemleri kullanarak iki modülasyon tanıma sistemli bir CR sisteminin modülasyon tanıma amacıyla kullanılabileceği sonucuna ulaşılmıştır. K-Ortalama algoritmasının kullanılması durumunda modülasyon sınıflandırma sistemlerinin başarımlarının genel olarak SNR, 10 dB seviyesinin üzerine çıktuktan sonra modülasyon sınıflandırma başarımlarının çok artmadığı hesaplanmıştır. Tablo 6.1'den görülebileceği gibi derin öğrenme ağı modülasyon sınıflandırma sistemlerinin başarımlarının genellikle 5 dB SNR'ye kadar ciddi biçimde artarak sonra ise yatay seyrettiği gözlemlenmektedir. AWGN kanaldan alınmış işaretler için ise derin öğrenme yöntemi için modülasyon sınıflandırma sisteminin başarımları 2 ve 4 modülasyon dereceleri için 3 dB SNR'den itibaren yatay devam ettiği için bu SNR değerlerinde modülasyon sınıflandırma başarımları yüksek bir sistem elde edilebileceği görülmüştür. Frekans kayması yönünden ise 10 Hz frekans kayması ile sınıflandırma başarımları, K-Ortalama sisteminde %5, derin öğrenme sistemlerinde %2 düşüş göstermiştir. Derin öğrenme ağları frekans kayması olan IQ işaretler ile eğitildiğinden dolayı frekans kayması şartlarında daha iyi performans sergilemektedir. Dolayısıyla alınan işaretin frekansının kayma durumlarında derin öğrenme sisteminin K-Ortalama sistemi yerine tercih edilebileceği sonucuna varılmıştır. Literatürde tez ile karşılaştırılan çalışmalardan [7] ve [9]'un Tablo 1.1'de görülebileceği gibi sınıflandırma başarımlarının literatürdeki diğer çalışmalardan ve tezde elde edilen sınıflandırma başarımlarına kıyasla önemli derecede yüksek olduğu görülmektedir. Bunun sebebi ise bu çalışmalarda modülasyon sınıflandırma gerçekleştirilen işaretlerin darbe şekillendirme filtresinden geçmemiş olmasıdır.

Gelecek çalışmalar için K-Ortalama sisteminde, işaretin genlik ve açılara ek olarak frekans bilgisinin de kullanılarak sınıflandırma başarımlarının artırılması ve FSK gibi farklı modülasyon tiplerinin de bu yöntem ile sınıflandırılması gerçekleştirilebilir. K-Ortalama'ya alternatif olarak lider kümeleme (leader clustering) algoritması gibi diğer kümeleme algoritmaları kullanılarak modülasyon sınıflandırma

gerçekleştirilebilir. Derin öğrenme sisteminin gelecek çalışmalarda, sistemin işaretin frekans bilgisini de kapsayan daha büyük bir veri setiyle ve daha fazla sayıda katman ile tasarlanabilir. Bu şekilde FSK gibi farklı modülasyon tipleri de sınıflandırılabilir ve sınıflandırma başarımları artırılabilir. Farklı modülasyon sınıflandırma sistemlerinin beraber kullanıldığı BK ve İK'lerin sınıflandırıldığı bir CR sistemi tasarlanabilmesi mümkündür.



KAYNAKLAR

- [1] I.F.Akyildiz, B.F.Lo ve R.Balakrishnan, Cooperative spectrum sensing in cognitive radio networks: A survey, *Physical communications*, 2011, **4**(1), 40-62.
- [2] J.Ma, G.Zhao ve Y.Li, Soft combination and detection for cooperative spectrum sensing in cognitive radio networks, *IEEE Transactions on Wireless Communications*, 2008, **7**(11), 4502- 4507.
- [3] G.Ding, Q.Wu, J.Wang, ve X.Zhang, Joint cooperative spectrum sensing and resource scheduling for cognitive radio networks with soft sensing information, *IEEE Youth Conference on Information Computing and Telecommunications (YC-ICT)*, Beijing, 28-30 Kasım 2010.
- [4] Sharmila A. ve Dananjayan P., Spectrum Sharing Techniques in Cognitive Radio Networks – A Survey, *2019 IEEE International Conference on System, Computation, Automation and Networking (ICSCAN)*, Pondicherry, Hindistan, 2019.
- [5] Xiao H., Shi Y. Q., Su W., Kosinski J. A., Automatic Classification of Analog Modulation Schemes, *2012 IEEE Radio and Wireless Symposium*, Santa Clara, CA, 2012.
- [6] Yan-ling L., Bing-bing L., Chang-yi Y., Modulation Classification of MQAM Signals Using Particle Swarm Optimization and Subtractive Clustering, *IEEE 10th International Conference on Signal Processing Proceedings*, Beijing, 24-28 Ekim 2010,
- [7] Kim B., Kim J., Chae H., Yoon D. ve Choi J. W., Deep Neural Network Based Automatic Modulation Classification Technique, *2016 International Conference on Information and Communication Technology Convergence (ICTC)*, Jeju, 19-21 Ekim 2016.
- [8] Ghasemzadeh P., Banerjee S., Hempel M., Sharif H., Accuracy Analysis of Feature-based Automatic Modulation Classification with Blind Modulation Detection, *2019 International Conference on Computing, Networking and Communications (ICNC)*, Honolulu, HI, USA, 2019.
- [9] Dobre O. A., Abdar-Ness Y., Su W., Survey of Automatic Modulation Classification Techniques: Classical Approaches and New Trends, *IET Communications*, 2007, **2**(1), 1751-8636.
- [10] Kurniansyah H., Wijanto H. ve Suratman F. Y., Automatic Modulation Detection Using Non-Linear Transformation Data Extraction And Neural

Network Classification, *2018 International Conference on Control, Electronics, Renewable Energy and Communications (ICCEREC)*, Bandung, Endonezya, 2018.

- [11] Xu J. L., Su W., Zhou M., Likelihood Function Based Modulation Classification in Bandwidth Constrained Sensor Networks, *2010 International Conference on Networking, Sensing and Control (ICNSC)*, Chicago, IL, 2010,
- [12] Lee J. H., Kim K., Shin Y., Feature Image-Based Automatic Modulation Classification Method Using CNN Algorithm, *2019 International Conference on Artificial Intelligence in Information and Communication (ICAIIIC)*, Okinawa, 2019.
- [13] Kirillov S. N., Batishchev A. V., Neural Algorithm for Radio Signals Modulation Classification of Satellite Communication Systems at Low Signal-to-Noise Ratio, *2018 XIV International Scientific-Technical Conference on Actual Problems of Electronics Instrument Engineering (APEIE)*, Novosibirsk, 2018.
- [14] Karataeev T., Alternatif Sönümlenmeli Kanal Yapıları ve Haberleşme Sistemlerinde Etkilerinin Analizi, Yüksek Lisans, Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul, 2007, 213525.
- [15] Baricz A. ve Mészáros T., Bounds for the symmetric difference of generalized Marcum Q-functions, *IEEE 10th Jubilee International Symposium on Applied Computational Intelligence and Informatics*, Timisoara, 2015.
- [16] Neuman E, Inequalities involving modified Bessel functions of the first kind, *Journal of mathematical analysis and applications*, 1992, **171**(2), 532-536.
- [17] D. Bykhovsky, Simple Generation of Gamma, Gamma–Gamma, and K Distributions With Exponential Autocorrelation Function, *Journal of Lightwave Technology*, 2016, **9**(34), 2106-2110,
- [18] Ata S. Ö., Physical Layer Security Over Cascaded Rayleigh Fading Channels, *2018 26th Signal Processing and Communications Applications Conference (SIU)*, İzmir, 2018.
- [19] Akyildiz I. F., Lee W. Y., Vuran, M., Mohanty, S., NeXt Generation/Dynamic Spectrum Access/Cognitive Radio Wireless Networks: A Survey, *Computer Networks (Elsevier) Journal*, 2006, **13**(2006), 2127-2159.
- [20] Ridhima ve Singh Buttar A., Fundamental Operations of Cognitive Radio: A Survey, *2019 IEEE International Conference on Electrical, Computer and Communication Technologies (ICECCT)*, Coimbatore, India, 2019.
- [21] Stevenson C. R., Chouinard G., Lei Z., Hu W., Shellhammer S. J., Caldwell W., IEEE 802.22: The First Cognitive Radio Wireless Regional Area Networks

- (WRANs) Standard, *IEEE Communications Magazine*, 2009, **47**(1), 130-138.
- [22] Haykin S., Cognitive Radio: Brain Empowered Wireless Communications, *IEEE Journal on Selected Areas in Communications*, 2005, **23**(2), 201-220,
- [23] Brown T. X., An Analysis of Unlicensed Device Operation in Licensed Broadcast Service Bands, *IEEE DySPAN*, Kasım 2005.
- [24] A. Ghasemi, E.S. Sousa, Collaborative Spectrum Sensing for Opportunistic Access in Fading Environment, in: Proc. *IEEE DySPAN* 2005, November 2005
- [25] Ma L, Han X., Shen C., Dynamic Open Spectrum Sharing MAC Protocol for Wireless Ad Hoc Network, *IEEE DySPAN* 2005, Kasım 2005
- [26] Politanskyi R., Klymash M., Application of Artificial Intelligence in Cognitive Radio for Planning Distribution of Frequency Channels, *2019 3rd International Conference on Advanced Information and Communications Technologies (AICT)*, Lviv, Ukrayna, 2-6 Temmuz 2019.
- [27] Villardi G. P., Alemseged Y. D., Sun C., Sum C. S., Nguyen T. H., Baykas T., Harada, H. Enabling Coexistence of Multiple Cognitive Networks in TV White Space, *IEEE Wireless Communications*, 2011, **18**(4), 32-40,
- [28] Cabric D., Mishra S. M., Brodersen R. W., Implementation Issues in Spectrum Sensing for Cognitive Radios, *38th Asilomar Conference on Signals, Systems and Computers 2004*, Pacific Grove California ABD, 7-10 Kasım 2004.
- [29] Gupta A., Majumder S., Cognitive Radio Spectrum Classification using FLA-SVM, 2019 9th Annual Information Technology, *Electromechanical Engineering and Microelectronics Conference (IEMECON)*, 144-149, Jaipur, India, 13-15 Mart 2019.
- [30] Yang Y., Zhang Q., Wang Y., Emoto T., Akutagawa M., Konaka S., Adaptive Resources Allocation Algorithm Based on Modified PSO for Cognitive Radio System, *China Communications*, 2019, **16**(5), 83-92.
- [31] Preetha K. S., Rithanya. J. R. P., Chezhan M., Examining the Effect and Consequence of Switching Delay in Spectrum Handoff Using Residual Time Distributions in Cognitive Radio Networks, *2019 International Conference on Vision Towards Emerging Trends in Communication and Networking (ViTECoN)*, Vellore, India, 30-31 Mart 2019.
- [32] Cabric D., Brodersen R. W., Physical Layer Design Issues Unique to Cognitive Radio Systems, *IEEE Personal Indoor and Mobile Radio Communications (PIMRC)*, Berlin, Almanya, 11-14 Eylül 2005.
- [33] Cordeiro C., Challapali K., Birru D., Shankar S., IEEE 802.22: The First Worldwide Wireless Standard Based on Cognitive Radios, *IEEE DySPAN*, Baltimore, 2005.

- [34] Velmurugan T., Efficiency of K-Means and K-Medoids Algorithms for Clustering Arbitrary Data Points, *International Journal of Computer Technology and Applications*, 2012, **3**(5), 1758-1764.
- [35] Han J., Kamber M., *Data Mining Concepts and Techniques*, 1st ed., Morgan Kaufmann Publishers Inc., ABD, 2001.
- [36] Fayyad U., Piatesky G., Smyth P., Uthurusamy R., *Advances in data mining and Knowledge Discovery.*, 1st ed., AAAI Pres, USA, 1994.
- [37] Işık M., Çamurcu Y., K-Means, K-Medoids ve Bulanık C-Means Algoritmalarının Uygulamalı Olarak Performanslarının Tespiti, *İstanbul Ticaret Üniversitesi Fen Bilimleri Dergisi*, 2007, 1.
- [38] Krishna K., Murty N. M. (1999). Genetic K-Means Algorithm, *IEEE Transactions on Systems Man and Cybernetics-Part B: Cybernetics*, 1999, **29**(3), 433-439.
- [39] Han J., Kamber M., *Data Mining Techniques*, 1st ed., Morgan Kaufmann Publishers, ABD, 2000,
- [40] Sigh S. S., Chauhan N. C., K-Means v/s K-medoids: A Comparative Study, *National Conference on Recent Trends in Engineering & Technology*, Gujarat Hindistan, 11-13 Mayıs 2011.
- [41] Goodfellow A., *Deep Learning*, 1st ed., MIT Press, Cambridge, 2016.
- [42] Lee W., Kim M., Cho D. H., Deep Cooperative Sensing: Cooperative Spectrum Sensing Based on Convolutional Neural Networks, *IEEE Transactions on Vehicular Technology*, 2009, **68**(3), 3005-3009.
- [43] Erdem F., Landsat-8 Uydu Görüntülerinden Derin Öğrenme Algoritmaları Kullanarak Kıyı Çizgisi Çıkarımı, Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul, 2018, 517722.
- [44] Patterson A., *Deep Learning: A Practitioner's Approach*, 1st ed., O'Reilly Media, California 2017.
- [45] Tompson J. J., Jain A., LeCun Y., Bregler C., Joint Training of a Convolutional Network and a Graphical Model for Human Pose Estimation., *Proc. Advances in Neural Information Processing Systems*, Montreal Kanada, 2014.
- [46] Farabet C., Couprie C., Najman L., LeCun Y., Learning Hierarchical Features For Scene Labeling, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2013, **8**(2012), 1915-1929.

- [47] Krizhevsky A., Sutskever I., Hinton G. E., Imagenet Classification With Deep Convolutional Neural Networks, *Advances in Neural Information Processing Systems*, Lake Tahoe ABD, 2012.
- [48] LeCun Y., Bengio Y., Hinton, G., Deep Learning, *Nature*, 2015, **521**(7553), 436.
- [49] Szegedy C., Liu W., Jia Y., Sermanet P., Reed S., Anguelov D., Erhan D., Vanhoucke V., Rabinovich, A., Going Deeper With Convolutions, *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Boston, 2015.
- [50] Shannon, C. E., Communication theory of Secrecy Systems. *Bell System Technical Journal*, 1949, **28**(4), 656-715.
- [51] Bloch M., Barros J., Rodrigues M. R., McLaughlin S. W., Wireless Information-Theoretic Security, *IEEE Transactions on Information Theory*, 2008, **54**(6), 2515-2534.
- [52] Lei H., C. Gao Y., Pan G., On Physical Layer Security Over Generalized Gamma Fading Channels, *IEEE Communications Letters*, 2015, **7**(19) 1257-1260,
- [53] Ibnkahla M., *Signal Processing for Mobile Communications*, 1st ed., CRC Press, ABD, 2005.
- [54] Stuber G. L., *Principles of Mobile Communication*, 1st ed., Kluwer Academic Publishers, Norwell, MA, USA, 1996.
- [55] Barros J., Rodrigues M. R., Secrecy Capacity of Wireless Channels, *2006 IEEE International Symposium on Information Theory*, Seattle ABD, 2006.
- [56] Malhotra, J., Ajay R. S., On the Performance Analysis of Wireless Receiver Using Generalized-Gamma Fading Model. *Annales des Télécommunications*, 2009, **2**(64). 147-153.
- [57] Aydemir H., K-Means and K-Medoids Kümeleme Algoritmalarının Karşılaştırılması, Web Adresi: <https://fikirjeneratoru.com/K-Means-ve-k-medoids-kumeleme-algoritmalarinin-uygulanmasi-ve-karsilastirilmesi/>. (Ziyaret Tarihi: 20 Kasım 2019).
- [58] Lei H., Gao C., Guo Y., Pan G, On Physical Layer Security Over Generalized Gamma Fading Channels, *IEEE Communications Letters*, 2015, **1260**(1257), 2373-7891.

KİŞİSEL YAYIN VE ESERLER

- [1] **Demirci T.** Çolak S. A., Deep Learning for Cognitive Radio in Wireless Communications, *International Symposium on Engineering Natural Sciences and Architecture*, 2-5 Mayıs 2019.
- [2] Ekşim A., **Demirci T.**, Ultimate Secrecy in Wireless Communications, *11th International Conference on Electrical and Electronics Engineering*, 28-30 Kasım 2019.



ÖZGEÇMİŞ

Tolga Demirci 1993 yılında Ankara’da doğdu. Lise öğrenimini Ankara Kanuni Lisesinde tamamladı. 2012 yılında başladığı Gazi Üniversitesi Elektrik-Elektronik Mühendisliği bölümünden 2016 yılında mezun oldu. 2016 yılında TÜBİTAK BİLGEM’de araştırmacı mühendis olarak çalışmaya başladı. 2017 yılında Kocaeli Üniversitesinde Elektronik-Haberleşme Mühendisliği Anabilim Dalı’nda yüksek lisans öğrenimine başladı. Halen TÜBİTAK’ta görevine devam etmektedir.

