

KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

OTOMATİK MODÜLASYON TANIMA İÇİN ETKİLİ BİR
ALGORİTMA

YÜKSEK LİSANS TEZİ

Saeed Ghasemi

EYLÜL 2014
TRABZON

KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

OTOMATİK MODÜLASYON TANIMA İÇİN ETKİLİ BİR ALGORİTMA

Saeed GHASEMİ

Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsünde
“YÜKSEK LİSANS (ELEKTRONİK MÜHENDİSLİĞİ)”
Unvanı Verilmesi İçin Kabul Edilen Tezdir.

Tezin Enstitüye Verildiği Tarih : 21.08.2014
Tezin Savunma Tarihi : 16.09.2014

Tez Danışmanı : Prof. Dr. Ali GANGAL

Trabzon 2014

Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü
Elektrik-Elektronik Mühendisliği Anabilim Dalında
Saeed GHASEMİ tarafından hazırlanan

OTOMATİK MODÜLASYON TANIMA İÇİN ETKİLİ BİR
ALGORİTMA

Başlıklı bu çalışma, Enstitü Yönetim Kurulunun 26.08.2014 gün ve 1567 sayılı
kararıyla oluşturulan jüri tarafından yapılan sınavda
YÜKSEK LİSANS TEZİ
olarak kabul edilmiştir.

Jüri Üyeleri

Başkan : Prof. Dr. Ali GANGAL

Üye : Yrd. Doç. Dr. Tuğrul ÇAVDAR

Üye : Yrd. Doç. Dr. Gökçe HACIOĞLU

Prof. Dr. Sadettin KORKMAZ
Enstitü Müdürü

ÖNSÖZ

Yüksek lisans eğitimi boyunca her türlü tecrübe ve bilgilerinden istifade ettiğim, aynı zamanda manevi desteklerini esirgemeyen ve yanında çalışmaktan onur duyduğum tez danışmanım değerli hocam sayın Prof. Dr. Ali GANGAL'a, tez araştırma süresince değerli fikirleri ile bana yol gösteren arkadaşlarıma, sabırları ile her zaman yanımda olan aileme teşekkürü bir borç bilirim.

Saeed GHASEMİ
Trabzon, 2014

TEZ BEYANNAMESİ

Yüksek Lisans Tezi olarak sunduğum “Otomatik Modülasyon Tanımlama İçin Etkili Bir Algoritma” başlıklı bu çalışmayı baştan sona kadar danışmanım Prof. Dr. Ali GANGAL’ın sorumluluğunda tamamladığımı, verileri kendim topladığımı, analizleri ilgili laboratuvarlarda yaptığımı, başka kaynaklardan aldığım bilgileri metinde ve kaynakçada eksiksiz olarak gösterdiğimi, çalışma sürecinde bilimsel araştırma ve etik kurallara uygun olarak davrandığımı ve aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiğimi beyan ederim. 16/09/2014

Saeed GHASEMİ

İÇİNDEKİLER

Sayfa No

ÖNSÖZ.....	III
TEZ BEYANNAMESİ.....	IV
İÇİNDEKİLER.....	V
ÖZET	VII
SUMMARY	VIII
ŞEKİLLER DİZİNİ	IX
TABLolar DİZİNİ.....	XI
SEMBOLLER DİZİNİ	XII
1. GENEL BİLGİLER.....	1
1.1. Giriş	1
1.2. Literatür Araştırması.....	3
1.3. Gürültü.....	9
1.3.1. Toplanır Gürültü	9
1.3.2. Sinyal Gürültü Oranı	10
1.4. Dağılım/Yaygınlık Ölçüleri.....	10
1.4.1. Standart Sapma	11
1.5. Modülasyonun Gerekliği.....	11
1.5.1. İkili Faz Kaydırmalı Anahtarlama	12
1.5.2. M-li PSK.....	13
1.5.3. Karesel Genlik Modülasyonu	14
1.6. Semboller Arası Karışma.....	14
1.6.1. Darbe Biçimlendire.....	15
1.6.2. Yükseltmiş Kosinüs Filtresi	16
1.7. Örüntü Nedir?	18
1.7.1. Örüntü Tanıma.....	18
1.8. Ön İşleme.....	19
1.9. Özellik Çıkarma.....	20
1.9.1. Kullanılan Özellik Çıkarma Yöntemleri.....	20
1.9.1.1. Sürekli Dalgacık Dönüşümü.....	20
1.9.1.1.1. Haar Dalgacığı.....	24
1.9.1.2. Yüksek Mertebeli Kümülanlar	24

1.9.1.2.1.	Moment.....	25
1.9.1.2.2.	Yüksek Mertebeli Moment ve Kümülanlar	25
1.10.	Sınıflandırma Süreci	29
1.10.1.	Yapay Sinir Ağları.....	29
1.10.1.1.	Yapay Sinir Ağlarını Oluşturan Kısımlar	29
1.10.1.2.	Ağırlıklar	30
1.10.1.3.	Toplama fonksiyonu	30
1.10.1.4.	Etkinlik Fonksiyonu	30
1.10.1.5.	Yapılarına Göre Yapay Sinir Ağları.....	32
1.10.1.6.	Yapay Sinir Ağlarının Öğrenme Yöntemleri.....	33
1.10.1.7.	Yapay Sinir Ağlarının Eğitimi.....	34
1.10.2.	Destek Vektör Makineleri	35
1.10.2.1.	Verilerin Doğrusal Olarak Ayrılma Durumu.....	36
1.10.2.2.	Verilerin Doğrusal Olarak Ayrılmama Durumu.....	39
2.	YAPILAN ÇALIŞMALAR, BULGULAR VE İRDELEME	44
2.1.	Sayısal Modüleli Sinyallerin Oluşturulması.....	44
2.2.	Kullanılan Özellik Çıkarma Yöntemleri.....	45
2.2.1.	Sürekli Dalgacık Dönüşümünden Elde Edilen Özellikler	45
2.2.2.	Yüksek Mertebeli Kümülanlardan Elde Edilen Özellikler.....	49
2.3.	Önerilen Yapay Sinir Ağı Temelli Birinci Algoritma	51
2.3.1.	Ağ Parametrelerinin Belirlenmesi ve Sınıflandırma Aşamaları	51
2.4.	Önerilen İkinci Algoritma	63
2.5.	Modülasyon Tanıma İşleminde Giriş Örnek Sayısı Miktarının Etkisi	67
2.6.	Önerilen Yöntemler Başarımını Literatürdeki Yöntemlerle Karşılaştıma	70
3.	SONUÇLAR VE TARTIŞMA	73
4.	ÖNERİLER	75
5.	KAYNAKLAR.....	76

ÖZGEÇMİŞ

Yüksek Lisans Tezi

ÖZET

OTOMATİK MODÜLASYON TANIMA İÇİN ETKİLİ BİR ALGORİTMA

Saeed GHASEMİ

Karadeniz Teknik Üniversitesi
Fen Bilimleri Enstitüsü
Elektrik-Elektronik Mühendisliği Anabilim Dalı
Danışman: Prof. Dr. Ali GANGAL
2014, 81 Sayfa

Modülasyon tanımlama işlemi, haberleşme sistemlerinin çıkış aşamasındaki işlemlerdendir. Bu tez çalışmasında, Beyaz Gauss Gürültülü ortamda sınırlı sayıda sayısal modülasyon tiplerini otomatik olarak tanımak için akıllı bir sistem gerçekleştirilmiştir. Gerçekleştirilen bu sistemde özellik çıkarma yöntemleri olarak “Sürekli Dalgacık Dönüşümü” ve “Yüksek Mertebeli Kümülanlar” yöntemleri kullanılmıştır. Önerilen algoritmanın sınıflandırma işleminde, üç seviyeli çok katmanlı yapay sinir ağlarından yararlanılmıştır. Sonuç olarak bu tez çalışmasında önerilen algoritma, literatürde yer alan çalışmalara göre daha iyi sınıflandırma başarısıyla sonuçlanmış, ayrıca yine bu çalışmada giriş örnek sayısının etkisi, özellik çıkarma ve sınıflandırma işleminde incelenmiştir. Bu incelemeden elde edilen sonuçlara göre giriş örnek sayısı ve sınıflandırma performansı arasında doğrusal bir ilişki bulunmuş, yani giriş örnek sayısı arttırdığında sınıflandırma işleminden daha yüksek başarı elde edilmiştir. Ancak giriş örnek sayısı arttığında sınıflandırma zamanı da arttığı için bu çalışmada elde edilen yüksek sinyal gürültü oranlarında oldukça dayanıklı olan özellik değerlerinin bir kısmı kullanılarak sınıflandırma zamanı düşürülmüştür.

Anahtar Kelimeler: Otomatik Modülasyon Tanıma, Yapay Sinir Ağları, Destek Vektör Makineleri, Sürekli Dalgacık Dönüşümü, Yüksek Mertebeli Kümülanlar.

Master Thesis

SUMMARY

AN EFFECTIVE ALGORITHM FOR AUTOMATIC MODULATION RECOGNITION

Saeed GHASEMI

Karadeniz Technical University
The Graduate School of Science
Electronic Engineering Graduate Program
Supervisor: Prof. Dr. Ali GANGAL
2014, 81 Pages

Modulation Recognition is one of the most important process carrying out at the output stage of communication systems. In this thesis study, an automatic modulation recognition system is developed to limited numbers of modulation formats exposed to white gaussian channel. In this modulation recognition system continuous wavelet transform and higher order cumulants are used as a feature extraction methods. Also, In this proposed algorithm, a three-level multilayer perceptron neural network was applied as a classifier. As a result of this thesis study, the proposed algorithm seemed to have better results in comparison to the other algorithms located in literature section. After that, in this thesis study, effect of the number of input samples on the performance of classification was investigated. The results of this investigation indicate that there is a direct relevance between the number of input sampels and classification performance. Namely, increasing the number of input sampels leads to an increase of operation in classification process. But increasing the number of input sampels lead to increasing classification time too. In this study, because of selected feature extraction methods which are resistant against noise impact, the value of extracted feature were stable partly. In this thesis instead of using all elements of extracted feature vektor we just used a part of them in the training step. Because our extracted features were reasonably stable in front of signal noise rate. So classification time is reduced subsequently.

Key Words: Automatic Modulation Recognition, Artifical Neural Networks, Support Vector Machine Algorithm, Continuous Wavelete Transform, Higher Order Cumulants.

ŞEKİLLER DİZİNİ

	<u>Sayfa No</u>
Şekil 1. Haberleşme sistemlerinin temel yapısı	1
Şekil 2. Bir iletişim sistemi modeli.....	10
Şekil 3. a) Dikdörtgensel darbe biçimindeki giriş işareti, b) Giriş işaretin frekans spektrumu.....	15
Şekil 4. Temel banttaki bir yükseltilmiş kosinüs filtresinin genlik transfer fonksiyonu	17
Şekil 5. a) Dikdörtgensel darbe biçimindeki giriş işareti, b) Yükseltilmiş kosinüs filtresinden geçirilmemiş işaretin frekans spektrumu, c) Zaman uzayında yükseltilmiş kosinüs filtrelenmiş giriş işareti, d) Yükseltilmiş kosinüs filtresinden geçirilmiş giriş işaretin frekans spektrumu	17
Şekil 6. Örüntü tanıma sisteminin genel yapısı	19
Şekil 7. İşaretin farklı boyutlarda çözünürlük gösterimi	21
Şekil 8. Haar dalğacığını grafiksel ifadesi	24
Şekil 9. YSA’larda tipik bir işleme elemanı	30
Şekil 10. Eşik etkinlik fonksiyonu	31
Şekil 11. Doğrusal etkinlik fonksiyonu	31
Şekil 12. Tanjant hiperbolik fonksiyonu.....	32
Şekil 13. Üç katmanlı ileri beslemeli YSA.....	33
Şekil 14. YSA’larda danışmanlı öğrenme	34
Şekil 15. YSA’larda danışmansız öğrenme	34
Şekil 16. DVM için doğrusal olarak ayrılabilen örnek	36
Şekil 17. Doğrusal olarak ayrılabilen sınıflar için hiper düzlem belirlenmesi	37
Şekil 18. Doğrusal olarak ayrılamayan sınıflar için örnek	39
Şekil 19. Doğrusal olarak ayrılamayan sınıflar için hiper-düzlem belirlenmesi	40
Şekil 20. SDD yöntemi ile özellik çıkarma diyagramı	45
Şekil 21. SDD’den elde edilen özelliklerinin gösterimi	47
Şekil 22. 16-QAM modülasyonu için 2. ve 3. Ölçekten elde edilen niteliklerin gürültüye göre diyagramı.....	48
Şekil 23. 32-QAM modülasyonu için 2. ve 3. Ölçekten elde edilen niteliklerin gürültüye göre diyagramı.....	48
Şekil 24. 64-QAM modülasyonu için 2. ve 3. Ölçekten elde edilen niteliklerin gürültüye göre diyagramı.....	49
Şekil 25. Tek gizli katmanlı birinci sınıflandırıcının genel yapısı.....	53

Şekil 26.	Kullanılan modüleli işaretlerin hangi gruba ait olduğunu belirleyen birinci YSA sınıflandırıcı	54
Şekil 27.	İki gizli katmanlı ikinci sınıflandırıcının genel yapısı.....	54
Şekil 28.	PSK modüleli işaretlerin tipini belirlemek için kullanılan YSA sınıflandırıcı.....	57
Şekil 29.	Tek gizli katmanlı üçüncü sınıflandırıcının genel yapısı.....	58
Şekil 30.	PSK modüleli işaretlerin tipini belirlemek için kullanılan üçüncü sınıflandırıcı.....	60
Şekil 31.	Önerilen birinci algoritmada YSA sınıflandırıcının yapısı.....	61
Şekil 32.	PSK modüleli işaretlerin sınıflandırılmasından elde edilen sonuçlar.....	62
Şekil 33.	QAM modüleli işaretlerin sınıflandırılmasından elde edilen sonuçlar.....	63
Şekil 34.	DVM sınıflandırıcısıyla BPSK, QPSK ve 8-PSK modüleli işaretler için elde edilen sınıflandırma sonuçları.....	66
Şekil 35.	DVM sınıflandırıcısıyla 16-QAM, 32-QAM ve 64-QAM modüleli işaretler için elde edilen sınıflandırma sonuçları.....	67
Şekil 36.	Giriş örnek sayısı 2000 olduğu durumda BPSK, QPSK ve 8-PSK modüleli işaretlerin sınıflandırma başarımları.....	70

TABLolar DİZİNİ

	<u>Sayfa No</u>
Tablo 1. Momentlerin polinomları olarak ifade edilen YMK'ler-1	27
Tablo 2. Momentlerin polinomları olarak ifade edilen YMK'ler-2.....	28
Tablo 3. M-QAM modüleli işaretler için SDD'nin 5 farklı ölçeklerinden elde edilen nitelik değerleri	46
Tablo 4. M-PSK modüleli işaretler için SDD'nin 5 farklı ölçeklerinden elde edilen nitelik değerleri	46
Tablo 5. BPSK, QPSK ve 8-PSK türlü modüleli işaretler için farklı YMK'lerden elde edilen özellik değerleri	50
Tablo 6. BPSK, QPSK ve 8-PSK modüleli işaretler için seçilen özellik değerleri	50
Tablo 7. Birinci sınıflandırıcının gizli katmanının ağırlık vektörü	53
Tablo 8. Birinci sınıflandırıcının çıkış katmanının ağırlık vektörü	53
Tablo 9. İkinci sınıflandırıcının birinci gizli katmanının ağırlık vektörü	55
Tablo 10. İkinci sınıflandırıcının ikinci gizli katmanının ağırlık vektörü.....	56
Tablo 11. İkinci sınıflandırıcının çıkış katmanının ağırlık vektörü	57
Tablo 12. Üçüncü sınıflandırıcının gizli katmanının ağırlık vektörü	58
Tablo 13. Üçüncü sınıflandırıcının çıkış katmanının ağırlık vektörü	59
Tablo 14. DVM sınıflandırıcısında QAM modüleli işaretler için kullanılan özellik değerleri	64
Tablo 15. DVM sınıflandırıcısında PSK modüleli işaretler için kullanılan özellik değerleri	64
Tablo 16. Çalışmaya ait BKB temelli DVM sınıflandırıcısının karışıklık matrisi	65
Tablo 17. BPSK modüleli işaretler için giriş örnek sayısı 2000 olduğunda YMK değerleri	68
Tablo 18. BPSK modüleli işaretler için giriş örnek sayısı 20000 olduğunda YMK değerleri	68
Tablo 19. QPSK modüleli işaretler için giriş örnek sayısı 2000 olduğunda YMK değerleri	68
Tablo 20. QPSK modüleli işaretler için giriş örnek sayısı 20000 olduğunda YMK değerleri	69
Tablo 21. 8-PSK modüleli işaretler için giriş örnek sayısı 2000 olduğunda YMK değerleri	69
Tablo 22. 8-PSK modüleli işaretler için giriş örnek sayısı 20000 olduğunda YMK değerleri.....	69
Tablo 23. Bu çalışmada elde edilen sonuçlarla literatürdeki bazı çalışmaların kıyaslanması	71

SEMBOLLER DİZİNİ


ASK	: Genlik Kaydırmalı Anahtarlama
BKB	: Bire-Karşı-Bir
BKD	: Bire-Karşı-Diğer
CUM	: Kümülant
<i>dB</i>	: Desibel
EEG	: Elektroensefalografi
FSK	: Frekans Kaydırmalı Anahtarlama
GMSK	: Gauss Minimum kaydırmalı anahtarlama
ISI	: Simgeler arası Girişimi Temsil Etmektedir
K-NN	: En Yakın Komşu Algoritması
LSB	: Alt Yan Bant
MATLAB	: Matrix laboratory
MOD	: Modülasyon
OFDM	: Dik Frekans Bölmeli Çoğullama
PSK	: Faz Kaydırmalı Anahtarlama
QAM	: Karesel Genlik Anahtarlama
RBFN	: Radyal Tabanlı Yapay Sinir Ağları
SDD	: Sürekli Dalgacık Dönüşümü
SGO	: Sinyal Gürültü Oranı
SSB	: Tek Yan Bant Modülasyonu
SVD	: Tekil Değer Ayrışımı Yöntemi
YMM	: Yüksek Mertebeli Moment
YMK	: Yüksek Mertebeli Kümülant
SW	: Sürekli Dalga Modülasyonu (YMM)
YMM	: Yüksek Mertebeli Moment
f_c	: Taşıyıcı Ferekansı
f_s	: Örnekleme Ferekansı
f_{symb}	: Sembol Oranı
R_{symb}	: Bit Oranı
σ_{dp}	: İşaret Parçalarının Kuvvetli Aralıklarında, Anlık Fazın Doğrusal Olmayan Bileşeninin Standart Sapması

- σ_{ap} : İşaretin Zayıf Olmayan Aralığında, Anlık Fazın Doğrusal Olmayan Parçasının Mutlak Değerinin Standart Sapması
- γ_{max} : Anlık Genliğin Normalize Edilmiş Spectrum Güç Yoğunluğunun Maximum Değeri
- σ_{aa} : İşaretin Normalize Edilmiş Anlık Genliğinin Mutlak Değerinin Standart Sapması
- σ_{af} : İşaretin Normalize Edilmiş Anlık Frekansının Mutlak Değerinin Standart Sapması
- σ_{fn} : Sinyalin Zayıf Olmayan Aralığında, Normalize Edilmiş Anlık Frekans Miktarının Standart Sapması
- σ_{af} : İşaretin Normalize Edilmiş Anlık Frekansının Mutlak Değerinin Standart Sapması

1. GENEL BİLGİLER

1.1. Giriş

Kaliteli, verimli ve güvenli bir şekilde ses, görüntü ve video gibi bilgilerin bir noktadan diğer bir noktaya iletilmesi, alınması ve kullanılmasına haberleşme denir. Bu bilgi aktarımı yapay teçhizat kullanılarak gerçekleştirilmektedir. Günümüzde kablosuz iletim, internet ve medyaların hızlı şekilde gelişmesi ve haberleşme alanında kullanılan cihazların yaygınlaşması, iletişim kavramına küresel bir anlam katmıştır. Şekil 1’de gösterildiği gibi haberleşme sistemlerinin temel yapısı verici, haberleşme kanalı ve alıcı bloklarından oluşmaktadır.



Şekil 1. Haberleşme sistemlerinin temel yapısı

İletilmesi istenen verilerin işaret şeklinde kaynaktan gönderilmesini sağlayan teçhizatlar verici, iletilen işaretin hedefte alınıp ve yeniden elde edilmesini sağlayan teçhizatlar alıcı ve iletilen işaretin iletiildiği ortam haberleşme kanalı olarak adlandırılmaktadır. Alçak frekanslı bilgilerin iletilmesi için bu alçak frekanslı işaretleri başka bir yüksek frekanslı işaretlere bindirilmesi gerekmektedir. Bu işlemin nedeni alçak frekanslı işaretlerin iletilmesi için yeryüzünün elverişli olmamasıdır [1]. Bu bilgi işaretinin iletilmesinde kullanılan yüksek frekanslı işarete taşıyıcı işareti denir. Bu şekilde bilginin taşıyıcı işaretini kullanarak iletilmesine modülasyon denir [2]. Modülasyon türü bilinmeyen bir sinyal geldiği anda sinyalin modülasyon türünü tanımlayabilecek bir yeteneğe sahip olmak, kablosuz ağlarda çok önemli bir avantajdır ve bu avantajı sağlayan sistemler her geçen gün artmaktadır. Sinyal tanımlama işlemini gerektiren birçok uygulama alanları vardır. Bu uygulamalardan bazıları elektronik savaş, tehdit algılama, tehdit analizi ve gözetleme olmak üzere askeri amaçlı kullanılır. Diğer kullanım alanları ise sinyal doğrulaması, işaret onaylama ve parazit tanımlama ise sivil amaçlı gerçekleştirilen

uygulamalardandır [3]. Geçmişte iletişim sistemlerinde farklı yayıcıları sınıflandırmada ölçülen parametreler, bir uzman işletmen vasıtasıyla yapılmaktaydı ve bu işletmenin yaptığı işlem elcil modülasyon tanıma olarak adlandırılırdı. Bu uzman işletmen alınan modüleli sinyali dinleyerek ya da inceleyerek modülasyon tipini belirlemekteydi. Bu modülasyon tanıyıcı sistemlerin becerikli işletmenler ve uzun sinyal süresi gerektirmesinden dolayı otomatikleştirilmeleri düşünüldü [3]. Söz konusu elcil sistemlerin otomatikleştirilmesi için sistemin çıkışına karar algoritmaları kümesi konuldu. İlk ortaya atılan modülasyon tanımlama sistemlerinde her bir sistem sadece tek bir modülasyon tipini tanımlamak için tasarlanmıştı ve bu otomatikleştirmenin gerçekleşmesi karmaşık bir işlemdi. Bununla birlikte oldukça fazla bilgisayar belleği gerektirirdi ve tanınabilecek modülasyon tiplerinin sayısı modülasyon tanıyıcıların sayısına bağlıydı [3, 4]. Bu yüzden daha sonraki zamanlarda daha etkili otomatik modülasyon tanıma sistemleri hızlı ve güvenli veri iletebilme, verimli bant kullanma ihtiyaçlarından dolayı geliştirildi. Haberleşme sistemlerinin çıkış aşamasında bilgi özütleme, kaydetme ve keşfetme ile ilgili birçok esas işlevi vardır. Modülasyon tanımlama işlevi bütün bu işlevlerin öncesinde yer alan işlemdir. Algılanan sinyalin modülasyon tipini otomatik olarak tanımlayan sistemlerine otomatik modülasyon tanıma sistemleri denir [4]. Haberleşme sistemlerinde modülasyon tipini tanımlama işlemi son derece önemlidir. Örneğin eğer bilgi işaretinin modülasyon tipi doğru olarak tanımlanmazsa yanlış demodülatöre verilir ve bu da bilgi işaretine tamamen ya da kısmen zarar verebilir [3].

Bu tez çalışmasında sınırlı sayıda modüleli işaretleri otomatik olarak tanımlama için etkili bir algoritma önerilmiştir. Bu çalışma kapsamında sayısal iletişim sistemlerinde yaygın olarak kullanılan BPSK, QPSK, 8-PSK, 16-QAM, 32-QAM ve 64-QAM modülasyonları ele alınmıştır. Çalışmamızın birinci bölümünde otomatik modülasyon tanıma konusunda, literatürde yer alan çalışmalar ve uygulamalar, ele alınan modülasyon türleri, kullanılan öznitelik çıkarma yöntemleri ve sınıflandırıcılar hakkında genel bir bilgi verilmiştir. Tezin ikinci bölümünde, bu çalışmada geliştirilmiş olan algoritmalar hakkında bilgi verilmiştir, öznitelik çıkarma aşamaları açıklanmış ve elde edilen sınıflandırma başarımları sunulmuştur. Daha sonra önerilen algoritmaların sınıflandırma başarımları literatürdeki çalışmalarla kıyaslanmıştır. Ayrıca bu bölümde giriş örnek sayısının etkisi sınıflandırma başarımlarında incelenmiştir. Bundan sonraki bölümler; sonuçlar, öneriler ve kaynaklar kısımlarından oluşmaktadır.

1.2. Literatür Araştırması

Farklı modülasyon tipleri için farklı demodülatörler kullanılan ilk modülasyon tanıma sistemlerinde [5, 6, 7] modülasyon tipi belirleme işlemi; uzmanlar tarafından radyo frekansı spektrumunun taranması, göstergelerin kontrol edilmesi, uzmanların yeteneğine ve tecrübelerine bağlıydı. Bundan dolayı modülasyon tanıma alanlarında, otomatik modülasyon tanıma sistemleri geliştirilmeye başladı. Otomatik sinyal sınıflandırma teknikleri genellikle iki teknik prensibe ayrılır. Bunlardan birisi Karar Teorisi yöntemi ve diğeri ise Örüntü Tanımlama yöntemidir. Karar Teorisi metotları örüntü tanımayı formüle etmek için olasılık ve hipotezi test eden argümanlar kullanır [8, 9]. Bu metotlar içerisinde çok fazla cebirsel karmaşıklık ve uygulama alanında zorluk barındırırken örüntü tanıma yöntemi, Karar Teorisi metodları kadar sıkıntılı değildir ve uygulanması daha kolaydır. Bu yöntem özellik çıkarma ve sınıflandırma olmak üzere iki önemli alt sisteme ayrılmıştır. İlk olarak 1980'li yıllarda otomatik modülasyon tanıma yöntemini ortaya atan Liedtke [7], bu yöntemle 2-ASK, 2-FSK, BPSK, QPSK, 8-PSK gibi modülasyon türlerini sınıflandırmak için genlik histogramı, frekans histogramı, faz ayırım histogramı, genlik varyansı ve frekans varyansı gibi anahtar özellikleri kullanmıştır. Bu alanda bir diğeri çalışmayı yapan Wu Juan Ping, Ying Zheng ve Wanghua Kui [10] başka bir algoritma önermişlerdir ve bu algoritmada işaretin istatistiksel özellikleri ile işaretin spektral özelliklerini kullanmışlardır. Bu çalışmada sınıflandırma işlemini yapmak için YSA sınıflandırıcısı kullanılmıştır. Sinyal gürültü oranı (*SGO*) miktarı 8 *dB*'de yapılan bu çalışma sonucunda 2-ASK, 4-ASK, BPSK, QPSK, 2-FSK, 4-FSK, 16-QAM ve 64-QAM modülasyonları tanımlamasında %98 başarı elde etmişlerdir.

K. Hassan ve arkadaşları da [11] dalgacık dönüşümünün yüksek mertebeli momentlerini (YMM) özellik olarak kullanmışlardır. Bu makalede önerilen algoritmada, gürültü karşısında dayanıklı olan iki farklı özellik setini kullanarak 16-QAM, 32-QAM, 64-QAM, 2-ASK, 4-ASK, 8-ASK, 2-FSK, 4-FSK ve 8-FSK türlü modüleli işaretler, YSA sınıflandırıcısı ile sınıflandırılmıştır. *SGO* miktarı -10 *dB* olduğunda 16-QAM, 32-QAM ve 64-QAM türlü modülasyonlar sırasıyla %99.5, 99.3 ve %99.8 başarıyla sınıflandırılmıştır. *SGO* miktarı -8 *dB* olduğunda 2-ASK, 4-ASK ve 8-ASK türlü modülasyonlar sırasıyla %99.4, 99.1 ve %99.3 başarıyla sınıflandırılmıştır. *SGO* miktarı 2 *dB* olduğunda 2-FSK, 4-FSK ve 8-FSK türlü modülasyonlar sırasıyla %99.7, 99.2 ve %99.1 başarıyla sınıflandırılmıştır. *SGO* miktarı 4 *dB* olduğunda BPSK, QPSK ve 8-PSK

türlü modülasyonlar sırasıyla %99.9, %99.8 ve %99.5 başarısıyla sınıflandırılmıştır. Kullanılan iki katmanlı sınıflandırıcının birinci katmanında 10 ve ikinci katmanında 15 nöron kullanılmıştır. Bu çalışmanın eğitim aşamasında, sınıflandırılan her modülasyon türünden 300 modüleli işaret ele alınmıştır.

Chen Xiaolong, Wang Jiali ve Li Xin [12], otomatik modülasyon tanıma çalışmalarında AM, LSB, FSK ve GMSK gibi modülasyon türlerini sınıflandırmışlardır. Chen Xiaolong ve arkadaşları yapmış olduğu çalışmalarında, periyodik spektrum analizinden elde edilen farklı uzunluktaki verileri (512, 2048, 8192) , özellik olarak ve YSA'lerden sınıflandırıcı olarak kullanmışlardır. Bu Çalışma $5dB \leq SGO \leq 25$ dB yapılmıştır ve modülasyon türleri 10 dB SGO'da %95'lik bir başarı oranı ile sınıflandırılmıştır. Bu çalışmada örnek sayısı miktarının etkisi, modülasyon tanıma işleminde incelenmiştir. Elde edilen sonuçlara göre yüksek sayıda giriş örnek sayısı kullanıldığında, sınıflandırma performansı yükselmiştir.

Kaynak [13]'te Jaspal Bagga ve Netta Tripathi sayısal modüleli sinyaller için yeni bir modülasyon tanıma yöntemi önermişlerdir. Bu yöntemde karar teori yaklaşımından yararlanılmıştır. 2-ASK, 4-ASK, 2-FSK, 4-FSK, BPSK, QPSK ve 16-QAM modüleli sinyaller arasında sınıflandırma yapmak için faz ve frekans genliği gibi anlık özellikler ve anlık özelliklerden elde edilen genlik ortalama, karesel genlik ortalama, faz ortalama ve karesel frekans ortalama gibi özellik seti kullanılmıştır. Bu metotla yukarıda söylenen modülasyon türleri toplamsal Beyaz Gauss gürültülü ortamda, SGO miktarı 5 dB'den büyük olduğunda %97 ve SGO miktarı 20 dB'den büyük olduğunda %100 başarı ile sınıflandırılmıştır. Bu çalışmada taşıyıcı ve örnekleme frekansı sırasıyla 10 KHZ ve 200 KHZ olarak seçilmiştir.

Kaynak [14]'te MASK, MFSK, M-PSK türlü modüleli sinyalleri sınıflandırmak için sade ve hızlı bir algoritma önerilmiştir. Bu algoritmada özellik seti çıkarmak için Hilbert dönüşümü kullanılmıştır. Bu dönüşüm kullanılarak sinyalin anlık özellikleri çıkarılmıştır. Bu özellikler anlık genlik, anlık faz ve anlık frekans olarak tanımlanmıştır. Elde edilen özellikler kullanılarak iki farklı özellik vektörü oluşturulmuştur. Özellik vektörü boyutlarını düşürmek için SVD tekniği kullanılmıştır. Genelleştirilmiş regresyon sinir ağı tekniği sınıflandırıcı yöntemi olarak kullanılmıştır. Bu çalışmada kullanılan f_c ve f_s sırasıyla 150 KHZ ve 1200 KHZ olarak seçilmiştir. Yazarların iddiasına göre bu algoritma sade, basit ve hızlı bir algoritmadır.

Kaynak [15]'te sayısal modüleli işaretler için başka bir modülasyon tanıyıcı algoritması önerilmiştir. Bu modülasyon tanıyıcı algoritmasında dördüncü ve altıncı mertebeden kümülanlar özellik seti olarak kullanılmıştır. Bu çalışmada LI Pei-hua ve arkadaşları toplamsal Beyaz Gauss gürültülü ortamda 2-ASK, 8-ASK, 8-PSK, 16-OFDM, BPSK, QPSK, 16-QAM, 32-QAM ve 8-QAM modülasyon türlerini sınıflandırmaya çalışmışlardır. Sınıflandırma yöntemi olarak SVM sınıflayıcısı kullanılır ve sonuç olarak *SGO* miktarı -5 dB'den büyük olduğu durumda 16-OFDM, 8-PSK, BPSK, 16-QAM ve 8-QAM modülasyon türleri %100 başarı ile ve 2-ASK, QPSK ve 32-QAM modülasyon türleri sırasıyla %80, %80 ve %60 başarıyla sınıflandırılmıştır. Bu çalışma toplamsal Beyaz Gauss gürültülü ortamda uygulanmıştır.

A.Ebrahimzade ve S.E. Mousavi diğer bir çalışmada [16] 2-ASK, 4-ASK, BPSK, Q-PSK, 8-PSK, 8-QAM, 16-QAM, 32-QAM, V29, V32, 64-QAM ve 128-QAM modülasyonlarını sınıflandırmaya çalışmışlardır. Bu makalede YMM ve yüksek mertebeli kümülanların (YMK) kombinasyonu özellik seti olarak kullanılmıştır. YMM'lerin dördüncü ve altıncı mertebesinin değerleri ve YMK'lerin altıncı ve sekizinci mertebesinin değerleri özellik setinde kullanılmıştır. Sınıflayıcı tekniği olarak YSA'ların RBFN yöntemini kullanan bu makalede *SGO* miktarı 3 dB'den büyük olduğu durumda 2-ASK, 4-ASK, B-PSK, Q-PSK, 8-PSK, 8-QAM, 16-QAM, 32-QAM, V29, V32, 64-QAM ve 128-QAM modülasyon türleri sırasıyla %95, %95, %97, %98, %94, %95, %92, %92, %92, %92, %90 ve %93 başarıyla sınıflanmıştır ve *SGO* miktarı 6 dB'den büyük olduğu durumda yukarıda söylenen modülasyon türleri sırasıyla %99, %98, %99, %99, %98, %99, %95, %92, %93, %94, %91 ve %97 başarıyla sınıflanmıştır.

Başka bir makalede Ali Özen ve Celal Öztürk [17], toplamır Beyaz Gauss gürültülü kanala maruz kalmış BPSK, QPSK, 8-PSK, 16-PSK, 4-QAM, 16-QAM ve 64-QAM modülasyonların sınıflandırılmasına yeni bir yöntem önermişlerdir. Bu algorithmada alınan sinyallerin YMK değerlerinden yararlanarak, Yapay Arı koloni algoritması ile eğitilmiş çok katmanlı YSA sınıflandırıcı tekniği olarak önerilmiş ve bu önerilen algoritmanın başarımı ölçekli eşlenik gradiyent algoritması ile karşılaştırılmıştır. Önerilen bu algorithmada *SGO* miktarı 5 dB'den büyük olduğunda QPSK, 8-PSK, 16-PSK, 4-QAM, 16-QAM ve 64-QAM modülasyon tipleri %100 tanıma başarısıyla sonuçlanmıştır. Ama *SGO* miktarı 0 dB'dan büyük olduğunda yukarıda söylenen modülasyon türleri sırasıyla %100, %94.99, %91.88, %80.57, %88.73, %93.77 ve %96.27 başarı ile sınıflandırılmıştır.

Yapılan diğler bir çalıřmada [18] K.Hassan ve arkadaşları otomatik modülasyon tanıma için sürekli dalgacık dönüşümünün (SDD) YMM'lerinde özellik seti oluşturmak için kullanmışlardır ve sınıflandırıcı olarak iki katmanlı YSA tekniğini uyguladıktan sonra 16-QAM, 32-QAM, 64-QAM, 2-ASK, 4-ASK, 8-ASK, 2-FSK, 4-FSK, 8-FSK, BPSK, QPSK ve 8-PSK modülasyonlar üzerinde sınıflandırma yapmışlardır. Bu çalışmanın eğitim aşamasında her modülasyon formatından 100 işaret ve sınıflandırma aşamasında ise 300 adet gerçekleştirilmiş modüleli işaret kullanılmıştır. Bu çalışma sonucunda 16-QAM, 32-QAM ve 64-QAM türlü modülasyonlar *SGO* miktarı -6 dB olduğu durumda sırasıyla %99.5, %99.3 ve %99.8 başarı ile sınıflandırılmıştır. 2-ASK, 4-ASK ve 8-ASK türlü modülasyonlar *SGO* miktarı -4 dB olduğu durumda sırasıyla %99.4, %99.1 ve %99.3 başarı ile sınıflandırılmıştır. BPSK, QPSK ve 8-PSK türlü modülasyonlar *SGO* miktarı 4 dB olduğu durumda sırasıyla %99.9, %99.8 ve %99.8 başarı ile sınıflandırılmıştır. 2-FSK, 4-FSK ve 8-FSK türlü modülasyonlar *SGO* miktarı 2 dB olduğu durumda sırasıyla %99.7, %99.2 ve %99.1 başarı ile sınıflandırılmıştır.

Çalışma [19]'da Ebrahimzade ve Mirbozorgi PSK, ASK, FSK ve QAM modüleli işaretleri sınıflandırma için SDD katsayılarının varyansı, dördüncü mertebeli momentler, sıfır geçiş oranı, sinyalin entropisi ve sinyalin enerjisini özellik seti oluşturmak için kullanmışlardır. Sınıflandırıcı olarak iki katmanlı YSA tekniğini kullanmışlardır. Bu uygulamada *SGO* miktarı -5 dB olduğunda 2-ASK, 4-ASK, BPSK, QPSK, 2-FSK, 4-FSK ve 16-QAM modüleli işaretler %91.03 başarıyla tanımlanmıştır .

Yapılan diğler bir çalışma ise [20] LI Shi-ping ve arkadaşları tarafından yapılmıştır. LI Shi-ping ve arkadaşları otomatik modülasyon tanıma işlemini yapmak için etkili bir yöntem önermiştir. Bu çalışmada sinyallerin YMK'lerinin farklı mertebeli oranlarından elde edilen değerler, özellik seti oluşturmak için kullanılmıştır. Bu özellikler seti 2-ASK, 4-ASK, 2-FSK, 4-FSK, BPSK, QPSK, 8PSK, 16-QAM modüleli sinyallerden elde edilmiş ve bire- karşı-diğlerleri (BKD) temelli SVM yöntemi kullanılarak sınıflandırma yapılmıştır. Bu uygulama *SGO* miktarı -30 ve 20 dB aralığında yapılmış ve elde edilen sonuçlara göre *SGO* miktarı -1 dB olduğu durumda en iyi sonuç, yani %93.75 oranı elde edilmiştir. Bu makalede modülasyon türleri $f_s = 40$ KHZ, $f_c = 10$ KHZ ve $R_{Symb} = 1200$ bps parametre miktarları ile oluşturulmuştur. Bu çalışmada özellik setini oluşturmak için

$\left| \frac{CUM_{40}}{CUM_{42}} \right|$, $\left| \frac{CUM_{41}}{CUM_{42}} \right|$ ve $\left| \frac{CUM_{41}^2}{CUM_{20}} \right|$ oranlarına sahip YMK değerleri kullanılmıştır.

Çalışma [21]'de Ataollah Ebrahimzadeh ve M. Hossienzadeh tarafından önerilen algoritma; özellik çıkarma, sınıflandırma ve optimizasyon adlı üç alt bölümden oluşmuştur. Bu algoritmanın özellik çıkarma kısmında sinyalin γ_{max} , σ_{ap} , σ_{dp} gibi anlık özellikleri ve dördüncü mertebeli momentleri kullanılmıştır. Bu çalışmada 2-ASK, 4-ASK, BPSK, QPSK, 2-FSK, 4-FSK, 16-QAM modüleli sinyalleri sınıflandırmak için iki katmanlı RBFN tekniği kullanılmıştır. Bu sınıflandırıcının nöron sayısı optimizasyon işlemi ile belirlenmiştir. Sınıflandırma performansını yükseltmek için kullanılan optimizasyon tekniği genetik algoritma tekniğidir. Önerilen algoritmanın başarı performansı *SGO* miktarı -3 dB olduğu durumda %91 ve *SGO* miktarı 6 dB olduğu durumda %99 olmuştur.

Xin ZHOU ve arkadaşları diğer bir çalışmada ise [22], giriş sinyalinin YMK'lerinin ikinci, dördüncü ve altıncı mertebesinde elde edilen verileri kullanarak özellik vektörünü oluşturmuşlardır. Bu çalışmanın eğitim aşamasında her modülasyon formatından 100 adet gerçekleştirilmiş modüleli işaret kullanılmıştır. Daha sonra radyal tabanlı çekirdek kullanarak destek vektör makineleri (DVM) ile sınıflandırıcısı ile sınıflandırma işlemi yapmışlardır. Bu çalışmada, en iyi sonuç *SGO* miktarı 5 dB olduğunda elde edilmiştir. *SGO* miktarı 5 dB olduğunda, bu çalışmada kullanılan 4-ASK, 2-ASK/ BPSK, QPSK, 2-FSK, 8-FSK ve 16-QAM modülasyonları sırasıyla %92.2, %100, %99.4, %100, %97.4, %97, %89.2 başarıyla sınıflandırılmıştır. Bu çalışmada örnekleme frekansı 40 KHZ, taşıyıcı frekansı 8 KHZ, sinyal uzunluğu 1200 seçilmiştir.

M. Hadi Valipour ve arkadaşları [23] 2-ASK, 4-ASK, 8-ASK, 16-ASK, 2-FSK, 4-FSK, 8-FSK, BPSK, QPSK, 8-PSK, 16-PSK, 16-QAM, 32-QAM ve 64-QAM gibi modülasyon türleri arasında ayırım yapmak için yeni bir modülasyon sınıflandırma yöntemi önermişlerdir. Bu modülasyonlar arasında ayırım yapmak için sinyalin γ_{max} , σ_{ap} , σ_{dp} , σ_{aa} , σ_{af} gibi anlık özellikleri, YMM'lerinin ikinci, üçüncü ve dördüncü mertebelerinden elde edilen özellikleri ve SDD'nin YMM'leri özellik vektörü olarak kullanılmıştır. SDD'de Haar dalgacığı ana dalgacık olarak seçilmiştir. Bu çalışmada sınıflayıcı olarak DVM sınıflandırıcısı kullanılmıştır. Bu çalışma *SGO* miktarı 0 dB olduğu durumda %96 başarı ile sonuçlanmıştır.

Kaynak [24]'te Ataollah Ebrahimzadeh 2-ASK, 4-ASK, 2-FSK, 4-FSK, BPSK, QPSK, 16-QAM ve 64-QAM modülasyonları arasında sınıflandırma yapmak için çalışmıştır. Bu çalışmada sinyalin σ_{af} , γ_{max} ve σ_{fn} gibi spektral özellikleri ve YMM ve YMK'lerinden elde edilen değerler kullanarak özellik vektörü oluşturulmuştur. Kullanılan

modülasyonlar arasında ayırışım yapmak için RBFN sınıflandırıcısı kullanılmıştır. Bu çalışmada *SGO* miktarı 9 dB olduğunda 2-ASK, 4-ASK, 2-FSK, 4-FSK, BPSK, QPSK, 16-QAM ve 64-QAM modülasyonları sırası ile %89, %87, %94, %90, %94, %87,%85 ve %86 ve *SGO* miktarı 6 dB olduğunda %85, %78, %84, %82, %76, %71, %74 ve %68 başarısı ile sınıflandırılmıştır.

Çalışma [25]'te Ahmet Güner ve arkadaşları taşıyıcı frekans kaymasına maruz kalmış BPSK, QPSK, 8-PSK, 16-QAM, 32-QAM ve 4-ASK modüleli sinyallerin sınıflandırılması için sinyallerin yıldız kümesi histogramını ve YMK'lerinden öznelik olarak kullanmışlardır ve sinyalin dönmüş olan yıldız kümesi noktalarının yeniden düzenlemesi için faz farkı yöntemini kullanmışlardır. Bu çalışma farklı *SGO* seviyelerinde yapılmış ve karar ağacı yapısı ile sınıflandırılmıştır. Çalışmanın sonuçlarına göre bu algoritma ile frekans kayması etkisi varken ve $SGO \geq 8$ dB olduğunda daha iyi sonuçlar elde edilmiştir. Bu çalışmada $SGO = 8$ dB olduğunda BPSK, QPSK, 8-PSK, 16-QAM, 64-QAM ve 4-ASK modüleli işaretler sırasıyla %97.9, %100, %97.7, %99.8, %99.4 ve %100 başarısıyla sonuçlanmıştır. Ayrıca bu çalışmada önerilen algoritma ve diğer bir çalışma sonuçları karşılaştırılmıştır ve bu makalede önerilen algoritmanın sınıflandırma işleminde etkin olduğu gösterilmiştir.

Çalışma [26]'da Mumammad Waqar ve arkadaşları otomatik modülasyon tanıma işlemini yapmak için yeni bir algoritma önermişlerdir. Bu çalışmada Genetik algoritması ve en yakın komşu yönteminden yararlanmışlardır. Bu sınıflandırma işleminde sinyalin YMK'lerinden özellik seti oluşturmada kullanmışlardır. Önerilen algoritma BPSK, QPSK, 16-QAM ve 64-QAM modülasyonlarının sınıflandırmasında kullanılmıştır. Sınıflandırma kısmında iki aşamalı bir sınıflandırıcı kullanılmıştır. Birinci aşamada bu modülasyon türleri, üç farklı sınıfa ayrılır (BPSK, QPSK ve QAM). İkinci aşamada ise üçüncü sınıf (QAM sınıfı) 16-QAM ve 64-QAM sınıflarına ayrılır. Sonuç olarak, bu algortmada *SGO* miktarı 4 ile 20 dB arasında olduğunda BPSK, QPSK, 16-QAM ve 64-QAM modüleli sinyaller yüksek başarı ile sınıflandırılmıştır. Bu çalışmanın giriş örnek sayısı 2048 olarak seçilmiştir. Sonuç olarak *SGO* miktarı 4 dB olduğunda kullanılan modüleli işaretler sırasıyla %100, %96.99, %81.18 ve %79.26 başarılarıyla sınıflandırılmıştır.

Çalışma [27]'de M. Farhang ve arkadaşları QPSK, 8-PSK, 16APSK ve 32APSK sistemlerinde kullanılan modülasyon türlerini sınıflandırmak için yeni ve farklı bir yöntem önermişlerdir. Önerilen bu farklı algortmada, farklı alıcılar aynı zamanda sınıflandırma yapma işleminde kullanılmıştır. Bu algortmada üç boyutlu özellik vektörünü oluşturmak

için, sinyalin YMK'lerinin yedinci, sekizinci ve altıncı mertebeye değerleri kullanılmıştır. Üç alıcı aynı zamanda özellik çıkarma işlemi yaptıktan sonra üç farklı sınıflandırma işlemi yapılır. Sonraki aşamada farklı sınıflandırıcıların sonuçlarına göre giriş sinyalinin modülasyon türü belirlenir. Bu çalışmada YSA sınıflandırıcısı kullanılmıştır. Bu çalışmada *SGO* miktarı -4 ile 10 *dB* arasında seçilmiştir.


Başka bir makalede Ataollah Ebrahimzade Shermeh ve arkadaşları [28], toplanır Beyaz Gauss gürültülü kanala maruz kalmış 4-ASK, 8-ASK, BPSK, QPSK, 8-PSK, 8-QAM, V29, 32-QAM ve 64-QAM modülasyonların sınıflandırılmasına yeni bir yöntem önermişlerdir. Bu algoritmada alınan sinyallerin YMM ve YMK'lerinden elde edilen özelliklerden yararlanarak SVM tabanlı bir sınıflandırma tekniği, sınıflandırıcı teknik olarak önerilmiştir ve bu önerilen algoritmanın başarımı SCG algoritması ile karşılaştırılmıştır. Önerilen bu algoritmada *SGO* miktarı 3 *dB*'den büyük olduğunda 4-ASK, 8-ASK, BPSK, QPSK, 8-PSK, 8-QAM, V29, 32-QAM ve 64-QAM modülasyon tipleri sırasıyla %98, %98, %100, %100, %97, %96 ve %96, %94 ve %92 başarı ile sınıflandırılmıştır.

1.3. Gürültü

Aslında gürültü kendi kaynağına göre bilgi veren ve haberleşme sistemlerinde alıcının istenen sinyali algılama becerisini etkileyen istenmeyen sinyaldir [29]. Gürültü kaynakları sistemin içinde veya dışında olabilir. Atmosferik gürültü, galaktik gürültü ve insan yapımı istenmeyen sinyallerini kapsayan gürültüler dış gürültü olarak adlandırılır. İç gürültü ise elektronik devrelerindeki voltajdan meydana gelen gürültü türünü kapsamaktadır [4].

1.3.1. Toplanır Gürültü

Şekil 2'de Gösterilen iletişim sistemi modelinde $X_0(t)$ vericinin girişi olarak tanımlanır ve rastgele süreciyle modellenilen işarettir. Kanal, toplanır rastgele gürültü dışında başka bir bozulmaya neden olmayan bloktur. Alıcı ise doğrusal bir sistemdir. Bu Şekil 2'de gözüktüğü gibi alıcı bloğun girişinde, gürültüye karışmış bir sinyal vardır [30].



Şekil 2. Bir iletişim sistemi modeli

Alıcı doğrusal olduğundan, alıcı çıkışı denklem 1 biçiminde yazılabilir.

$$Y_0(t) = X_0(t) + n_0(t) \quad (1)$$

Burada $X_0(t)$ giriş sinyali ve $n_0(t)$ ise gürültü bileşenidir.

1.3.2. Sinyal Gürültü Oranı

Haberleşme sistemlerinin performansını değerlendirmede en çok kullanılan ölçütlerden birisi ve sistem tasarımlarında önemli bir parametre sayılan *SGO*, işaretin gürültüye oranıdır. *SGO*, işaret seviyesinin gürültü seviyesinden farkını ifade eder ve belirlenen bant genişliği içerisinde, desibel (*dB*) ölçümü ile tanımlanır. *SGO*'nun birimi olarak tanımlanan *dB*'nin orijinal tanımı, iki güç seviyesinin karşılaştırılmasına dayanır. Çıkış gücünün giriş gücüne logaritmik oranınının 10 katı bize *dB* seviyesini verir [31].

$$SGO(dB) = 10 \log_{10} \frac{P_1}{P_2} \quad (2)$$

Denklem 2'de P_1 Sinyal gücünü ve P_2 gürültü gücünü ifade eder. Bu denklemde belirlendiği gibi *dB* mutlak bir birim değildir, iki farklı büyüklüğün karşılaştırılmasıdır.

1.4. Dağılım/Yaygınlık Ölçüleri

Veri kümelerinin dağılım şekli ve değişkenlik durumunu tespit etmek için kullanılan ölçülere yaygınlık ölçüleri denilir. Standart hata, dağılım aralığı, varyans ve standart sapma

ölçüleri yaygınlık ölçülerinin en önemli ve kullanışlı türlerindendirler [32]. Bu çalışmanın özellik çıkarma aşamasında standart sapma ölçüsü kullanılmıştır.

1.4.1. Standart Sapma

Bir veri kümesinin her bir elemanının ortalamaya göre ne uzaklıkta olduğunu gösteren bir ölçüdür (denklem 3). Dağılımın yaygınlaşması ile standart sapma ölçüsünün arasında doğrusal bir ilişki vardır. Yani dağılım yaygınlaşmasının sonucunda standart sapma ölçüsünde büyümektedir [32].

$$SS = \sqrt{\frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n}} \quad (3)$$

Bu denklemde n örnek sayısı, x_i i' inci örnek sayısını ve \bar{x} ise n sayıda örneğin ortalamasını ifade etmektedir.

1.5. Modülasyonun Gerekliliği

İletilmesi istenen bilgilerin hızlı, sağlıklı ve en uzak mesafelere ulaşabileceği haberleşme sistemlerinin en önemli problemlerindendir. Pratik olarak bilgi işaretinin gideceği mesafenin sınırlı olması, çevreden karışan başka bozucu etkileri ve çok geniş haberleşme sistemlerinin gerçekleşmesinin pahalı ve imkânsız olması gibi olumsuzluklardan dolayı iletilecek bilgi sinyali verici tarafında değiştirilerek iletilir. Bu sebeplerden dolayı alçak frekanslı bilgi işaretini daha yüksek frekanslı taşıyıcı işaretiyle birleştirilerek iletilmesi çözümü (modülasyon) ortaya atılmıştır. Yani modülasyon işlemi iletilmesi, istenen bilgi işaretinin oldukça uzak mesafelere iletimini sağlar ve verimli, hızlı ve ekonomik haberleşme sistemlerini gerçekleştirilmesinde oldukça kolaylık sağlar. Modülasyonun haberleşme sistemlerinde sağladığı kolaylıkların bazıları aşağıda özetlenecektir.

- Bilgi işaretinin alçak frekanslı olmasından dolayı bunların doğrudan iletilmesi için kilometrelerce uzunlukta antenler gerektirir. Bu yüzden alçak frekanslı bilgi işaretini yüksek frekanslı taşıyıcı işaretiyle bindirilerek iletilmesi, gerekli anten boyutlarının küçültülmesine sebep olmaktadır.

- Modülasyon dünya yüzünde kullanılan pek çok verici ve alıcıların frekanslarını kendileri için ayrılan frekans bölgesine kaydırılmasını sağlamaktadır.
- Modülasyon haberleşmede mevcut iletim ortamlarına uygun frekanslarda iletim yapmayı sağlamaktadır
- Bazı modülasyon türleri gürültü, girişim veya diğer türlü iletim bozucu etkenlerin etkisini azaltma özelliğine sahiptirler.
- Haberleşme sistemlerinin alıcı ve verici teçhizatının yapımının kolaylaştırılması uygun modülasyon seçimi ile gerçekleştirilebilir [34].

1.5.1. İkili Faz Kaydırmalı Anahtarlama

Çevre bozucu, gürültü ve girişimlerden en az etkilenen ve uydu haberleşme gibi haberleşme sistemlerinde sıkça kullanılan modülasyon türlerinden birisi ikili faz kaydırmalı anahtarlama sayısal modülasyonudur. Aynı zamanda pek çok haberleşme sistemlerinde kullanılan yüksek seviyeli modülasyon tiplerinin temelini teşkil eden modülasyon türüdür. İkili faz kaydırmalı anahtarlama modülasyonunda sayısal bilginin 0 ve 1 bitlerine bağlı olarak taşıyıcı sinyalin iki farklı fazı kullanılmaktadır. Yani ikili faz kaydırmalı anahtarlama modülasyonunda sinyalin genlik ve frekansı sabittir. İkili işaretleme için genel olarak iki taşıyıcı sinyalinin arasında 180° faz farkı kullanılmaktadır ve bunun nedeni elde edilen işaretin gürültülerden oldukça az etkilenmesidir. Yani ikili faz kaydırmalı anahtarlama modülasyonların fazları arasında 180° olacak biçimde seçilmesi hata olasılık performansı açısından da en uygun seçim olmaktadır [35]. BPSK modülasyonları için taşıyıcı frekansı f_c olmak üzere iletilen işaret genel olarak denklem 4 şeklinde ifade edilebilmektedir.

$$I(t) = \begin{cases} A \cos(2\pi f_c t + \phi_1), & \text{sayısal sembol 1 ise} \\ A \cos(2\pi f_c t + \phi_0), & \text{sayısal sembol 0 ise} \end{cases} \quad (4)$$

İkili faz kaydırmalı anahtarlama modülasyonları için taşıyıcı frekansı f_c olmak üzere, tipik olarak sembollerden biri için sıfır derece, diğer sembol içinse 180° fazlı taşıyıcı kullanılmaktadır. Bu durumda iletilen işaret denklem 5 şeklinde ifade edilebilmektedir [36].

$$I(t) = \begin{cases} A \cos(2\pi f_c t) & \text{sayısal sembol 1 ise} \\ A \cos(2\pi f_c t + \pi) & \text{sayısal sembol 0 ise} \end{cases} \quad (5)$$

1.5.2. M-li PSK

Çok seviyeli geçiş bandı iletimi faz kaydırmalı anahtarlama modülasyonunda taşıyıcı sinyalinin fazını ikiden fazla farklı değerler arasında anahtarlanmasından elde edilir. Yani tek bir taşıyıcının kullanılması ile daha fazla bilgi iletilmektedir. M-li PSK (M-PSK) iletimi gerçekleştirilmesi için M adet farklı faz değeri kullanılır. M parametresinin miktarı çok seviyeli geçiş bandı işaretlemesinde modülasyon türüne göre belirlenir. M-PSK iletimlerinde her bir bit grubu için farklı bir taşıyıcı sinyali kullanılır ve bu iletimin sonucunda her bir bit grubunu temsil ettiği bilgi iletilir. Çok seviyeli iletimlerde k adet ikili bit gruplandırılmasının sonucunda $M = 2^k$ farklı grub oluşmaktadır ve M adet farklı taşıyıcı sinyali kullanılarak elde edilen bilgi grupları iletilmektedir. Yukarıda söylenildiği gibi bu durumda her bir bit grubu k adet bitten oluşmakta ve her bir bit grubu bir sembol şeklinde iletilmektedir. Burada r_b ikili bilgi işaretinin bit oranını gösterdiği takdirde sembol oranı r_b/k olarak tanımlanmaktadır. 2π radyanlık faz uzayının M eşit parçaya bölünmesi sonucunda M adet farklı taşıyıcı fazını kullanan M-li PSK (M-PSK) modülasyonunun iletim işlemi için kullanılacak taşıyıcı sinyalinin fazları bulunabilmektedir. Bu nedenle f_c frekansında M-PSK iletimi yapmak için kullanılacak taşıyıcılar genel olarak denklem 6 şeklinde ifade edilebilir.

$$I(t) = A \cos\left(2\pi f_c t + k \frac{2\pi}{M}\right), \quad k = 0, 1, 2, \dots, M-1 \quad (6)$$

M-li PSK iletiminde M adet sembol kullanıldığında her bir grubunun içerisinde k adet ikili bit mevcut olmaktadır.

$$M = 2^k \quad (7)$$

M-li PSK modülasyonlarının sembol oranı her bir grup, bir adet taşıyıcı ile iletildiği durumda denklem 8 ve 9 ile elde edilmektedir.

$$r_s = \frac{r_b}{k} \quad (8)$$

$$r_s = \frac{r_b}{\log_2 M} \quad (9)$$

Fakat uygulamalarda M-PSK için kullanılabilir taşınıcı sayısında pratik bir sınırlama bulunmaktadır ve bunun nedeni taşınıcı sinyal sayısı arttığında iletim için kullanılan gerekli bant genişliğinin azalmasıdır. Yani çok seviyeli iletimlerde sembol sayısı arttığında iki komşu taşınıcı sinyalin arasındaki faz farkı da azalmaktadır ve bu gürültü parametresinden daha fazla etkilenme anlamına gelir [36].

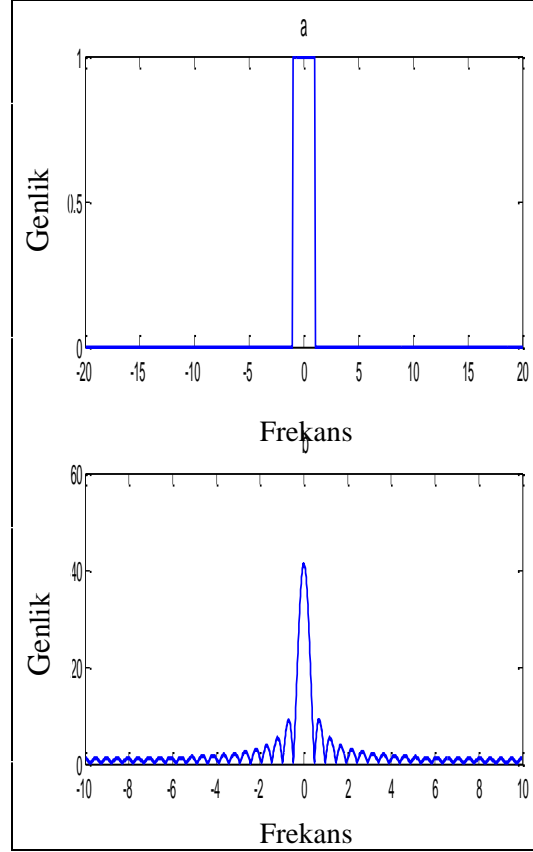
1.5.3. Karesel Genlik Modülasyonu

Haberleşme sistemlerinde sıkça kullanılan diğer bir modülasyon tipi, QAM modülasyonudur. Kullanılan bu teknikte iletilmesi istenen semboller taşınıcının hem farklı fazlarında, hem de farklı genliklerinde dağılır. Yani taşınıcının fazı ile genliği beraber modüle edilir. Bu tekniğin sonucunda taşınıcı sayısı artmakta ve kullanılan bant genişliği etkili bir şekilde kullanılmaktadır ve M-PSK modülasyonundaki taşınıcı sinyal sayısının sınırlılığı aşılmaktadır. Karesel genlik modülasyonları için en iyi performans, taşınıcıların fazör uzayında bir kare oluşturacak şekilde yerleştirilmesi sonucunda elde edilmektedir. Karesel olarak yerleştirilen genlik-faz anahtarlamalı modülasyonlar QAM (Quadrature Amplitude Modulation) olarak adlandırılır [36]. Genelde QAM modülasyonunda farklı sembol sayısı iletilmesine bağlı olarak çeşitli tiplerde QAM modülasyonları bulunmaktadır. 16-QAM, 32-QAM, 64-QAM, 128-QAM ve 256-QAM modülasyon tipleri en yaygın kullanılan QAM modülasyon tiplerindedir. Dijital radyo, dijital video, karasal mikrodalga ve modemler QAM modüleli işaretlerin kullanım alanlarındadırlar [37].

1.6. Semboller Arası Karışma

Sayısal sinyal iletişimde, gönderilen veriler dikdörtgensel darbe biçiminde olduğunda, haberleşme kanalının bantı sınırlı olmasından dolayı işaretin frekans spektrumunda meydana gelen sınırlama sonucunda oluşan zaman düzlemindeki

yayımlar, diğer darbe zaman aralıklarına geçmekte ve simgeler arası girişim (ISI) (Şekil 3) oluşmaktadır. Yani pratikte kullanılan bant genişlikleri sınırlıdır ve dolayısıyla iletilen darbeler iletim esnasında kendi zaman dilimlerinden komşu zaman dilimlerine eğilim gösterir ve alıcıda algılanan komşu zaman dilimindeki sembollerin hata olasılığı artmaktadır. Sistemden yüksek bir performans elde etmek için semboller arası karışmanın etkisini oldukça azaltılması gerekmektedir [38].



Şekil 3. a) Dikdörtgensel darbe biçimindeki giriş işareti, b) Giriş işaretin frekans spektrumu

1.6.1. Darbe Biçimlendirme

Semboller arası karışma nedeniyle darbelerin komşu zaman dilimlerine taşmasından olabileceğince az etkilenmek için, alıcıda sembol zaman-dilimlerinin merkez noktasındaki işaret seviyelerine göre çözümleme yapılabilmektedir. Simgeler arası karışma durumunda sembol zaman-dilimlerinin merkez noktasında komşu zaman dilimindeki darbelerin karışma etkisi en düşük seviyede olmaktadır. Çünkü zaman dilimlerinin merkez noktası her


iki zaman dilimine en uzak mesfede bulunmaktadır. Bu nedenle simgeler arası karışmadan daha az etkilenmek için merkez-noktası sezici yapısı kullanılabilir. Merkez-noktası sezici yapısı kullanıldığında alıcı, her sembol zaman dilimlerinin orta noktasındaki işaret seviyesine göre çözümü yapmaktadır. Bu durumda simgeler arası karışma etkisinin olmaması için iletilen darbe biçiminin komşu zaman dilimlerinin orta noktasında sıfır değerini alması yeterli olmaktadır [36].

1.6.2. Yükseltilmiş Kosinüs Filtresi

Yükseltilmiş kosinüs filtresi, frekans tepkisi birden bire değil yavaşça sıfıra inen ve dürtü tepkisinin bir biçimli zaman aralıklarında (merkez dışında) sıfıra eşit olan darbe biçimlendiren filtredir. Yükseltilmiş kosinüs filtresi semboller arası girişimi en aza indirgeme özelliğinden dolayı sayısal modülasyonda darbe biçimlendirmekte yaygın olarak kullanılan filtrelerdendir. Bu filtrenin frekans yanıtı denklem 10'daki gibidir.

$$H_{RC}(f) = \begin{cases} 1 & 0 \leq f \leq \frac{1-\alpha}{2T} \\ \frac{1}{2} \left[1 + \cos\left(\frac{\pi|f|2T-1+\alpha}{2\alpha}\right) \right] & \frac{(1-\alpha)}{2T} \leq |f| \leq \frac{(1+\alpha)}{2T} \\ 0 & |f| \geq \frac{(1+\alpha)}{2T} \end{cases} \quad (10)$$

İfade 10'daki α parametresi azaltma yoksa yuvarlama faktörü olarak tanımlanmaktadır. Bu faktör sıfır ile bir arasında değişen değere sahiptir. $\alpha = 0$ olduğunda yükseltilmiş kosinüs filtresi en az bant genişliğine sahip dikdörtgen filtreye karşılık gelir ve $\alpha = 1$ durumu tam kosinüs yuvarlama karakteristiği olarak belirlenir (Şekil 4). Uygulamada genelde 0.1 ile 0.35 arasında değişen azalma faktörü kullanılmaktadır.

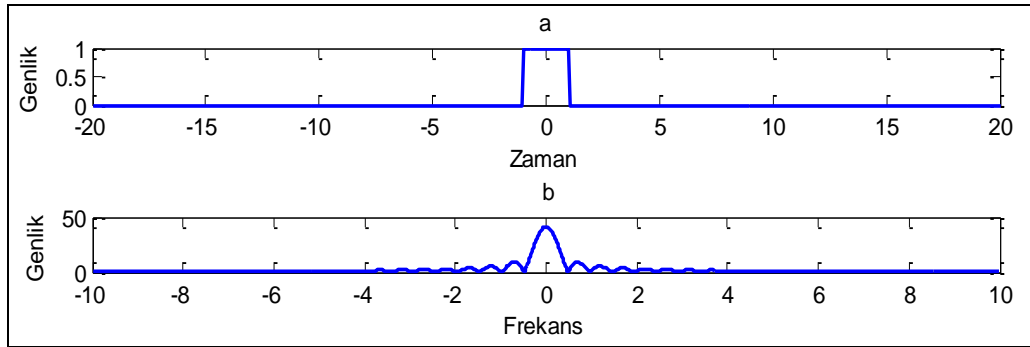


Şekil 4. Temel banttaki bir yükseltilmiş kosinüs filtresinin genlik transfer fonksiyonu

Yükselmiş kosinüs filtresinin vuruş tepkisi denklem 11’de verilmiştir [39].

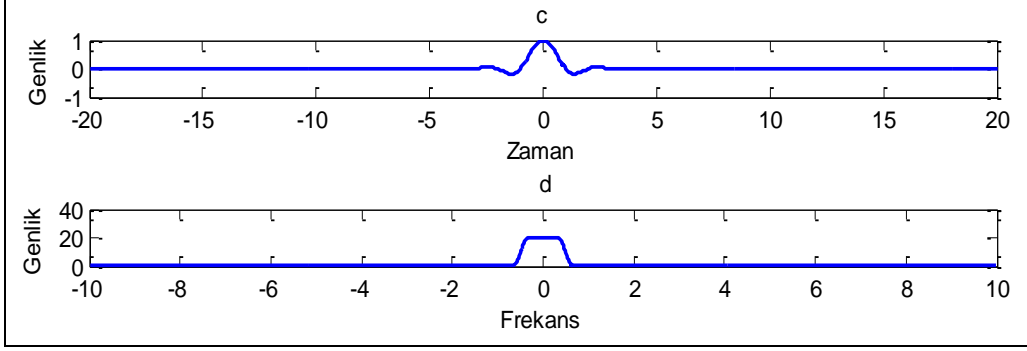
$$h_{RC}(t) = \left(\frac{\sin(\frac{\pi t}{T})}{\pi t} \right) \left(\frac{\cos(\pi \alpha t)}{1 - (\frac{4\alpha t}{2T})^2} \right) \quad (11)$$

Şekil 5’de yükseltilmiş kosinüs filtresinden geçirilmiş ve geçirilmemiş dikdörtgenel darbe biçimindeki giriş işareti gösterilmektedir. Bu şekil yükseltilmiş kosinüs filtresinin semboller arası girişimi en aza indirgeme özelliğini belirgin şekilde göstermektedir.



Şekil 5. a) Dikdörtgenel darbe biçimindeki giriş işareti, b) Yükseltilmiş kosinüs filtresinden geçirilmemiş işaretin frekans spektrumu, c) Zaman uzayında yükseltilmiş kosinüs filtrelenmiş giriş işareti, d) Yükseltilmiş kosinüs filtresinden geçirilmiş giriş işaretin frekans spektrumu

Şekil 5'in devamı

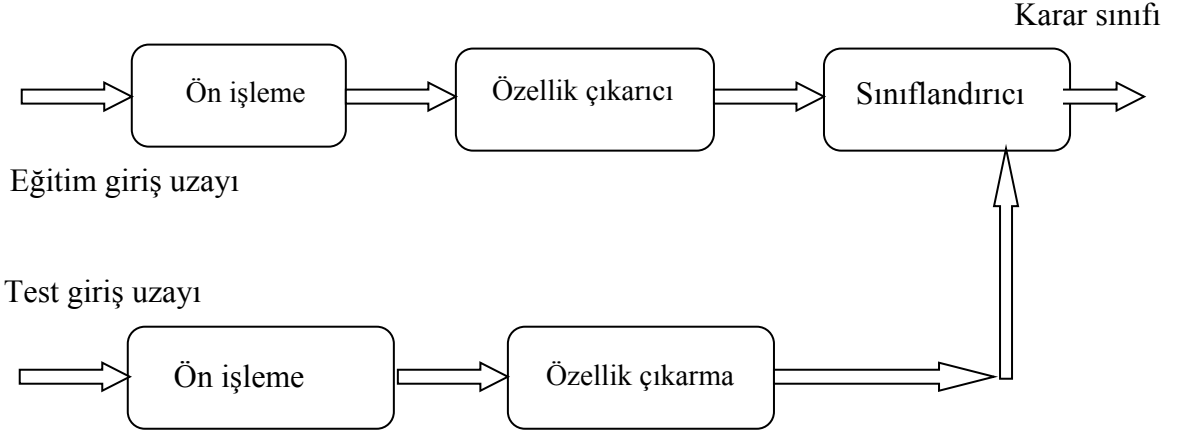


1.7. Örüntü Nedir?

Örüntü, standart sınıflandırma amaçlı n boyutlu özellik uzayındaki veriler kümesidir [40]. Başka bir ifade ile elemanları belirli bir yöntem veya şekilde birbirine benzeyen nesne, olay veya kavramlardır [41]. Metin içerisindeki karakterler, parmak izi, ses işareti, yaprak görüntüsü, normal ve hastalık belirtisi içeren işaretler, insan yüzü ve ayak izi, örüntüye dair bazı örneklerdir.

1.7.1. Örüntü Tanıma

Önceden tanımlanmış kategorilerden birine göre bir nesne ya da bir olayın otomatik etiketleme makine algılama sürecidir [42]. Başka bir ifade ile örüntü tanıma verilerin (özelliklerin) semboller (sınıflar) uzayına dönüştürme işlemidir. Yani sınıfı bilinmeyen örüntülere belirli bir şekil vermek ve bilinen bir sınıfa ait olan örüntüyü teşhis etmektir. Konuşma tanıma teknolojileri, tıp bilimleri, ses tanıma, hava değişim algılama, çiçek ve bilgi tanımlama, veri madenciliği, hedef tanıma, el yazısı ve parmak izi tanıma uygulamaları, deprem tahmini ve yüz tanıma uygulamaları örüntü tanıma uygulama alanlarındadırlar [43, 44]. Daha önceden eğitilmiş örüntü tanıma sistemi algılanan örüntülerin özelliklerini kullanarak bu örüntülerin hangi sınıfa ait olduğunu belirlemektedir. Örüntü tanıma sistemlerinin temel yapısı Şekil 6'da gösterilmiştir.



Şekil 6. Örüntü tanıma sisteminin genel yapısı

Şekil 6’da gösterildiği gibi örüntü tanıma sistemleri genel olarak üç temel aşamadan oluşmaktadır. Alınan sinyali kullanılan hale getirme işlemi ön işleme aşamasında yapılmaktadır. Sınıflandırma işlemi yapılması için alınan sinyalin gerekli özelliklerini çıkarma ve vektörel forma dönüştürülmesi ise özellik çıkarma aşamasında yapılmaktadır ve sınıflandırma aşamasında elde edilen özellik vektörler ve önceden eğitilmiş sınıflandırıcı sistemini kullanılarak algılanan sinyalin hangi sınıfa ait olduğu işlemi yapılmaktadır [45].

1.8. Ön İşleme

Otomatik modülasyon tanıma sistemlerinde güvenilirlik ve tanıma performansının artırılması için yapılan ön işleme işlemi çok önemli bir rol taşımaktadır. Ön işleme işlemi aşağıdaki nedenlerden dolayı yapılmaktadır [46].

- Kullanılan veri kümesi üzerinde analiz yapma işlemi engelleyebilen veri problemlerini çözme.
- Kullanılan veri kümesinden daha anlamlı bilgi çıkarma.
- Alınan veri kümesinin doğasının daha kaliteli anlaşılması

1.9. Özellik Çıkarma

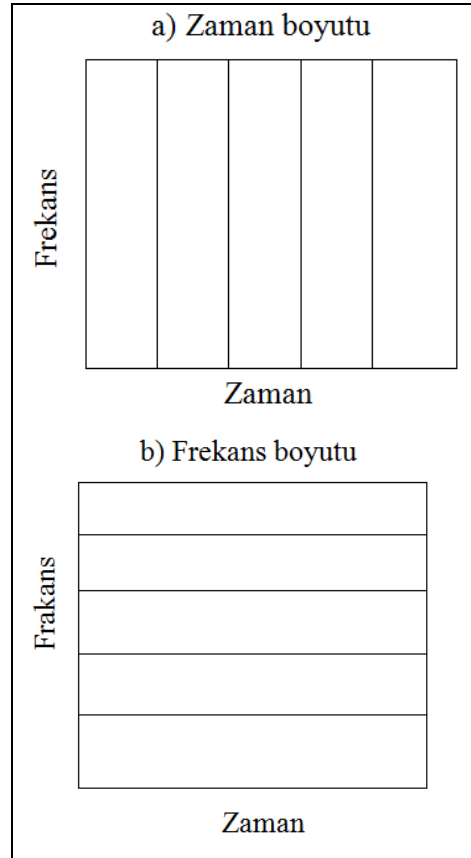
Haberleşme sistemlerinde modülasyon tipi tanımlama işlemi birçok nedenlerden dolayı son derece önemlidir. Örneğin haberleşme sistemlerinde modülasyon tipinin doğru olarak tanımlanmadan bilgi işaretini demodülatöre verilirse bilgi işaretine tamamen ya da kısmen zarar verebilir. Özellik çıkarma işleminde, kullanılan örüntülerin gerekli olmayan bilgilerini eleyerek örüntüye ait önemli kısımların elde edilmesi sağlanır. Yani bu aşamanın sonucunda her sınıfa ait olan karakteristik bilgiler elde edilir. Her sınıfa ait olan bilgileri elde etmek örüntüye bağlı olarak değişmektedir. Örneğin görüntü işleme problemlerinde görüntünün köşe, kenar ve histogramı gibi bilgiler özellik setinin elde edilmesinde kullanılabilir. Metin, kelime ve rakam tanıma uygulamalarında; metin, kelime yada rakam içerisindeki sembol veya adedin frekansı gibi özellikler çıkarımıyla özellik vektörü oluşturulmaktadır [45]. Otomatik modülasyon tanımlama uygulamalarında ise modülasyon tipi ve kullanım alanına bağlı olarak genlik histogramı, frekans histogramı, faz ayırım histogramı, genlik varyansı ve frekans varyansı, işaret parçalarının kuvvetli aralıklarında anlık fazın doğrusal olmayan bileşeninin standart sapması, işaretin zayıf olmayan aralığında anlık fazın doğrusal olmayan parçasının mutlak değerinin standart sapması, sürekli ve süreksiz dalgacık dönüşümünün farklı ölçekleri gibi özellikler kullanılmaktadır. Bu tez çalışmasında sinyalin SDD'sinden elde edilen özelliklerin standart sapması ve YMK'lerinden elde edilen özelliklerden, özellik vektörü oluşturmada yararlanılmıştır.

1.9.1. Kullanılan Özellik Çıkarma Yöntemleri

1.9.1.1. Sürekli Dalgacık Dönüşümü


Orijinal sinyallerden kolaylıkla elde edilemeyen bilgileri elde etmek için matematiksel dönüşümler kullanılır. Uygulamalarda kullanılan sinyallerin çoğu, zaman boyutundaki ham verilerden oluşmaktadır. Bir sinyalin zaman (bağımsız değişken) ve genlik (bağımlı değişken) ekseninde gösterilmesi, sinyalin zaman-genlik temsilini elde etmek anlamına gelir ama bu boyuttan elde edilen veriler (uygulama amacına bağlı olarak) her zaman elverişli olmayabilir. Birçok durumda sinyalin önemli özellikleri, sinyalin frekans içeriğinde gizli kalmaktadır. Yani bu önemli ve elverişli özelliklerin sinyalin

frekans içeriğinden elde edilmesi gerekir. Bir işaretin frekans içeriğindeki özelliklerini elde etmek için Fourier dönüşümü işlemi yapılır. Zaman boyutundaki sinyalin Fourier dönüşümünü elde etmek, o sinyalin frekans- genlik gösterimini elde etmek anlamına gelmektedir. Başka bir ifadeyle Fourier dönüşümü, işaretleri farklı frekanslardaki sinüs dalgalarına ayırır. Fourier dönüşümü ters çevirebilir bir dönüşüm yöntemidir. Elde edilen frekans boyutundaki verileri zaman boyutuna dönüştürme işlemi ters Fourier dönüşümü ile yapılmaktadır. Fourier dönüşümü ile frekans bilgileri hangi zamanlarda mevcut oldukları hakkında hiçbir bilgi elde edilemez. Örneğin EEG gibi sinyallerde belirli bir frekans bileşeni hangi anda meydana geldiği bilgisi çok önemli bir parametredir. Sinyallerin frekans boyutunda elde edilebilecek bilgileri zaman boyutlarında ve zaman boyutunda elde edilebilecek bilgileri frekans boyutunda mevcut olmamasından dolayı Fourier dönüşümlerinden daha elverişli olarak dalgacık dönüşümleri ön plana çıkmıştır (Şekil 7). Çünkü durağan sinyallerde frekans çözünürlüklü Fourier dönüşümü, duyulan ihtiyaçlara cevap verebilir ama sinyalin durağan olmadığı durumda aynı zamanda zaman bilgisi de gerektiğinden dolayı dalgacık dönüşümü yöntemleri daha fazla kullanılmaktadır [47].



Şekil 7. İşaretin farklı boyutlarda çözünürlük gösterimi

Şekil 7'nin devamı



Şekil 7'de gözüktüğü gibi zaman boyutundaki işaretin frekans çözünürlüğü hakkında ve frekans boyutundaki işaretin zaman çözünürlüğü hakkında hiç bir bilgi elde edilmez. Fakat zaman-frekans boyutundaki işaretin hem zaman ve hem frekans çözünürlüğü hakkında bilgi elde edilebilir [48]. Dalgacık dönüşümleri gürültüye karşı daha az hassasiyet gösteren ve rahatlıkla uygulanabilir yöntemlerdendir [49]. Sürekli dalgacık analizinde çeşitli irdeleme fonksiyon aileleri kullanarak, temel fonksiyonun farklı ölçeklerinden yararlanılır. Bu fonksiyon orijinal işaret üzerinde gezdirilirken hem yeri (öteleme) hem de büyüklüğü (ölçekleme) değiştirilir. Yani kullanılan farklı ölçekteki dalgacık fonksiyonlar, ana fonksiyonun farklı ölçekteki türleridirler. Fourier dönüşümünde sonsuz uzunlukta ve değişik frekanslardaki düzenli frekans dalgaları kullanılır fakat dalgacık dönüşümünde sınırlı süreli, düzensiz ve asimetrik ana dalgacık kullanılır [50]. Fourier dönüşümü matematiksel olarak denklem 12 ile ifade edilir.

$$F(\omega) = \int_{-\infty}^{+\infty} f(t)e^{-j\omega t} dt \quad (12)$$

Denklem 12'de gösterildiği gibi giriş sinyalin bütün zaman zarfında, karmaşık üstel bir çarpanla çarpımlarının toplamından elde edilen sonucu Fourier dönüşümünü ifade etmektedir. Dalgacık dönüşümü denklem 13 ile ifade edilir.

$$\text{CWT}(a, \tau) = \int_{-\infty}^{+\infty} s(t)\Psi_{a,\tau}^*(t)dt \quad (13)$$

Denklem 13’de $\Psi(t)$ ana dalgacık, τ öteleme faktörü ve a ölçekleme parametresini göstermektedir ve $*$ eşleniği simgelemektedir. Dalgacık fonksiyonları bir ana dalgacık, öteleme ve ölçekleme parametreleri yardımıyla elde edilir. Ana dalgacığın matematiksel ifadesi denklem 14’deki gibidir.

$$\Psi_{a,\tau}(t) = \frac{1}{\sqrt{a}} \Psi\left(\frac{t-\tau}{a}\right) \quad (14)$$

Denklem 14’te gösterildiği gibi enerjiyi normalize etmek için $\frac{1}{\sqrt{a}}$ katsayısı kullanılmıştır. Denklem 14 ifade denklemi denklem 13’te yerine konulmasından denklem 15 elde edilir.

$$\text{CWT}(a, \tau) = \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} s(t) \Psi^*\left(\frac{t-\tau}{a}\right) dt \quad (15)$$

Denklem 15’teki $s(t)$ dönüşümü yapılacak fonksiyon ve $\Psi(t)$ ise ana dalgacık fonksiyonudur. Denklem 16’daki fonksiyon, $s(t)$ ve ana dalgacık fonksiyonunun iç çarpımının diğer bir matematiksel yazılım biçimidir [51].

$$\text{CWT}(a, \tau) = \langle s(t), \Psi_{a,\tau}(t) \rangle \quad (16)$$

$\Psi_{a,\tau}(t)$ fonksiyonunda aşağıdaki koşulları gerekmektedir.

- $\Psi_{a,\tau}(t)$ fonksiyonunun integrali sıfır olması gerekir.

$$\int_{-\infty}^{+\infty} \Psi_{a,\tau}(t) dt = 0 \quad (17)$$

- $\Psi_{a,\tau}(t)$ fonksiyonu zaman açısından sınırlı olması gerekir.

$$\forall t \leq L_B \quad \Psi_{a,\tau}(t) = 0 \quad (18)$$

$$\forall t \geq U_B \quad \Psi_{a,\tau}(t) = 0 \quad (19)$$

- $\Psi_{a,\tau}(t)$ 'nin karesinin integrali bire eşit olması gerekir.

$$\int_{-\infty}^{+\infty} \Psi_{a,\tau}(t)^2 dt = 1 \quad (20)$$


Yukarıdaki koşulları sağlayan fonksiyon dalgacık olarak adlandırılır [47].

1.9.1.1.1. Haar Dalgacığı

Yukarıdaki koşulları sağlayan ve oldukça kullanılan dalgacık çeşitlerinden birisi Haar dalgacığıdır. Haar dalgacığının matematiksel gösterimi

$$\begin{cases} \Psi_{a,\tau}(t) = 1 & t \in [0, 0.5] \\ \Psi_{a,\tau}(t) = -1 & t \in [0.5, 1] \\ \Psi_{a,\tau}(t) = 0 & t \notin [0, 1] \end{cases} \quad (21)$$

şeklindedir. Şekil 8 Haar dalgacığıını grafiksel olarak göstermektedir.



Şekil 8. Haar dalgacığıını grafiksel ifadesi

1.9.1.2. Yüksek Mertebeli Kümülanlar

Bu bölümde otomatik modülasyon tanıma sistemlerinde kullanılan istatistiksel özelliklerden moment ve kümülanlardan bahsedilecektir. Momentler ve kümülanlar verilerin ayırt edici özelliklerinin belirlenmesinde kullanılan istatistiksel özelliklerdir. Bu istatistiksel özellikler, özellikle sinyal işleme alanlarında otomatik modülasyon tanıma

sistemlerinde kullanılır. Moment ve kümülanların otomatik modülasyon tanımada kullanımlarının asıl nedeni bu özelliklerin gürültülerden oldukça az etkilenmeleridir. Bu tez çalışmasında YMK'lerin dördüncü mertebelerinden elde edilen özelliklerden otomatik modülasyon tanıma sisteminde kullanılan özellik vektörlerini oluşturmada yararlanmıştır.

1.9.1.2.1. Moment

Momentler yaygın istatistiksel ortalama veya beklenen değerin genelleştirilmiş halidir. Olasılık teorisinde ayırık veriler kümesi elemanları ile o elemanların olasılık yoğunluk fonksiyonunun çarpımlarının toplanmasıyla beklenen değer miktarı elde edilir. Eğer X bir ayırık rastgele değişken varsayılırsa X veri setinin momentler seti denklem 22'de gösterildiği gibi elde edilir.

$$M_{ab} = E_{X,a,b} = E[x^a \cdot (x^*)^b] , \quad for \quad a, b \in Z \quad (22)$$

Simulink modelinde, beklenen değer miktarı toplama işlemi ile yaklaştırılır. Bu çalışmada kullanılan veriler sınırlı uzunlukta olmasından dolayı toplama işlemi sonsuza kadar sürmemektedir. Toplam işlemi nihayetle n.inci miktarda bitmektedir. Yukarıda açıklanan beklenen değer kavramı rastgele momentlerin elde edilmesine yol açmaktadır. Giriş sinyalinin ortalama miktarı sifıra eşit olduğu varsayılan durumda elde edilen ikinci dereceli moment giriş sinyalin gücü olarak tanımlanmaktadır. Böylece ikinci dereceden moment miktarı $E\{X^2\}$ olarak tanımlanmaktadır. Bu özellik, sinyalin gücünün ortalamasını tarif etmektedir. Çünkü X^2 sinyalin gücünü elde etmekte kullanılan fonksiyondur. Böylece m.inci dereceden moment $E\{X^m\}$ fonksiyonu ile tanımlanmaktadır [52].

1.9.1.2.2. Yüksek Mertebeli Moment ve Kümülanlar

Kümülanlarda momentler gibi rastgele değişenlerin istatistiksel özelliklerindedirler. Yukarıdaki bölümde açıklanan momentler sonuçta kümülanları tanımlamak için kullanılan özelliklerdir. Tam olarak kümülanlar, moment üreten fonksiyonların geliştirilmesiyle üretilen kümülan fonksiyonlarıyla açıklanmaktadır.

Kaynak [52]'de kümülan özelliklerini üreten fonksiyon denklem 23'teki gibi tanımlanmıştır.

$$g(t) = \log(E\{e^{tx}\}) = \sum_{n=1}^{\infty} k_n \frac{t^n}{n!} \quad (23)$$

Denklem 23'teki fonksiyonun türevinde $t = 0$ yapılırsa k_n gibi kümülan miktarını gösteren bir değer elde edilir. Bu fonksiyonun birinci türevinden elde edilen kümülan miktarı uygulanan işaretin ortalama miktarını göstermektedir. İkinci türevden elde edilen kümülan miktarı ele alınan işaretin varyansını ifade etmektedir. Yüksek dereceli kümülanlar ise ele alınan işaretin merkezi eğilim ölçütlerini ifade etmekte kullanılır. Ayrıca çift dereceli kümülanlar aynı veya düşük derecedeki momentlerle gerçekleştirilir ve kümülan miktarlarını hesaplama işleminde kolaylık sağlanır [53]. P'inci dereceden YMK'lerin simgesel olarak gösterimi, p'inci dereceden momentlerin göstermesine benzemektedir.

$$C_{ab} = \text{Cum} \left[\underbrace{s_1, \dots, s_a}_{(a) \text{ adet terim}}, \underbrace{s_1^*, \dots, s_b^*}_{(b) \text{ adet terim}} \right] \quad (24)$$

n 'inci derece ve daha düşük momentlerin bir fonksiyonu olan n 'inci dereceli kümülanların Leonov-Shiryaev denkleminden elde edilebilen 24 ifadesi denklem 25'le gösterilmektedir [54].

$$\text{Cum}[s_1, \dots, s_n] = \sum_{q=1}^n (-1)^{q-1} (q-1)! E[\prod_{j \in v_1} s_j] \cdots E[\prod_{j \in v_q} s_j] \quad (25)$$

Burada n indisli kümeler sayısını göstermektedir. $v = (v_1, \dots, v_q)$ mevcut bütün çarpımsal parçaları kapsamaktadır ve q ise verilen çarpımsal parça içerisindeki eleman sayısını göstermektedir. Örneğin $n=3$ olduğunda bu üç küme için beş farklı çarpımsal parça türü elde edilebilir.

$$\begin{aligned} \text{Cum}[s_1, s_2, s_3] = & (-1)^{1-1} (1-1)! E[s_1 s_2 s_3] + (-1)^{2-1} (2-1)! E[s_1] E[s_2 s_3] + \\ & (-1)^{2-1} (2-1)! E[s_2] E[s_1 s_3] + \\ & (-1)^{2-1} (2-1)! E[s_3] E[s_1 s_2] + \end{aligned}$$

$$\begin{aligned}
& (-1)^{3-1}(3-1)!E[s_1]E[s_2]E[s_3] \\
& = E[s_1s_2s_3] - E[s_1]E[s_2s_3] - E[s_2]E[s_1s_3] - E[s_3]E[s_1s_2] + \\
& \quad 2E[s_1]E[s_2]E[s_3]
\end{aligned} \tag{26}$$

Benzer şekilde, sekizinci dereceye kadar olan YMK ifadeleri hesaplanabilmektedir.

$$\begin{aligned}
\text{Cum}[s_1, s_2, s_3, s_4] & = E[s_1s_2s_3s_4] - E[s_1]E[s_2s_3s_4] - E[s_2]E[s_1s_3s_4] - \\
& \quad E[s_3]E[s_1s_2s_4] - E[s_4]E[s_1s_2s_3] - E[s_1s_2]E[s_3s_4] - \\
& \quad E[s_1s_3]E[s_2s_4] - E[s_1s_4]E[s_2s_3] + 2E[s_1]E[s_2]E[s_3s_4] + \\
& \quad 2E[s_1]E[s_3]E[s_2s_4] + 2E[s_1]E[s_4]E[s_2s_3] + \\
& \quad 2E[s_2]E[s_3]E[s_1s_4] + 2E[s_2]E[s_4]E[s_1s_3] + \\
& \quad 2E[s_3]E[s_4]E[s_1s_2] - 6E[s_1]E[s_2]E[s_3]E[s_4]
\end{aligned} \tag{27}$$

İfade 27 tekrar düzenlendiğinde (28) ifadesi elde edilir [55].

$$\begin{aligned}
\text{Cum}[s_1, s_2, s_3, s_4] & = E[s_1s_2s_3s_4] - E[s_1s_2]E[s_3s_4] - E[s_1s_3]E[s_2s_4] - \\
& \quad E[s_1s_4]E[s_2s_3]
\end{aligned} \tag{28}$$

Tablo 1’de moment cinsinden olan farklı derecedeki kümülan fonksiyonlarının elde edilme denklemleri göstermektedir [52]. Bu tabloda farklı mertebelerdeki kümülanlarda ($C_{s,a,b}$), s ele alınan sinyal a , ele alınan sinyalin gücü ve b ise eşlenik sinyalin gücü olarak tanımlanır. Özet olarak bu bölümde, geliştirilen modülasyon tanıma sisteminde kullanılan istatistiksel moment ve kümülan analizi açıklanmıştır. Momentlerin polinomları olarak ifade edilen YMK’ler iki farklı şekilde Tablo 1 ve 2’de gösterilmektedir.

Tablo 1. Momentlerin polinomları olarak ifade edilen YMK’ler-1

Derece	Kümülan	Momentler açısından açıklama
2	$C_{s,2,0}$	$E_{s,2,0} = E[x^2 \cdot (\bar{x})^0]$
2	$C_{s,1,1}$	$E_{s,1,1} = E[x^1 \cdot (\bar{x})^1]$
4	$C_{s,4,0}$	$E_{s,4,0} - 3 \cdot (E_{s,2,0})^2$
4	$C_{s,3,1}$	$E_{s,3,1} - 3 \cdot E_{s,2,0} \cdot E_{s,1,1}$
4	$C_{s,2,2}$	$E_{s,2,2} - (E_{s,2,0})^2 - 2(E_{s,1,1})^2$
6	$C_{s,6,0}$	$E_{s,6,0} - 15E_{s,2,0}E_{s,4,0} + 30(E_{s,2,0})^3$
6	$C_{s,5,1}$	$E_{s,5,1} - 10E_{s,2,0}E_{s,3,1} - 5E_{s,1,1}E_{s,4,0} + 30(E_{s,2,0})^2E_{s,1,1}$

Tablo 1'in devamı

6	$C_{s,4,2}$	$E_{s,4,2} - E_{s,2,0}E_{s,4,0} - 8E_{s,1,1}E_{s,3,1} - 6E_{s,2,0}E_{s,2,2}$ $+ 6(E_{s,2,0})^3 + 24(E_{s,1,1})^2 E_{s,2,0}$
6	$C_{s,3,3}$	$E_{s,3,3} - 6E_{s,2,0}E_{s,3,1} - 9E_{s,1,1}E_{s,2,2} + 18(E_{s,2,0})^2 E_{s,1,1} +$ $12(E_{s,1,1})^3$
8	$C_{s,8,0}$	$E_{s,8,0} - 35(E_{s,4,0})^2 - 630(E_{s,2,0})^4 + 420(E_{s,2,0})^2(E_{s,4,0})$
8	$C_{s,7,1}$	$E_{s,7,1} - 35E_{s,4,0}E_{s,3,1} - 630(E_{s,2,0})^3 E_{s,1,1}$ $+ 210E_{s,4,0}E_{s,2,0}E_{s,1,1} + 210E_{s,1,1}E_{s,3,1}$
8	$C_{s,6,2}$	$E_{s,6,2} - 15E_{s,4,0}E_{s,2,2} - 20(E_{s,3,1})^2 + 30E_{s,4,0}(E_{s,2,0})^2 +$ $60E_{s,4,0}(E_{s,1,1})^2 + 240E_{s,3,1}E_{s,1,1}E_{s,2,0} + 90E_{s,2,2}(E_{s,2,0})^2 -$ $90(E_{s,2,0})^4 - 540(E_{s,2,0})^2(E_{s,1,1})^2$
8	$C_{s,5,3}$	$E_{s,5,3} - 5E_{s,4,0}E_{s,3,1} - 30E_{s,3,1}E_{s,2,2} + 90E_{s,3,1}(E_{s,2,0})^2 +$ $120E_{s,3,1}(E_{s,1,1})^2 + 180E_{s,2,2}E_{s,1,1}E_{s,2,0} + 30E_{s,4,0}E_{s,2,0}E_{s,1,1} -$ $270(E_{s,2,0})^3 E_{s,1,1} - 360(E_{s,1,1})^3 E_{s,2,0}$
8	$C_{s,4,4}$	$E_{s,4,4} - (E_{s,4,0})^2 - 18(E_{s,2,2})^2 - 16(E_{s,3,1})^2 - 54(E_{s,2,0})^4 -$ $144(E_{s,1,1})^4 - 432(E_{s,2,0})^2(E_{s,1,1})^2 + 12E_{s,4,0}(E_{s,2,0})^2 +$ $96E_{s,3,1}E_{s,1,1}E_{s,2,0} + 144(E_{s,2,2})(E_{s,1,1})^2 + 72(E_{s,2,2})(E_{s,2,0})^2 +$ $96E_{s,3,1}E_{s,2,0}E_{s,1,1}$

Tablo 2. Momentlerin polinomları olarak ifade edilen YMK'ler-2

Derece	Kümülant	Momentler açısından açıklama
2	C_{20}	M_{20}
2	C_{11}	M_{11}
4	C_{40}	$M_{40} - 3M_{20}^2$
4	C_{31}	$M_{31} - 3M_{20}M_{11}$
4	C_{22}	$M_{22} - M_{20}^2 - 2M_{11}^2$
6	C_{60}	$M_{60} - 15M_{20}M_{40} + 30M_{20}^3$
6	C_{51}	$M_{51} - 10M_{20}M_{31} - 5M_{11}M_{40} + 30M_{20}^2M_{11}$
6	C_{42}	$M_{42} - M_{20}M_{40} - 8M_{11}M_{31} - 6M_{20}M_{22} + 6M_{20}^3 + 24M_{11}^2M_{20}$
6	C_{33}	$M_{33} - 6M_{20}M_{31} - 9M_{11}M_{22} + 18M_{20}^2M_{11} + 12M_{11}^3$
8	C_{80}	$M_{80} - 35M_{40}^2 - 630M_{20}^4 + 420M_{20}^2M_{40}$
8	C_{71}	$M_{71} - 35M_{40}M_{31} - 630M_{20}^3M_{11} + 210M_{40}M_{20}M_{11}$ $+ 210M_{11}M_{31}$
8	C_{62}	$M_{62} - 15M_{40}M_{22} - 20M_{31}^2 + 30M_{40}M_{20}^2 + 60M_{40}M_{11}^2 +$ $240M_{31}M_{11}M_{20} + 90M_{22}M_{20}^2 - 90M_{20}^4 - 540M_{20}^2M_{11}^2$
8	C_{53}	$M_{53} - 5M_{40}M_{31} - 30M_{31}M_{22} + 90M_{31}M_{20}^2 + 120M_{31}M_{11}^2 +$ $180M_{22}M_{11}M_{20} + 30M_{40}M_{20}M_{11} - 270M_{20}^3M_{11} - 360M_{11}^3M_{20}$
8	C_{44}	$M_{44} - M_{40}^2 - 18M_{31}^2 - 16M_{31}^2 - 54M_{20}^4 - 144M_{11}^4 -$ $432M_{20}^2M_{11}^2 + 12M_{40}M_{20}^2 + 96M_{31}M_{11}M_{20} + 144M_{22}M_{11}^2 +$ $72M_{22}M_{20}^2 + 96M_{31}M_{20}M_{11}$

1.10. Sınıflandırma Süreci

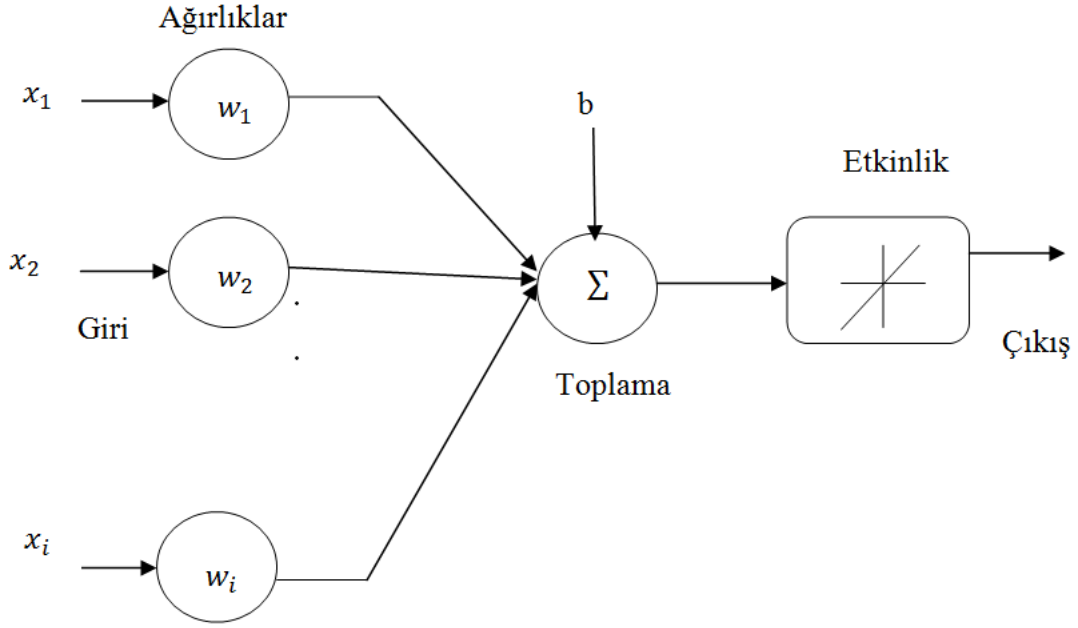
Bu tez çalışmasında sınıflandırma kısmında birinci sınıflandırıcı olarak üç seviyeli YSA ve ikinci sınıflandırıcı olarak BKB temelli DVM sınıflandırıcısı kullanılmıştır. Aşağıda bu sınıflandırma yöntemleri hakkında genel bilgiler verilmiştir.

1.10.1. Yapay Sinir Ağları

YSA'ların matematiksel modeli ilk olarak 1943 yılında McCulloch ve Pitts tarafından ortaya atılmıştır [54]. YSA sistemleri insanın biyolojik sinir sisteminin şeklinden esinlenerek tasarlanmıştır. Başka bir ifade ile insanın yaşayarak ve deneyerek öğrenme yeteneği bilgisayar üzerinde uygulanarak YSA sistemlerinin temeli kurulmuştur [55]. Bilim adamları beynin üstün özelliklerinden dolayı beyin üzerinde çalışmaya başlamışlardır ve nörofiziksel yapısını göz önüne alarak matematiksel modelini çıkarmaya çalışmışlardır. Böylelikle yeni ve kullanışlı bir bilim alanı ortaya çıkmıştır. YSA denilen yeni bilim dalı yapısı ve yararlarından dolayı çeşitli bilim dallarını kapsamaktadır. Bu sistemler bilgilerini öğrenerek elde ettikten sonra öğrendiği duruma benzer durumlarda benzer karar vermektedirler [56].

1.10.1.1. Yapay Sinir Ağlarını Oluşturan Kısımlar

Genellikle YSA sistemleri girişler, ağırlıklar, toplama fonksiyonları, etkinlik fonksiyonları ve çıkışlar kısımlarından oluşan sistemlerdir. Şekil 9'da gösterildiği gibi x ile belirlenen i sayısındaki girişlerin kendi ağırlıkları ile çarpılıp ve b eşik değeri ile toplandıktan sonra etkinlik fonksiyonuna tabi tutulur ve çıkış değeri elde edilir. Sigmoid, doğrusal, hiperbolik, tanjant ve keskin sınırlayıcı fonksiyonları en çok kullanılan etkinlik fonksiyonlarıdır [57].



Şekil 9. YSA’larda tipik bir işleme elemanı

1.10.1.2. Ağırlıklar

w_b ile gösterilen i sayıdaki ağırlıklar her giriş bilgisinin kendisine ait ve o bilgiyi etkileyen katsayılardır. Bağlılık değeri ile giriş bilginin sinire bağlılığının doğrusal bir ilişkisi vardır. Yani giriş bilgisinin sinire bağlılığı güçlü ise ağırlık değeri de büyük olmakta ve giriş bilgisinin sinire bağlılığı zayıf ise ağırlık değeri de küçük olmaktadır.

1.10.1.3. Toplama fonksiyonu


Şekil 9’da gösterildiği gibi x_i ile tanımlanan giriş bilgileri kendilerine ait ağırlıklar ile çarpılarak toplanırlar ve daha sonra sonra b ile tanımlanan eşik değeri ilave edilir.

1.10.1.4. Etkinlik Fonksiyonu

YSA’larda etkinlik fonksiyonuna bağlı olarak giriş ve çıkışlar arasındaki farklı bağlantılar sağlanmaktadır. Şekil 9’da gösterildiği gibi toplama işleminden elde edilen sonuçlar etkinlik fonksiyonundan geçirilir ve çıkış miktarı elde edilir. Şekil 10, 11 ve 12’de çeşitli etkinlik fonksiyonları gösterilmektedir [2].

- Eşik fonksiyon


$$y = \begin{cases} 1 & v \geq 0 \\ 0 & v \leq 0 \end{cases}$$



Şekil 10. Eşik etkinlik fonksiyonu

- Doğrusal fonksiyonu


$$y = v$$



Şekil 11. Doğrusal etkinlik fonksiyonu

- Tanjant hiperbolik fonksiyonu

$$y = \frac{1-e^{-v}}{1+e^{+v}}$$



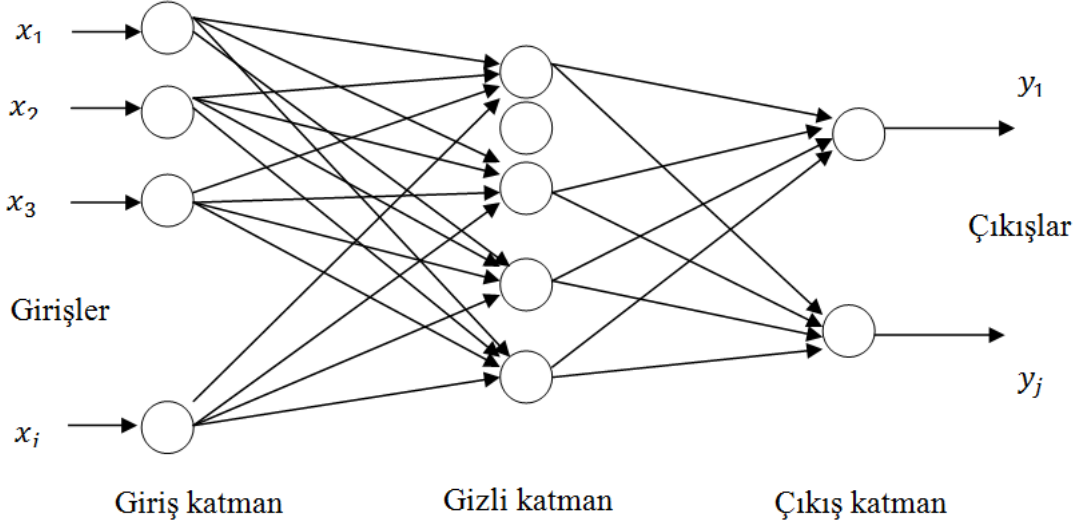
Şekil 12. Tanjant hiperbolik fonksiyonu

1.10.1.5. Yapılarına Göre Yapay Sinir Ağları

YSA'lar yapılarına göre farklı türlerde olabilirler ve türlerine göre farklı isimlere anılırlar. YSA'lar yapılarına göre geri beslemeli ve ileri beslemeli ağlar olmak üzere ikiye ayrılır.

- İleri beslemeli ağlar

Katman şeklinde düzenlenen hücrelerin çıkışları bir sonraki katmana giriş olarak verilir. Yani bir katmandaki hücreler sadece önceki katmanın hücrelerinin çıkışlarından beslenir. Giriş katmandaki hücreler aldığı bilgilerin üzerinde hiçbir işlem yapmadan sonraki katmandaki hücrelere iletir [58, 59]. Bu tip YSA'ların eğitiminde en çok bilinen geri yayılım öğrenme algoritması kullanılmaktadır. Örnek olarak Şekil 13'te üç katmanlı ileri beslemeli YSA sistemi gösterilmektedir [60].



Şekil 13. Üç katmanlı ileri beslemeli YSA

- Geri beslemeli ağlar

Geri beslemeli YSA’larda sonraki katmanlardan önceki katmanlara doğru ters yönlü ilişkiler vardır ve en az bir hücrenin çıkışı diğer hücreler ya da kendisine giriş olarak verilir. Yani sonraki nöronlar önceki nöronlara bağlı olduğundan dolayı yeni giriş vektörü olarak ağı etkilemektedir [58].

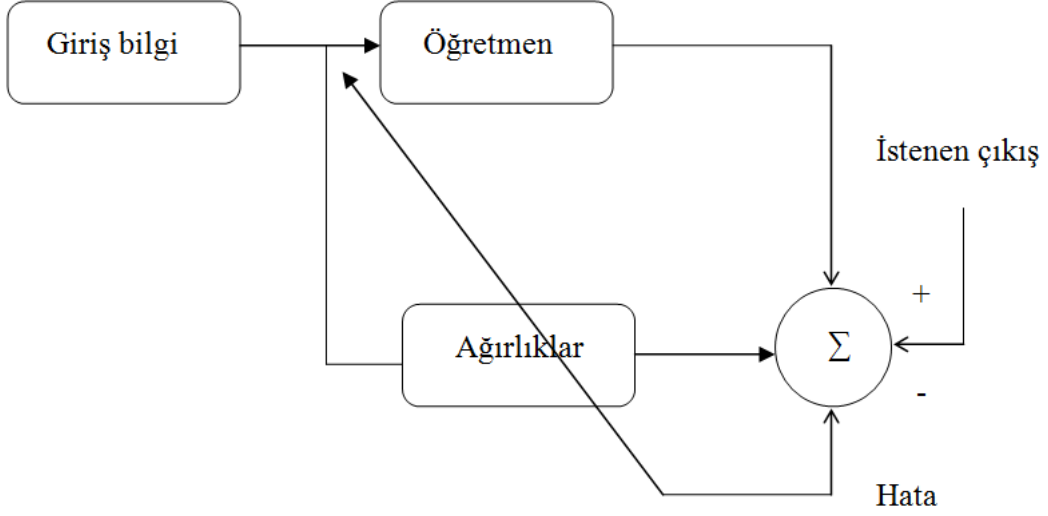
1.10.1.6. Yapay Sinir Ağlarının Öğrenme Yöntemleri

Genelde YSA’larda öğrenme yöntemleri danışmanlı ve danışmansız olmak üzere iki tip öğrenme yöntemi vardır.

- Danışmanlı Öğrenme Yöntemi

Danışmanlı öğrenme yöntemlerinde sinir ağlarına giriş ve çıkış bilgileri örnek olarak verilir. Başka bir ifade ile sistem, yapması beklenen işleme göre eğitilir. Sistem çıkışı ve istenen çıkış karşılaştırılır ve ağırlıklar miktarı değiştirilerek hata miktarı azaltılır. (Şeki 14).


Örneğin $(x_1, x_2, x_3, \dots, x_n)$ şeklinde giriş bilgi vektörü ve $(y_1, y_2, y_3, \dots, y_n)$ şeklinde gerçek çıkış vektörü belli olduğu durumda $(x_1, y_1), (x_2, y_2), (x_3, y_3), \dots, (x_n, y_n)$ çiftleri için sistem iyi sonuçlar elde edecek şekilde, seçilen bir öğrenme algoritmasıyla eğitilir.



Şekil 14. YSA’larda danışmanlı öğrenme [61].

- Danışmansız öğrenme yöntemi

Danışmansız öğrenme yöntemlerinde girdi değişkenleri vardır ama arzu edilen çıkışlar hakkında hiç bir bilgi yoktur. Yani ağın davranışını değiştirmek için kullanılan kesin bir hata bilgisi yoktur ve öğrenme, sisteme verilen giriş bilgilerden alınan cevapların gözlenmesi ile başarıya ulaşır (Şekil 15).



Şekil 15. YSA’larda danışmansız öğrenme [61].

1.10.1.7. Yapay Sinir Ağlarının Eğitimi

Çok katmanlı ağların eğitimi delta kuralının geliştirilmiş bir halini kullanarak yapılmaktadır. Delta kuralı en küçük kareler yöntemine bağlı bir kuraldır. Delta kuralında ileri doğru ve geriye doğru hesaplama işlemi yapılmaktadır. Ağa verilen yeni giriş verileri; giriş ve gizli katmanlardan geçerek çıkış katmana gitmektedir. Sistemin sonucunda; elde edilen çıkışlar ile giriş verilerine ait gerçek çıktılar karşılaştırılır ve bunların arasındaki

farkı göz önüne alarak ağırlıklar yeniden güncellenilir. Bu aşamada giriş örneklerin gerçek çıkış değerleri ve bu sistemden elde edilen çıkış değerlerinin arasındaki hatayı en düşük yapan ağırlıklar hesaplanmaktadır. Yani ağa sunulan giriş verileri için ağın ürettiği çıkış miktarı ile beklenen (istenen) çıkışlar karşılaştırılır. Bu iki miktarın arasındaki fark hata miktarı olarak kabul edilir. Bu aşamanın amacı bu hata miktarının oldukça aza indirgenmesidir. Yukarıda açıklanan delta kuralının geriye doğru hesaplama kısmında ise giriş örneğinin çıktısı (d_n) ile beklenen gerçek çıktı (y_n) arasındaki farka bağlı olarak hata değeri (E_n) denklem 29'daki gibi elde edilir.

$$E_n = \frac{1}{2}(y_n - d_n)^2 \quad (29)$$

Toplam hata denklem 30'dan elde edilir. Toplam hatayı en aza indirmek için katmanların ağırlıklarına göre türev alındıktan sonra elde edilen türev sifıra eşitlenir. İlk olarak çıkış katman ve bir önceki gizli katman arasındaki ağırlıklar güncellenilir.

$$E = \frac{1}{2} \sum_n (y_n - d_n)^2 \quad (30)$$

$$\Delta w_{ji}(n) = -\eta \frac{\partial E}{\partial w} \quad (31)$$

$$w_{ji}(n+1) = w_{ji}(n) + \Delta w_{ji}(n) \quad (32)$$

Sonraki aşamada gizli katman ile bir önceki katman arasındaki ağırlıklar miktarı güncelleşir [57].


1.10.2. Destek Vektör Makineleri

Makine öğrenme algoritmalarından birisi olan DVM'ler sınıflandırma probleminin çözülmesi için geliştirilmiştir. Bu sınıflandırma yöntemi 1995 yılında Vapnik ve Crotes tarafından ortaya atılan örüntü tanıma ve sınıflandırma yöntemidir [62]. Sınıflandırma problemini optimizasyon problemine dönüştürerek çözmek DVM'lerin en önemli avantajlarından. Bu özellikten dolayı DVM teknikleri diğer sınıflandırma tekniklerine göre daha başarılıdır [63, 64]. DVM'leri çok katmanlı YSA'ların tersine yapısal risk

minimizasyonu prensibine dayalı sınıflandırma yöntemidir. Başka bir ifade ile iki farklı sınıfa ait destek vektörler arasındaki mesafeyi maksimize etmek bu yöntemin önemli amaçlarındandır. DVM'ler doğrusal olarak ayıramadığı veri setlerini doğrusal olmayan yöntemlerle ayırma yeteneğine de sahiptir. İstatiksel öğrenme teorisine dayalı DVM'leri kontrollü sınıflandırma yöntemidir. Başlangıçta DVM'ler iki farklı sınıfa ait doğrusal veri setlerini sınıflandırma problemini çözmek için tasarlanmıştır. Daha sonra doğrusal olmayan çok sınıflı veri kümelerinin sınıflandırma problemlerinin çözümü için geliştirilmiştir [65].

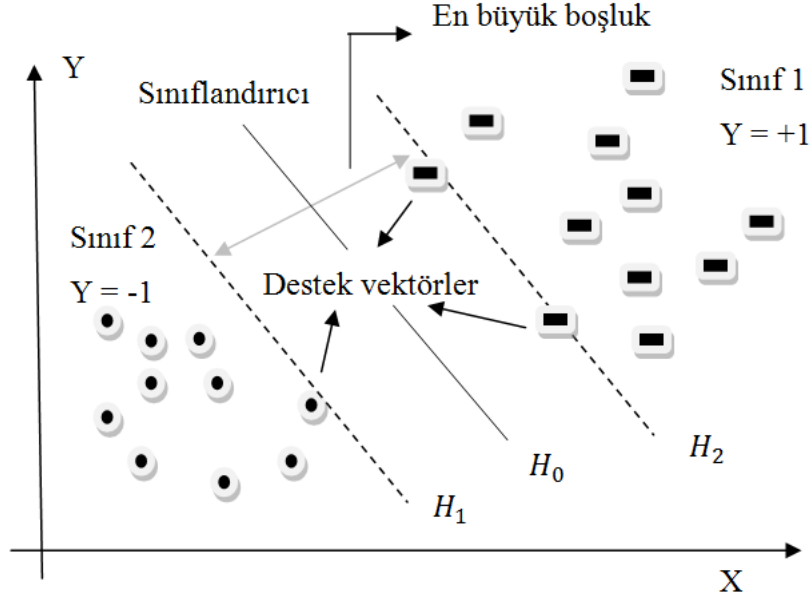
1.10.2.1. Verilerin Doğrusal Olarak Ayrılma Durumu

k sayıda örneklerden oluşan $(x_1, y_1), (x_2, y_2), (x_3, y_3), \dots, (x_k, y_k)$ biçiminde bir veri kümesini varsayalım. Burada $y \in \{-1, +1\}$ verilerin etiketlerini belirleyen elemanlar olduğu kabul edilir [66]. İki farklı sınıflı k sayıdaki veri kümesi Şekil 16'da yer almaktadır.



Şekil 16. DVM için doğrusal olarak ayrılabilen örnek

Bu k sayıdaki veri kümesini sınıflara göre ayırmak için birçok doğrusal düzlem kullanılabilir. Ama Şekil 17'de gösterildiği gibi DVM'ler iki sınıfa ait destek vektörlerinin arasındaki maksimum uzunluğu iki eşit yere ayıran doğrusal düzlemin bulmasını amaçlar [66].



Şekil 17. Doğrusal olarak ayrılabilen sınıflar için hiper düzlem belirlenmesi

Bu düzleme genel olarak optimal ayırma hiper düzlem denilir. Şekil 17’de gösterilen hiper düzlem üzerindeki H_1 ve H_2 düzlemleri denklem 33 ve 34 ile ifade edilir.

$$H_1 : w^T \cdot x_i + b \geq +1 \quad \text{her } y_i = +1 \text{ için} \quad (33)$$

$$H_2 : w^T \cdot x_i + b \leq -1 \quad \text{her } y_i = -1 \text{ için} \quad (34)$$

Yukarıdaki ifadelerde yer alan $y \in \{-1, +1\}$ sınıf etiketleridir. w ağırlık vektörünü ve b eğilim değerini gösteren sabit bir değerdir [67]. Denklem 33 ve 34’teki eşitsizliklerinin bir arada ifade edilmesi y_i parametresini eşitsizliklerin her iki tarafına çarpılmasından elde edilir.

$$y_i (w^T \cdot x_i + b) \geq +1 \quad \text{her } i \text{ için} \quad (35)$$

Yukarıda söylenildiği gibi DVM’lerde H_1 ve H_2 doğrusal düzlemlerinin arasındaki uzunluğu maksimize olması amaçlanır. Doğrusal düzlem ve orijin noktanın arasındaki uzaklık (R) genel halde denklem 36 ile hesaplanırken

$$R = \frac{|b|}{\|w\|} \quad (36)$$

H_1 ve H_2 düzlemler arasındaki uzaklığın maksimize olmasını sağlayan fonksiyon aşağıdaki gibidir.

$$\text{Minimizasyonu:} \quad \min \frac{1}{2} \|w\|^2 \quad (37)$$

$$\text{Kısıt:} \quad y_i (w^T \cdot x_i + b) \geq +1 \quad \text{her } i \text{ için} \quad (38)$$

Yani iki sınıf arasındaki uzaklığı maksimize eden en optimal ayırma doğrusal düzlemi fonksiyon yukarıda gösterilen optimizasyon probleminin çözülmesi ile elde edilir.

Denklem 37 çözülecek problem ve denklem 38 ise bu problemin çözümünde sağlanılan koşuldur. Bu optimizasyon problemi Lagrange çarpanlarını kullanarak çözülür. Çözülmesi istenen problem ve o problemin gerekli kısıtları Lagrange fonksiyonunda uygulanarak problemin Lagrange fonksiyonu denklem 39'da gösterildiği gibi elde edilir.

$$L_p = \frac{1}{2} \|w\|^2 - \sum_{i=1}^l \alpha_i y_i (w^T \cdot x_i + b) + \sum_{i=1}^l \alpha_i \quad (39)$$

Eşitlik 39'deki α_i Lagrange çarpanlarını ifade etmektedir. Elde edilen lagrange fonksiyonunda w ve b 'ye göre kısmi türev alınarak Korush-kuhn-tucher koşulları elde edilir. Elde edilen koşulları kullanarak denklem 39'daki ifade dual probleme dönüşür.

$$\frac{\partial L_p}{\partial w} = w - \sum_{i=1}^l \alpha_i y_i x_i \implies w = \sum_{i=1}^l \alpha_i y_i x_i \quad (40)$$

$$\frac{\partial L_p}{\partial b} = 0 \implies \sum_{i=1}^l \alpha_i y_i = 0 \quad (41)$$

$$\text{ve } \alpha_i > 0 \implies b = \frac{1}{N_{sv}} \sum_{i \in N_{sv}} (y_i - w^T x_i) \quad (42)$$

Elde edilen koşulları Lagrange fonksiyonunda yerleştirerek aşağıdaki denklem elde edilir.

$$L_D = \sum_i \alpha_i - \frac{1}{2} \sum_{i,j} \alpha_i \alpha_j y_i y_j x_i x_j \quad (43)$$

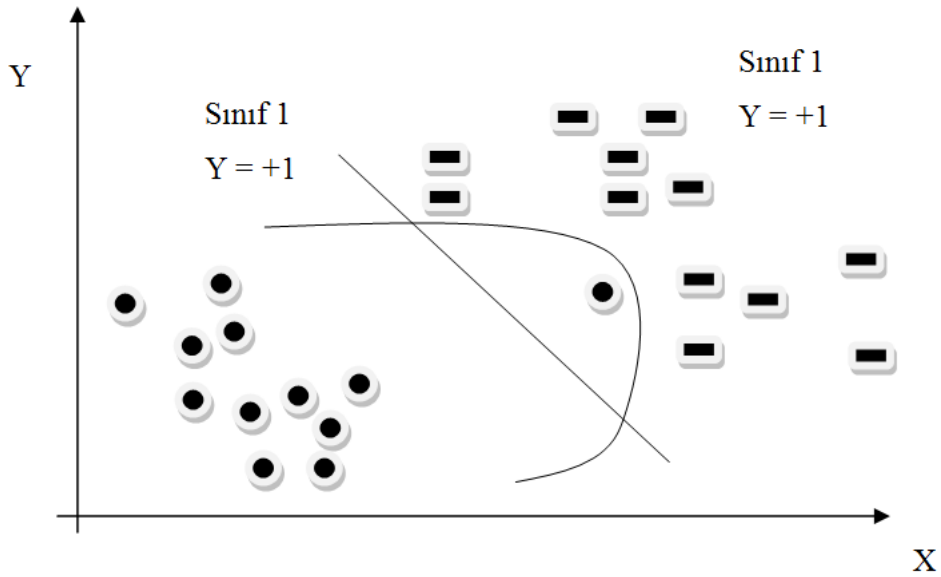
$$\alpha_i \geq 0 \quad \text{her } i \text{ için} \quad (44)$$

Bu durumda elde edilen yeni karar fonksiyonu aşağıdaki denklemde gösterilmiştir.


$$f(x) = \text{sign}(w^T x + b) \quad (45)$$

1.10.2.2. Verilerin Doğrusal Olarak Ayrılmama Durumu

Uygulamalarda iki farklı sınıfa ait veri kümelerinin doğrusal düzlemler ile ayrılmayabilir (Şekil 18). Bu durumlarda verilerin bir kısmı optimum hiper düzlemin diğer tarafında kalma (yerleşme) probleminin çözülmesi gerekir. Bu problemin çözülmesi için pozitif ve hataları gösteren bir gevşek değişken optimizasyon modeline eklenir ve ξ_i parametresi ile gösterilir (Şekil 19) [66].



Şekil 18. Doğrusal olarak ayrılmayan sınıflar için örnek



Şekil 19. Doğrusal olarak ayrılamayan sınıflar için hiper-düzlem belirlenmesi

Bu durumda H_1 ve H_2 düzlemleri şu şekilde ifade edilir.

$$H_1 : w^T \cdot x_i + b \geq +1 - \xi_i \quad \text{her } y_i = +1 \text{ için} \quad (46)$$

$$H_2 : w^T \cdot x_i + b \leq -1 - \xi_i \quad \text{her } y_i = -1 \text{ için} \quad (47)$$

Bu tür bir genelleştirilmiş fonksiyon C parametresi ile ifade edilen bir ilave terime sahiptir. Bu pozitif düzenleme parametresi sınırın maksimum hale getirilmesi ve yanlış sınıflandırma hatalarının minimum hale getirilmesi arasındaki dengeyi kontrol etmektedir. $C > 0$, kullanıcı tarafından seçilen bir sabittir. Bu durumda optimizasyon problemi aşağıdaki şekle dönüşür.

$$\text{Min} \left[\frac{1}{2} \|w\|^2 + C \sum_i \xi_i \right] \quad (48)$$

$$\text{Kısıtlar: } y_i (w^T x_i + b) \geq +1 - \xi_i \quad (i = 1, 2, 3, \dots, n) \quad (49)$$

$$\xi_i \geq 0 \quad (50)$$

Bu bilgileri göz önüne alarak Lagrange fonksiyonu aşağıdaki şekilde elde edilir [66].

$$L_p = \frac{1}{2} \|w\|^2 + C \sum_{i=1}^l \xi_i - \sum_{i=1}^l \alpha_i \{y_i (w^T \cdot x_i + b) - 1 + \xi_i\} - \sum_{i=1}^l \mu_i \xi_i \quad (51)$$

Burada μ_i ve α_i Lagrange çarpanlarıdır. Doğrusal ayrılabilir bölümündeki gibi elde edilen denklemin çözümü zor olduğundan dolayı bu problem bir dual problemine dönüştürülür.

$$\frac{\partial L_p}{\partial w} = w - \sum_{i=1}^l \alpha_i y_i x_i \implies w = \sum_{i=1}^l \alpha_i y_i x_i \quad (52)$$

$$\frac{\partial L_p}{\partial b} = 0 \implies \sum_{i=1}^l \alpha_i y_i = 0 \quad (53)$$

$$\frac{\partial L_p}{\partial \xi} = C - \alpha_i - \mu_i = 0 \implies C = \alpha_i + \mu_i \quad (54)$$

Elde edilen koşulları Lagrange denkleminde yerleştirerek aşağıdaki denklem elde edilir.

$$L_p = \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i=1}^l \alpha_i \alpha_j y_i y_j x_i x_j^T \quad (55)$$

Kısıtlar:

$$\sum_{i=1}^l \alpha_i y_i = 0 \quad (i = 1, 2, 3, \dots, n) \quad (56)$$

$$C \geq \alpha_i \geq 0 \quad (i = 1, 2, 3, \dots, n) \quad (57)$$

Doğrusal olarak ayırt edilemeyen veri kümeleri söz konusu olduğunda bu veri kümelerini birbirinden ayırt etmek için daha büyük uzaylara taşınması gerekir. Bu işlem DVM'ler ile sınıflandırma yapıldığında çekirdek fonksiyonlar kullanımıyla yapılır [65]. DVM'lerinde yapılan bu taşınmalarda x_j ve x_i vektörleri kullanarak $\varphi(x_i)$ ve $\varphi(x_j)$ fonksiyonları gözönüne alınacaktır. Optimizasyon problemindeki fonksiyon aşağıda gösterildiği gibidir:

$$L_p = \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i=1}^l \alpha_i \alpha_j y_i y_j x_i x_j^T \quad (58)$$

Bu Lagrange fonksiyonunda x_i nin dönüşümü için $\varphi(x_i)$ ve x_j^T nin dönüşümü için $\varphi(x_j)^T$ fonksiyonları kullanılır. Bu durumda denklem 55'deki fonksiyon aşağıdaki şekilde ifade edilir.

$$L_p = \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i=1}^l \alpha_i \alpha_j y_i y_j \varphi(x_j)^T \varphi(x_i) \quad (59)$$

Denklem 59'daki çekirdek fonksiyonu $\varphi(x_j)^T \varphi(x_i)$ çarpımı için şu şekilde tanımlanabilir.

$$k(x_i, x_j) = \varphi(x_j)^T \varphi(x_i) \quad (60)$$

Yukarıdaki denklemdeki çekirdek fonksiyonu tanımlayıcısını kullanarak yeni dual optimizasyon problemi aşağıda gösterildiği gibi elde edilir.

$$L_p = \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i=1}^l \alpha_i \alpha_j y_i y_j k(x_i, x_j) \quad (61)$$

Kısıtlar:

$$\sum_{i=1}^l \alpha_i y_i = 0 \quad (i = 1, 2, 3, \dots, n) \quad (62)$$

$$C \geq \alpha_i \geq 0 \quad (i = 1, 2, 3, \dots, n) \quad (63)$$

Sınıflandırıcılarda yaygın olarak kullanılan çekirdek fonksiyonları şunlardır [69].

- Doğrusal çekirdek fonksiyonu:

$$k(x_i, x_j) = x_j^T x_i \quad (64)$$

- Polinom çekirdek fonksiyonu:

$$k(x_i, x_j) = (\gamma x_j^T x_i + r)^d, \gamma > 0 \quad (65)$$

- Sigmoid çekirdek fonksiyonu:

$$k(x_i, x_j) = \tanh(\gamma x_j^T x_i + r) \quad (66)$$

- Radyal tabanlı çekirdek fonksiyonu (RBF):

$$k(x_i, x_j) = \exp\left(-\gamma \|x_i - x_j\|^2\right), \gamma > 0 \quad (67)$$

Bu fonksiyonlardaki γ , r ve d parametreleri çekirdek parametreleri olarak tanımlanır. Bu çalışmada ise yukarıda sıralanan çekirdek fonksiyonlarından biri olan Radyal tabanlı çekirdek fonksiyonu (RBF) kullanılmıştır. Literatüre göre bu çekirdek fonksiyonu en yaygın fonksiyonlar içinde yer almaktadır. Radyal tabanlı çekirdek fonksiyonundaki γ parametresi Gauss fonksiyonunun genişliğini göstermektedir [70]. Başka bir ifade ile γ parametresi radyal tabanlı fonksiyonun kernel boyutunu ifade eden parametredir. Çekirdek fonksiyonu tipine göre sınıflandırma performansları karşılaştırılan çalışmalarda radyal tabanlı çekirdek fonksiyonu en iyi performanslı çekirdek fonksiyonlardan olarak tanımlanmıştır [67, 71]. İkili sınıflandırıcılardan oluşan çok sınıflı sınıflandırıcılar M -sınıflı veri kümelerinin sınıflandırmasını ikili sınıflandırıcılar kullanımıyla yapmaktadır [72]. Bire-karşı-bir (BKB) ve BKD yöntemleri çok sınıflı sınıflandırıcılarda sıkça kullanılan en önemli DVM ayrıştırma yöntemlerindedirler. Bu tez çalışmasında BKB metodu kullanılmıştır. Bu yöntem Kneer ve arkadaşları tarafından ortaya atılmıştır [73]. BKB metodu N adet sınıflandırılması istenen sınıf için $\binom{N}{2}$ kombinasyonlarının ikili sınıflandırıcılarıyla gerçekleştirilir [67]. Yani bu yöntem tüm sınıf çiftlerinin ikili sınıflandırıcılarını oluşturmasıyla alakalıdır. Oluşturulan sınıflandırıcıların her biri sadece aynı sınıftan olan veri kümeleri ile eğitilir ve bu nedenle toplam eğitim zamanını azaltmaktadır [71]. Dikkate alınırsa eğer fazla sayıda sınıfların sınıflandırılması istenilirse BKB yöntemi daha uygun gözükmektedir.

2. YAPILAN ÇALIŞMALAR, BULGULAR VE İRDELEME

Birinci yöntem olarak bu tez çalışmasında sayısal modülasyon sınıflandırma için YSA tabanlı bir metot geliştirilmiştir. Bu metodun özellik çıkarma aşamasında, sinyalin SDD'sinin uygun ölçeklerinin standart sapmaları ve YMK'lerinin en yararlı mertebeleri kullanılır. Bu çalışmanın amacı, elde edilen özellikler ve üç seviyeli bir YSA sınıflandırıcısı kullanarak modülasyon türü bilinmeyen bir sinyal geldiği anda sinyalin modülasyon türünü oldukça yüksek *SGO* miktarlarında tanımlayabilmektir. Aynı zamanda bu çalışmada giriş örnek sayısı miktarı etkisini modülasyon tanıma işleminde incelenmiştir ve yüksek giriş örnek sayısından kaynaklanan uzun zamanlı sınıflandırma işleminin sürdüğü zamanı düşürmek için makul bir algoritma önerilmiştir.

2.1. Sayısal Modüleli Sinyallerin Oluşturulması

Bu çalışmada kullanılan QAM ve PSK modüleli işaretler -14 ve $+10$ *dB SGO* aralığında elde edilmiştir. Gürültünün doğası tesadüfi olduğundan dolayı bu işlem 10 kez tekrarlanmıştır. Yani her modülasyon türünden 250 adet oluşturulmuştur. Bu işaretler sınıflandırıcının eğitimi ve testi için kullanılmıştır.

- Kullanılan PSK modüleli işaretlerin oluşturulması

Bu çalışmada kullanılan PSK modüleli işaretlerler BPSK, QPSK ve 8-PSK tiplerinden oluşturulmuştur. -14 ve $+10$ *dB SGO* aralığında Beyaz Gauss gürültü ilave edilerek oluşturulan BPSK, QPSK ve 8-PSK modüleli işaretler, $f_c = 150$ *KHZ*, örnekleme frekansı $f_s = 1200$ *KHZ* ve $f_{symb} = 12500$ sembol/saniye olduğunda oluşturulmuştur. Giriş sembol sayısı ise 20000 örnek olarak kabul edilmiştir. Semboller arası girişimde sağladığı iyileşmelerden dolayı bu tez çalışmasında kullanılan modüleli işaretler üzerinde yükseltilmiş kosinüs darbe şekillendirme işlemi yapılmıştır. Literatüre göre pratikte sayısal haberleşme sistemlerinde genel olarak 0.10 ile 0.35 arasında değişen azalma faktörü kullanılmaktadır. Bu çalışmada ise azalma faktörü 0.35 olarak kabul edildi.

- Kullanılan QAM modüleli işaretlerin oluşturulması


Bu çalışmada kullanılan QAM modüleli işaretler 16-QAM, 32-QAM ve 64-QAM tiplerinden oluşturulmuştur. -14 ve +10 dB SGO aralığında Beyaz Gauss gürültü ilave edilerek oluşturulan 16-QAM, 32-QAM ve 64-QAM modüleli işaretler, taşıyıcı frekansı $f_c = 150 \text{ KHZ}$, örnekleme frekansı $f_s = 1200 \text{ KHZ}$ ve $f_{symp} = 12500$ sembol/saniye olduğunda oluşturulmuştur. Giriş sembol sayısı ise 20000 örnek olarak kabul edilmiştir. Semboller arası girişimde sağladığı iyileşmelerden dolayı bu tez çalışmasında kullanılan modüleli işaretler üzerinde yükseltilmiş kosinüs darbe şekillendirme işlemi yapılmıştır. Literatüre göre pratikte sayısal haberleşme sistemlerinde genel olarak 0.10 ile 0.35 arasında değişen azalma faktörü kullanılmaktadır. Bu çalışmada ise azalma faktörü 0.35 olarak kabul edildi.

2.2. Kullanılan Özellik Çıkarma Yöntemleri

Önerilen algoritmanın amacı SDD'den elde edilen özellik vektörlerinin standart sapması ve yüksek YMK'lerin dördüncü mertebelerinden elde edilen özellikleri kullanarak üç seviyeli hiyerarşik YSA sınıflandırıcı vasıtasıyla BPSK, QPSK, 8-PSK, 16-QAM, 32-QAM ve 64-QAM modüleli işaretleri otomatik olarak sınıflandırmaktır. Bu çalışma toplanır gauss dağılımlı kanallarda yapılmıştır.

2.2.1. Sürekli Dalgacık Dönüşümünden Elde Edilen Özellikler

Bu çalışmada BPSK, QPSK, 8-PSK, 16-QAM, 32-QAM ve 64-QAM sayısal modüleli işaretler için birinci özellik olarak SDD yöntemi kullanılmıştır. Haar dalgacığı $\Psi(t)$ ana dalgacık olarak seçilmiştir. SDD ile özellik çıkarmak için Şekil 20'deki diyagram önerilmiştir.



Şekil 20. SDD yöntemi ile özellik çıkarma diyagramı

Bu çalışmada $-15 \text{ dB} < SGO < 11 \text{ dB}$ olduğu durumda, kullanılan modülasyon türleri için 5 farklı (1~5) ölçekte (scale) SDD'nin katsayıları elde edilmiştir. Daha sonra outlier verilerin ortadan kaldırılması için medyan filtre kullanılmıştır, ardından verilerin standart sapması özellik olarak kullanılmıştır. Bu çalışmada kullanılan modülasyon türleri için 5 farklı ölçekte (scale) SDD'den elde edilen katsayı değerlerinin standart sapması Tablo 3 ve 4'te gösterilmektedir.

Tablo 3. M-QAM modüleli işaretler için SDD'nin 5 farklı ölçeklerinden elde edilen nitelik değerleri

Mod Türü	SGO	Ölçek1	Ölçek2	Ölçek3	Ölçek4	Ölçek5
16-QAM	-10	$5.0479e^{-16}$	3.4239	3.1891	4.3402	4.4701
	-5	$3.2033e^{-16}$	2.1761	2.3885	3.5063	3.8506
	0	$2.3664e^{-16}$	1.6078	2.0607	3.1818	3.6329
	5	$2.0419e^{-16}$	1.3874	1.9505	3.0746	3.5547
	10	$1.9306e^{-16}$	1.3117	1.9208	3.0500	3.5424
32-QAM	-10	$5.3123e^{-16}$	3.6037	3.6764	5.2412	5.6358
	-5	$3.6637e^{-16}$	2.4884	2.9769	4.4981	5.0562
	0	$2.9299e^{-16}$	1.9900	2.7127	4.2422	4.8785
	5	$2.6995e^{-16}$	1.8315	2.6378	4.1721	4.8335
	10	$2.6045e^{-16}$	1.8696	2.6102	4.1484	4.8187
64-QAM	-10	$5.9082e^{-16}$	4.0139	4.4890	6.6482	7.3808
	-5	$4.4487e^{-16}$	3.0224	3.9479	6.1131	6.9877
	0	$3.8905e^{-16}$	2.6431	3.7445	5.9083	6.8344
	5	$3.6938e^{-16}$	2.5095	3.6837	5.5811	6.7959
	10	$3.6395e^{-16}$	2.4725	3.6716	5.8443	6.7965

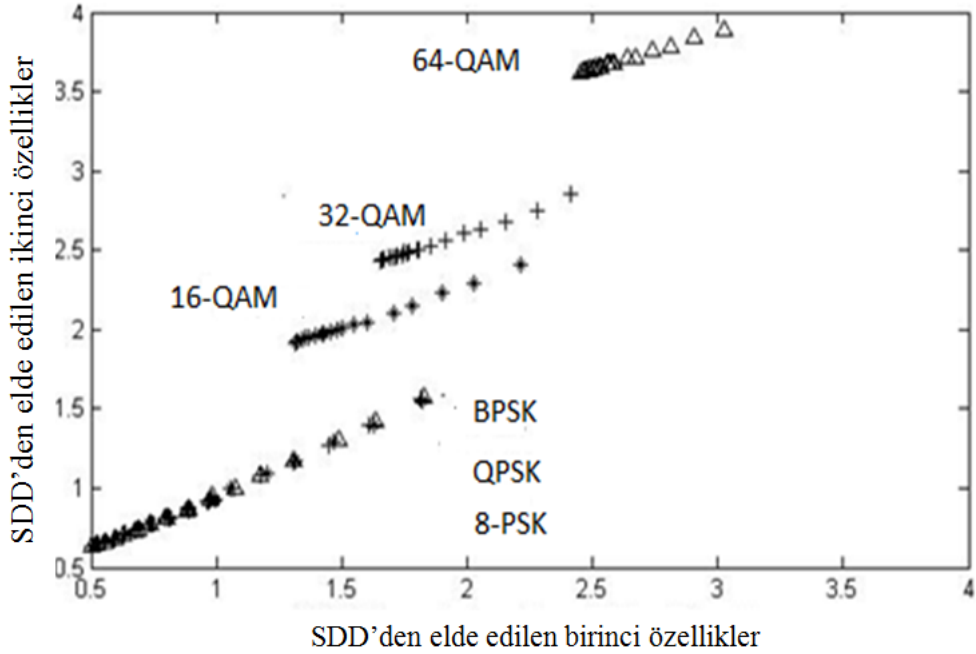
Tablo 4. M-PSK modüleli işaretler için SDD'nin 5 farklı ölçeklerinden elde edilen nitelik değerleri

Mod Türü	SGO	Ölçek1	Ölçek2	Ölçek3	Ölçek4	Ölçek5
QPSK	-10	$4.7088 e^{-16}$	3.1985	1.5502	3.2832	3.0169
	-5	$2.69733e^{-16}$	1.8325	0.9951	1.9794	1.8908
	0	$1.57329e^{-16}$	1.0688	0.7431	1.3489	1.3832
	5	$1.08105e^{-16}$	0.6931	0.6317	1.0843	1.1880
	10	$7.70248e^{-16}$	0.4996	1.0771	0.9724	1.1084
BPSK	-10	$4.7487 e^{-16}$	3.2259	2.6537	3.2889	3.0256
	-5	$2.7091e^{-16}$	1.8404	1.5916	2.5440	1.9631
	0	$1.5686e^{-16}$	1.0657	0.9948	1.3565	1.3965
	5	$1.0042e^{-16}$	0.6823	0.6391	1.0808	1.1846
	10	$7.3990e^{-16}$	0.5027	0.6332	0.9730	1.1062

Tablo 4'ün devamı

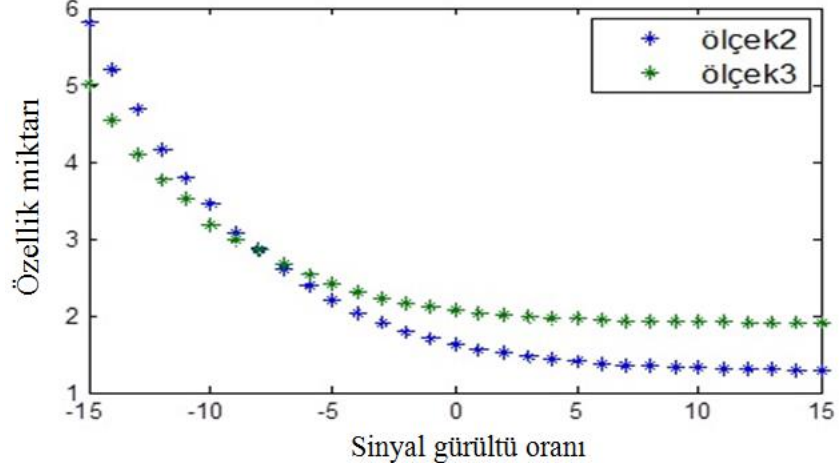
8-PSK	-10	$4.5785 e^{-16}$	3.1105	2.5941	3.2393	2.9909
	-5	$2.6391 e^{-16}$	1.7926	1.5503	1.9888	1.9042
	0	$1.5502 e^{-16}$	1.0532	0.9853	1.3451	1.3879
	5	$9.9945 e^{-16}$	0.6790	0.7346	1.0726	1.1741
	10	$7.37.8 e^{-16}$	0.5007	0.6384	0.9765	1.1113

Tablo 3 ve 4'te gözüktüğü gibi QAM modüleri işaretler için SDD'nin 2 ve 3'üncü ölçeklerinden elde edilen katsayı değerleri farklı SGO'larda daha dayanıklı ve sabittirler. Ama elde edilen özellik katsayıları PSK modüleri işaretleri ayırt etmede elverişli olmadıkları tabloda görülmektedir. Tablo 3 ve 4'teki elde edilen özellik değerleri incelendiğinde bu özellikler seti QAM modülasyon kümesi ile PSK modülasyon kümesini ayırt etmede oldukça başarılı gözükmektedir. Aynı zamanda QAM modülasyon kümesindeki 16-QAM, 32-QAM ve 64-QAM türlü modüleri işaretlerin arasında ayırım yapmada da başarılı olma ihtimali fazlalıkla beklenir. Ama bu özellik setleri ile BPSK, QPSK ve 8-PSK türlü işaretleri birbirinden ayırım yapmada başarısız olması beklenir (Şekil 21).




Şekil 21. SDD'den elde edilen özelliklerinin gösterimi

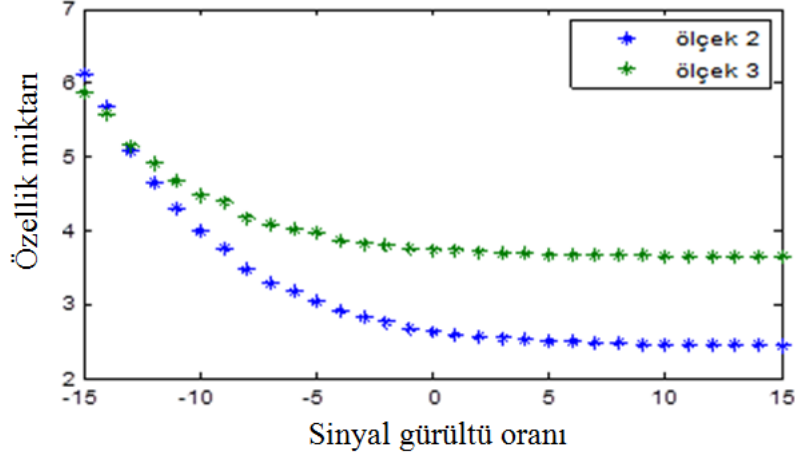
Şekil 21’de 2. ve 3. Ölçekler kullanarak SDD’nin standart sapma değerlerinin başka bir gösterimi gösterilmektedir. Toplanır Beyaz Gauss gürültülü ortamda 16-QAM, 32-QAM ve 64-QAM türlü işaretler için seçilen özellikler diyagramı Şekil 22, 23, 24’te gösterilmektedir.



Şekil 22. 16-QAM modülasyonu için 2. ve 3. Ölçekten elde edilen niteliklerin gürültüye göre diyagramı



Şekil 23. 32-QAM modülasyonu için 2. ve 3. Ölçekten elde edilen niteliklerin gürültüye göre diyagramı



Şekil 24. 64-QAM modülasyonu için 2. ve 3. Ölçekten elde edilen niteliklerin gürültüye göre diyagramı

Şekil 22, 23, 24'te *SGO* etkisi kullanılan QAM türlü modüleri işaretlerin üzerinde kıyaslanmıştır. Şekillerde gözüktüğü gibi 16-QAM, 32-QAM ve 64-QAM modüleri işaretler gürültü karşısında benzer bir davranış göstermektedirler. İşaretlerin gürültü karşısında benzer bir davranışları, sınıflandırma işlemi yapıldığında daha fazla kolaylık sağlar ve elde edilen özelliklerin avantajı olarak sayılır. Bu şekillerde gözüktüğü gibi *SGO* miktarı düşürüldüğünde elde edilen özellik değerlerinin hepsi düşmektedir. Özelliklerin gürültü karşısında ters davranışı, özellik değerlerinin yatay ve dikey yönde dağılması anlamına gelir ve bu özellikleri kullanarak yapılan sınıflandırma işleminin performansının düşmesi beklenir. Şekil 22, 23, 24'te gözüktüğü gibi SDD'nin standart sapmasından elde edilen özelliklerle, kullanılan iki farklı türdeki modülasyonları (M-PSK ve M-QAM) ayırabiliriz. Aynı zamanda bu özellik setini kullanarak 16-QAM, 32-QAM ve 64-QAM modülasyonlarının arasında da ayırım yapabiliriz. Ama elde edilen özellikleri kullanarak M-PSK türlü işaretlerin sınıflandırmasında çok düşük performans elde edildiğini düşündüğünden dolayı, gürültü karşısında dayanıklı olan YMK'ler, ikinci özellik seti olarak önerilmiştir.

2.2.2. Yüksek Mertebeli Kümülanlardan Elde Edilen Özellikler

Şekil 21'de gösterildiği gibi bu tez çalışmasında kullanılan QAM kümesindeki modüleri işaretler ve PSK kümesindeki modüleri işaretler SDD'nin standart sapmasından elde edilen nitelikler ile ayırt edilebilir. Aynı zamanda bu özellik setini kullanarak 16-

QAM, 32-QAM ve 64-QAM modülasyonlarının arasında da ayırım yapabiliriz. Fakat bu özellik setini kullanarak, kullanılan PSK kümesindeki modüleli işaretleri yüksek performans ile ayırt etme imkânı yoktur. Bu yüzden bu çalışmada kullanılan PSK gurubundaki modülasyonlar arasında ayırım yapmak için gürültü karşısında dayanıklı olan başka bir özellik çıkarma yöntemi önerilmiştir. Alınan sinyalin karmaşık zarfının dördüncü mertebeli kümülanlarından elde edilen özellik seti, bu amaç için önerilen niteliklerdir [15]. İlk olarak hedeflenen amaç için sinyalin YMK'lerinin 2, 4, ve 6. mertebeden değerleri elde edilmiştir. Tablo 5'te elde edilen özellik değerleri gösterilmektedir.

Tablo 5. BPSK, QPSK ve 8-PSK türlü modüleli işaretler için farklı YMK'lerden elde edilen özellik değerleri

MOD	BPSK						QPSK						8-PSK					
SGO	-6	-3	0	3	6	9	-6	-3	0	3	6	9	-6	-3	0	3	6	9
CUM20	1	1	1	1	1	1	0	0	0	0	0	0	0	0	0	0	0	0
CUM40	-2	-2	-2	-2	-2	-2	1	1	1	1	1	1	0	0	0	0	0	0
CUM31	-2	-2	-2	-2	-2	-2	0	0	0	0	0	0	0	0	0	0	0	0
CUM22	-2	-2	-2	-2	-2	-2	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1
CUM60	17	17	16	16	16	16	-9	-2	0	0	0	0	-5	-1	0	0	0	0
CUM51	16	16	16	16	16	16	-6	-4	-4	-4	-4	-4	-4	-4	-1	-1	-1	-1
CUM42	15	16	16	16	16	16	0	0	0	0	0	0	0	0	0	0	0	0
CUM33	14	16	16	16	16	16	0	3	4	4	4	4	3	4	4	4	4	4

Tablo 5'te gözüktüğü gibi sinyalin YMK'lerinden elde edilen özellik değerlerinde, 4. ve 6. mertebeden elde edilen değerler farklı gürültüler karşısında daha dayanıklı gözükmektedir. Bu yüzden 4. mertebeden elde edilen değerler, gürültü karşısında daha dayanıklı olmalarından dolayı özellik seti olarak seçildi. Daha detaylı olarak seçilen özellik değerleri BPSK, QPSK ve 8-PSK modülasyonlar için Tablo 6'da gösterilmektedir.

Tablo 6. BPSK, QPSK ve 8-PSK modüleli işaretler için seçilen özellik değerleri

SGO	CUM40	CUM31	CUM22	Mod
-7	-1	-1	-2	BPSK
-6	-2	-2	-2	
-5	-2	-2	-2	
-4	-2	-2	-2	
-3	-2	-2	-2	

Tablo 6'nın devamı

-2	-2	-2	-2	BPSK
-1	-2	-2	-2	
0	-2	-2	-2	
1	-2	-2	-2	
2	-2	-2	-2	
-7	-1	0	-3	QPSK
-6	2	0	-1	
-5	1	0	-1	
-4	1	0	-1	
-3	1	0	-1	
-2	1	0	-1	
-1	1	0	-1	
0	1	0	-1	
1	1	0	-1	
2	1	0	1	
-7	1	-3	1	8-PSK
-6	1	0	-1	
-5	0	0	-1	
-4	0	0	-1	
-3	0	0	-1	
-2	0	0	-1	
-1	0	0	-1	
0	0	0	-1	
1	0	0	-1	
2	0	0	1	

Tablo 6'da gösterilen özellik çıkarma işleminin sonucunda, düşük *SGO*'larda daha fazla değişiklik göstermeyen özellikler miktarı, sınıflandırma işleminin öğrenme aşamasında kullanmaya karar verildi. Bu özellik değerleri BPSK, QPSK ve 8-PSK modüleli işaretler için $-4 \leq SGO \leq +15 \text{ dB}$ aralığında elde edilmiştir.

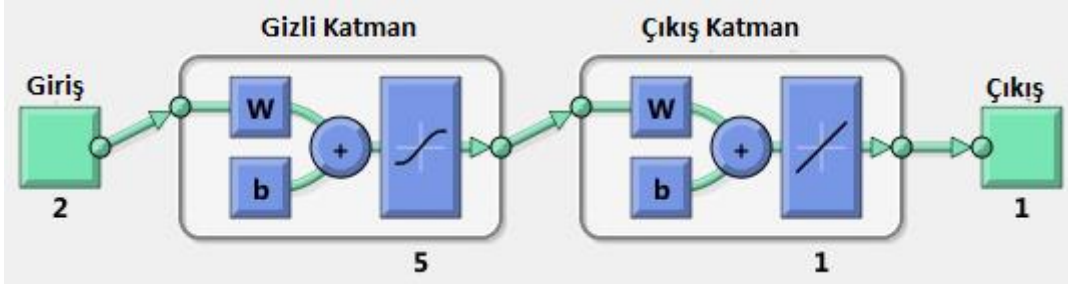
2.3. Önerilen Yapay Sinir Ağı Temelli Birinci Algoritma

2.3.1. Ağ Parametrelerinin Belirlenmesi ve Sınıflandırma Aşamaları

Son yıllarda sınıflandırma problemlerinde sıklıkla kullanılmaya başlayan YSA'lar birçok alanda başarıyla kullanılan sınıflandırma yöntemi olarak tanımlanabilir. Günümüzdeki sınıflandırma problemleri oldukça karışık hale dönüşmesi nedeniyle zeki

sınıflandırıcılara duyulan ihtiyaç artmaktadır. Eş zamanlı olarak çalışan birçok nöronun oluşan YSA'larda karmaşık işlevler bu nöronların eş zamanlı çalışmalarıyla meydana getirilir. Yani çalışma esnasında herhangi bir nöronun bozulması sistemin çalışmamasına ve sonucun güvensiz olmasına neden olmaz. Literatüre göre YSA sınıflandırıcıları tasarlanırken en fazla iki gizli katmanlı bir modelle başlanması önerilmiştir. Eğer bu oluşturulan iki gizli katmanlı YSA sınıflandırıcısından farklı gizli nöron sayılarıyla beklenen ya da istenilen sonuçlar elde edilmezse daha fazla katman ekleyerek yeni bir YSA sistemi oluşturmak tavsiye edilmiştir. YSA sınıflandırıcılarda en uygun gizli birim sayılarını veren bir denklem olmamasından dolayı [74], deneme yanılma yoluyla gizli katmanlardaki birimlerin sayısı belirlenmiştir. Bu deneme yanılma sürecinde üzerinde test yapılan katman dışında başka katmanların parametreleri sabit tutuldu ve gizli katman birimlerinin en uygun sayısını bulurken farklı birim sayılarında sistem eğitildi ve validasyon sonucu en iyi olan sistem seçilip kullanıldı. Bu yöntem YSA sistemlerinin gizli katman birimler sayısını bulmada en çok kullanılan yöntemdir. Bundan önceki çalışmalar baz alınarak oluşturulan bu sınıflandırıcıda çekirdek fonksiyonu ve öğrenme yöntemi sırasıyla Radyal Tabanlı Çekirdek Fonksiyonu (RTÇF) ve geri yayılım öğrenme algoritması kullanıldı.

Bu tez çalışmasında birinci sınıflandırma yöntemi olarak, sınıflandırma işlemini yapmak için üç aşamada çok katmanlı ileri beslemeli YSA sınıflandırıcısı kullanıldı. Önerilen sınıflandırıcının yapısı üç alt sınıflandırıcıdan oluşmaktadır. Yani bu tez çalışmadaki sınıflandırma problemi bu üç sınıflandırıcıdaki sonuçların birleşmesinden elde edilir. Kullanılan YSA sınıflandırıcılar için optimum gizli katman ve gizli katmanın sinir sayısını bulmak amacıyla değişik katman ve gizli katman sayıları denenmiştir. Sonuç olarak birinci sınıflandırıcı için optimum gizli katman sayısı 1 ve bu gizli katmanın sinir sayısı 5 (Şekil 25), ikinci sınıflandırıcı için optimum gizli katman sayısı 2 ve bu gizli katmanların sinir sayısı 10 ve 5 (Şekil 26), ve üçüncü sınıflandırıcı için optimum gizli katman sayısı 1 ve bu gizli katmanın sinir sayısı 10 (Şekil 27) olarak kabul edildi.



Şekil 25. Tek gizli katmanlı birinci sınıflandırıcının genel yapısı

Birinci YSA sınıflandırıcı için Levenberg-Marquardt geriye-yayılım öğrenme algoritmasından elde edilen ağırlık vektörleri aşağıdaki gibidir. Bu vektörlerde her eleman ($W_{n,m}$), m . girişin etkisini n . nöronun üzerinde göstermektedir. Bu vektörler Tablo 7 ve 8’de gösterilmektedir.

Tablo 7. Birinci sınıflandırıcının gizli katmanının ağırlık vektörü

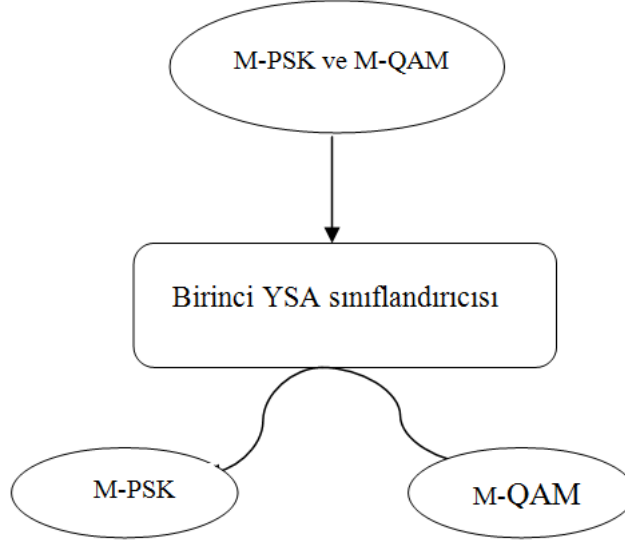
Birinci Sınıflandırıcının Gizli Katmanının Ağırlık Değerleri		Giriş (1-2)		Bias Değeri
		$m = 1$	$m = 2$	
Nöron	$n = 1$	30.44	-49.70	-13.35
	$n = 2$	$1.15 e - 18$	-4.43	17.90
	$n = 3$	-8.81	11.10	1.65
	$n = 4$	0.74	-0.87	3.92
	$n = 5$	-2.34	0.94	4.91

Tablo 8. Birinci sınıflandırıcının çıkış katmanının ağırlık vektörü

Birinci Sınıflandırıcının Çıkış Katmanının Ağırlık Değerleri		Giriş (1-5)					Bias Değeri
		$m = 1$	$m = 2$	$m = 3$	$m = 4$	$m = 5$	
Nöron	$n = 1$	-0.99	0.55	$6.04 e - 18$	0.0002	-2.00	1.45


Giriş işaretin hangi modülasyon grubuna (M-PSK ve M-QAM) ait olduğunu tahmin etmek amacıyla geliştirilen birinci YSA modelinin gizli katman ve çıktı katmanında aktivasyon fonksiyonu olarak sırasıyla tanjant sigmoid ve lineer fonksiyonu kullanılmıştır. Ayrıca bu modelin eğitim süreci 1000 iterasyon kullanılarak gerçekleştirilmiştir. Bu modülasyon kümelerinin ayrıştırılmasında, öznitelik olarak SDD’nin ikinci ve üçüncü ölçeklerinden elde edilen katsayıların standart sapması kullanılmıştır. SDD’nin ikinci ve üçüncü ölçeklerinden elde edilen katsayıların standart sapması Tablo 3 ve 4’te

gösterilmiştir. Bu özellik setleri $-15 \text{ dB} < SGO < 11 \text{ dB}$ olduğu durumda elde edilmiştir. Şekil 26’da gösterildiği gibi bu sınıflandırıcının sonucunda sadece, kullanılan modülasyonların hangi kümeye ait oldukları belirlenmektedir.



Şekil 26. Kullanılan modüleri işaretlerin hangi gruba ait olduğunu belirleyen birinci YSA sınıflandırıcısı

Eğer Şekil 25’te gösterildiği birinci sınıflandırıcının sonucu PSK kümesindeki modüleri işaretler türünden olursa, ikinci sınıflandırıcısı PSK tipli modüleri işaretleri birbirinden ayırmak için kullanılır. Bu sınıflandırıcının yapısı Şekil 27’de gösterildiği gibidir.



Şekil 27. İki gizli katmanlı ikinci sınıflandırıcının genel yapısı

İkinci YSA sınıflandırıcısı için Levenberg-Marquardt geriye-yayılım öğrenme algoritmasından elde edilen ağırlık vektörü aşağıdaki gibidir. Bu vektörlerde her eleman

$(W_{n,m})$, m . girişin etkisini n . nöronun üzerinde göstermektedir. Bu vektörler Tablo 9,10 ve 11'de gösterilmektedir.

Tablo 9. İkinci sınıflandırıcının birinci gizli katmanının ağırlık vektörü

İkinci Sınıflandırıcının Birinci Gizli Katmanının Ağırlık Değerleri		Giriş (1-3)			Bias Değeri
		$m = 1$	$m = 2$	$m = 3$	
Nöron	$n = 1$	1.93	-1.02	2.16	-2.94
	$n = 2$	$-2.16 e - 11$	-0.14	-0.69	3.05
	$n = 3$	-1.28	0.29	2.69	1.58
	$n = 4$	2.43	-1.57	-0.49	-1.31
	$n = 5$	$-1.98 e - 12$	-0.68	3.34	0.07
	$n = 6$	1.74	2.28	-1.52	-0.23
	$n = 7$	-1.56	2.53	1.32	-0.43
	$n = 8$	-0.11	1.03	-2.83	-1.71
	$n = 9$	$-0.82 e - 12$	$2.48 e - 13$	1.33	-2.70
	$n = 10$	1.35	1.63	2.13	2.96

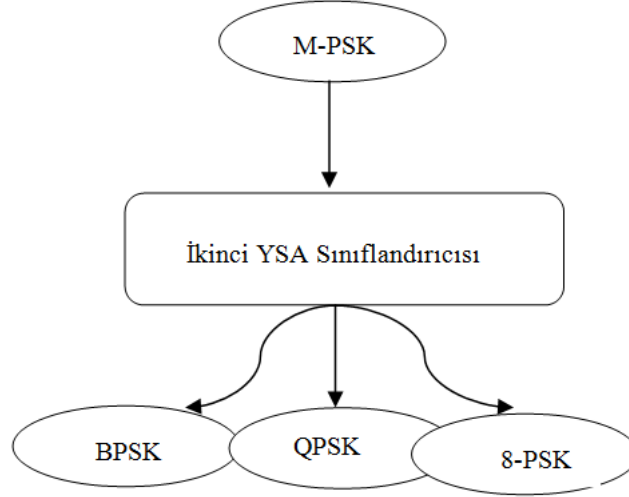
Tablo 10. İkinci sınıflandırıcının ikinci gizli katmanının ağırlık vektörü

İkinci Sınıflandırıcının İkinci Gizli Katmanının Ağırlık Değerleri	Giriş (1-10)										Bias Değeri
	$m = 1$	$m = 2$	$m = 3$	$m = 4$	$m = 5$	$m = 6$	$m = 7$	$m = 8$	$m = 9$	$m = 10$	
$n = 1$	-0.38	0.38	-0.31	-0.81	0.41	-0.14	-0.36	-0.05	-0.97	-0.51	1.90
$n = 2$	0.06	0.03	0.64	-0.35	-1.91	-0.65	-0.87	-0.27	0.25	-0.83	-0.79
$n = 3$	0.26	0.02	0.56	-0.30	-0.59	0.96	-0.70	-0.72	-0.84	-0.34	0.17
$n = 4$	0.13	0.45	0.38	-0.09	-2.36	-0.55	-0.29	-0.03	0.59	0.06	1.05
$n = 5$	0.64	-0.29	-0.09	-0.62	0.50	-0.33	-0.33	-0.53	-0.55	0.73	1.85

Tablo 11. İkinci sınıflandırıcının çıkış katmanının ağırlık vektörü


İkinci Sınıflandırıcının Çıkış Katmanının Ağırlık Değerleri		Giriş (1-5)					Bias Değeri
		m=1	m=2	m=3	m=4	m=5	
Nöron	$n = 1$	0.03	-0.84	-0.61	1.32	0.39	-0.71

Bu iki gizli katmanlı sınıflandırıcıda, öznitelik olarak sinyalin YMK'lerinin dördüncü mertebesinde elde edilen nitelik değerleri kullanılmıştır. Bu özellik setleri $-4 \text{ dB} < \text{SGO} < 15 \text{ dB}$ olduğu durumda elde edilmiştir. YMK'lerin dördüncü mertebesinde elde edilen nitelik değerleri Tablo 6'da gösterilmiştir. Şekil 28'de gösterildiği gibi bu sınıflandırıcının sonucunda PSK kümesindeki modüleli işaretin BPSK, QPSK yoksa 8-PSK türüne ait olduğu belirlenmektedir.



Şekil 28. PSK modüleli işaretlerin tipini belirlemek için kullanılan YSA sınıflandırıcı

Fakat birinci sınıflandırıcının (Şekil 25) sonucu QAM modüleli işaretler türünden olursa, üçüncü sınıflayıcıdan QAM türlü işaretlerin tipini ayırt etme işlemi için kullanılır. Bu sınıflandırıcının yapısı Şekil 29'da gösterildiği gibidir.



Şekil 29. Tek gizli katmanlı üçüncü sınıflandırıcının genel yapısı

Üçüncü YSA sınıflandırıcısı için Levenberg-Marquardt geriye-yayılım öğrenme algoritmasından elde edilen ağırlık vektörü aşağıdaki gibidir. Bu vektörlerde her eleman ($W_{n,m}$), m . girişin etkisini n . nöronun üzerinde göstermektedir. Bu vektörler Tablo 12 ve 13'te gösterilmektedir.

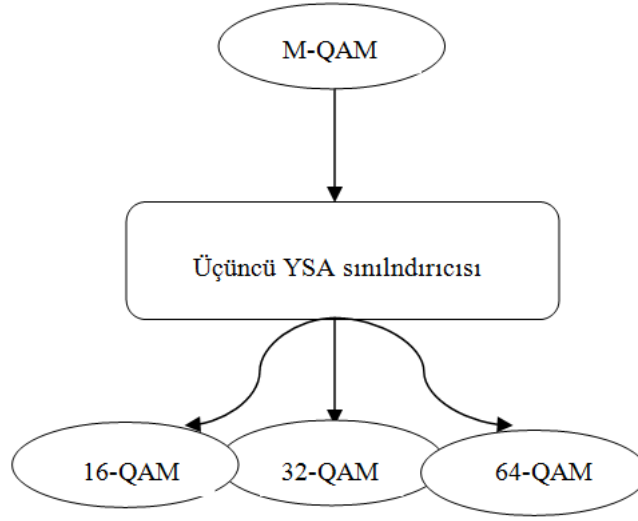
Tablo 12. Üçüncü sınıflandırıcının gizli katmanının ağırlık vektörü

Üçüncü Sınıflandırıcının Gizli Katmanının Ağırlık Değerleri		Giriş (1-2)		Bias Değeri
		m=1	m=2	
Nöron	$n = 1$	-3.28	2.48	5.06
	$n = 2$	-1.41	-3.86	3.49
	$n = 3$	-7.22	19.75	-5.42
	$n = 4$	-19.39	37.60	10.68
	$n = 5$	0.09	4.18	-2.45
	$n = 6$	3.97	2.85	1.31
	$n = 7$	-2.11	-5.27	-1.83
	$n = 8$	2.57	-2.53	3.02
	$n = 9$	-3.48	2.90	-3.67
	$n = 10$	7.56	2.18	6.79

Tablo 13. Üçüncü sınıflandırıcının çıkış katmanının ağırlık vektörü

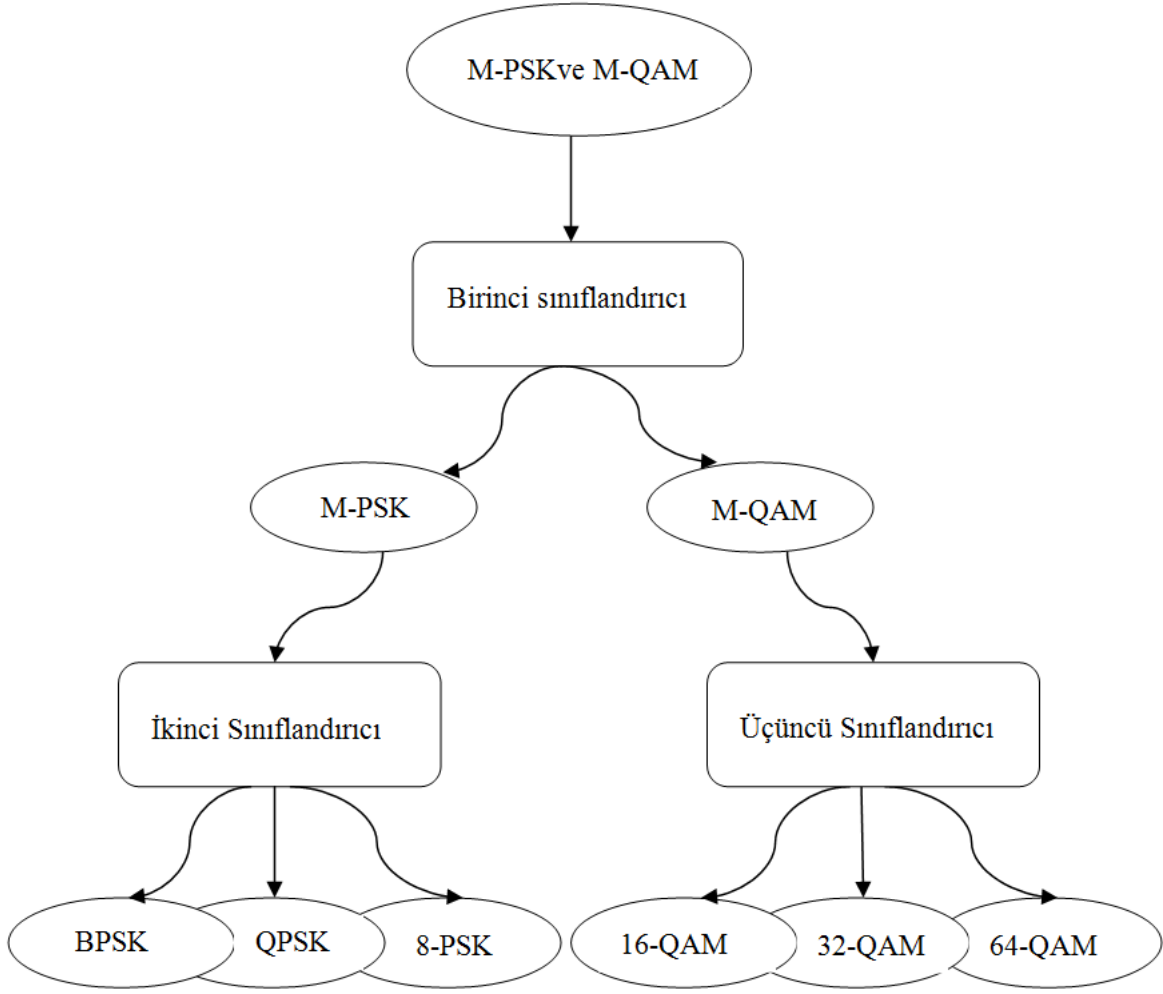
Üçüncü Sınıflandırıcının Çıkış Katmanının Ağırlık Değerleri		Giriş (1-10)										Bias Değeri
		$m = 1$	$m = 2$	$m = 3$	$m = 4$	$m = 5$	$m = 6$	$m = 7$	$m = 8$	$m = 9$	$m = 10$	
Nöron	$n = 1$	0.0	-2.3e-11	0.5	0.5	-5.7e-11	5.7e-13	1.5e-12	0.3	0.1	6e-20	$3.4 e - 12$

Bu tek gizli katmanlı sınıflandırıcının gizli katmanında 10 nöron kullanılmıştır. Bu sınıflandırıcıda QAM modüleri işaretlerin ayrıştırılmasında, öznitelik olarak SDD'nin ikinci ve üçüncü ölçeklerinden elde edilen katsayıların standart sapması kullanılmıştır. SDD'nin ikinci ve üçüncü ölçeklerin katsayılarının standart sapmasından elde edilen özellik seti Tablo 3 ve 4'te gösterilmiştir. Şekil 30'da gösterildiği gibi bu sınıflandırıcının sonucunda QAM modüleri işaretin 16-QAM, 32-QAM yoksa 64-QAM türüne ait olduğu belirlenmektedir.



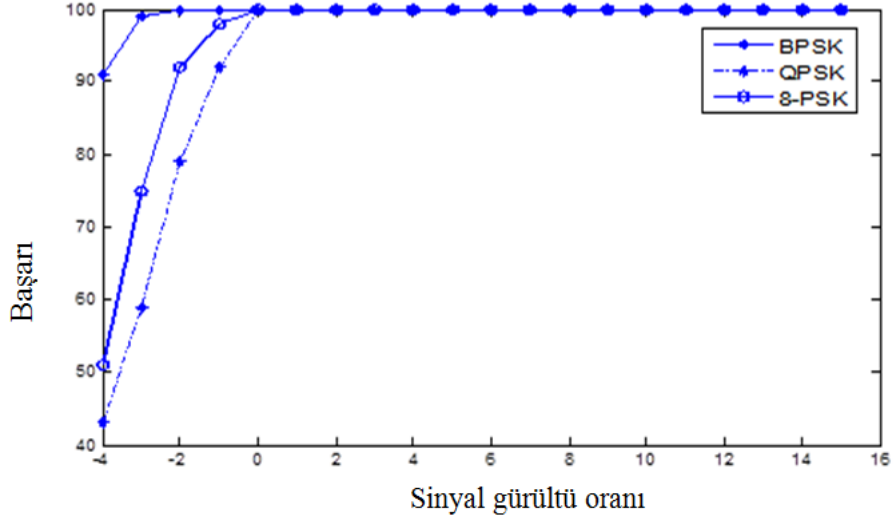
Şekil 30. PSK modüleri işaretlerin tipini belirlemek için kullanılan üçüncü sınıflandırıcı

Bu tez çalışmasındaki sınıflandırma problemi Şekil 26, 28 ve 30'da gösterilen bu üç sınıflandırıcının sonuçlarının birleşmesi ile elde edilir (Şekil 31).



Şekil 31. Önerilen birinci algoritmada YSA sınıflandırıcının yapısı

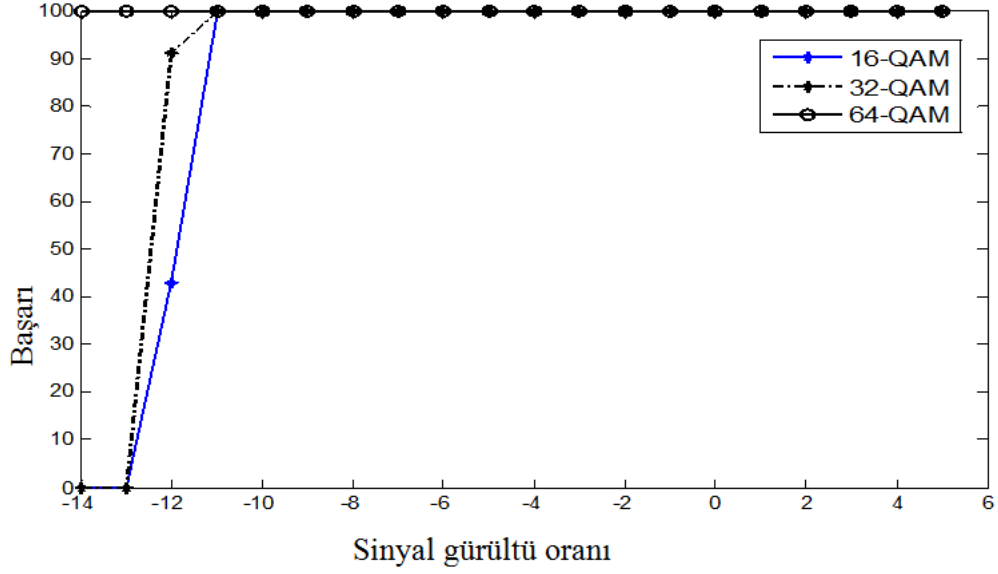
Şekil 32’de BPSK, QPSK ve 8-PSK modüleli işaretler için önerilen birinci sınıflandırma sisteminden elde edilen sınıflandırma sonuçları gösterilmiştir.



Şekil 32. PSK modüleli işaretlerin sınıflandırılmasından elde edilen sonuçlar

Şekil 31'deki üç seviyeli ileri beslemeli YSA sınıflandırıcısında YMK'lerin dördüncü mertebesinde elde edilen nitelikler ve SDD'nin ikinci ve üçüncü ölçeklerinden elde edilen katsayıların standart sapması kullanılarak, BPSK, QPSK ve 8-PSK modüleli işaretler için AWGN kanallardaki $SGO \geq -4 \text{ dB}$ olduğunda modülasyon sınıflandırma başarımları Şekil 32'de gösterilmiştir. Şekil 32'de belirtildiği üzere, BPSK türlü modüleli sinyaller $SGO = -3 \text{ dB}$ olduğu durumda %99 ve $SGO \geq -2 \text{ dB}$ olduğunda %100 başarıyla sınıflandırılmıştır. QPSK türlü modüleli sinyaller $SGO = -1 \text{ dB}$ olduğu durumda %91 ve $SGO \geq 0 \text{ dB}$ olduğunda %100 başarıyla sınıflandırılmıştır. 8-PSK türlü modüleli sinyaller $SGO = -1 \text{ dB}$ olduğu durumda %97 ve $SGO \geq 0 \text{ dB}$ olduğunda ise %100 başarıyla sınıflandırılmıştır.

Şekil 33'de 16-QAM, 32-QAM ve 64-QAM modüleli işaretler için önerilen birinci sınıflandırma siteminden elde edilen sonuçlar gösterilmiştir.



Şekil 33. QAM modüleri işaretlerin sınıflandırılmasından elde edilen sonuçlar

Şekil 31'deki üç seviyeli ileri beslemeli YSA sınıflandırıcısında YMK'lerin dördüncü mertebesinde elde edilen nitelikler ve SDD'nin ikinci ve üçüncü ölçeklerinden elde edilen katsayıların standart sapması kullanılarak 16-QAM, 32-QAM ve 64-QAM modüleri işaretler için $SGO \geq -14$ dB olduğunda modülasyon sınıflandırma başarımları Şekil 33'te gösterilmektedir. Şekil 33'te belirtildiği üzere, 16-QAM türlü modüleri sinyaller $SGO = -12$ dB olduğu durumda %44 ve $SGO \geq -11$ dB olduğunda %100 başarıyla sınıflandırılmıştır. 32-QAM türlü modüleri sinyaller $SGO = -12$ dB olduğu durumda %91 ve $SGO \geq -11$ dB olduğunda %100 başarıyla sınıflandırılmıştır. 64-QAM türlü modüleri sinyaller $SGO = -14$ dB olduğu durumda ise %100 başarıyla sınıflandırılmıştır.

2.4. Önerilen İkinci Algoritma

Bu çalışmanın ikinci sınıflandırma yöntemi olarak DVM sınıflandırıcısı kullanılmıştır. DVM'ler ile sınıflandırma yapma işleminde, kullanılacak kernel fonksiyon ve bu fonksiyona ait parametrelerin belirlenmesi esas bir işlemdir. Literatürde en çok kullanılan kernel fonksiyonlardan birisi olan, radyal tabanlı fonksiyon bu sınıflandırıcıda kullanılmıştır. Kernel fonksiyonu için bazı parametreler miktarının belirlenmesi gerekir. Kullanılan kernel fonksiyonun kernel boyutu, 1.25 olarak seçildi. Bu çalışmada kullanılan BKB metodunda sınıflandırma çözümü, N adet sınıf için $\binom{N}{2}$ kombinasyonlarının ikili

çözümü ile gerçekleştirilmektedir. SDD'nin ikinci ve üçüncü ölçeklerinden elde edilen katsayılarının standart sapması ve YMK'lerin dördüncü mertebesinde elde edilen özellikler arasında hiç bir seçim yapmadan, özellik vektörünü oluşturmak için kullanılmıştır. Böylece bu sınıflandırmada kullanılan özellik vektörü matrisi, birinci sınıflandırmada oluşturulan özellik vektörü matrisinin boyutuna göre daha büyüktür. Bu çalışmada kullanılan modülasyon türleri için elde edilen ve hiç bir seçim yapmadan kullanılan özellikler miktarları, giriş örnek sayısı 20000 olduğu durumda Tablo 14 ve 15'te gösterilmektedir.

Tablo 14. DVM sınıflandırıcısında QAM modüleli işaretler için kullanılan özellik değerleri

Mod	16-QAM				
SGO	CUM40	CUM31	CUM22	SDD-Ölçek 2	SDD-Ölçek3
-10	-52	-1	-64	3.3799	3.1626
-5	-53	0	-57	2.1488	2.3061
0	-55	-1	-57	1.5569	1.9589
5	-55	0	-57	1.3197	1.8349
10	-63	4	-53	3.3850	3.1331
SGO	32-QAM				
-10	-116	-57	-246	3.6015	3.6262
-5	-113	-55	-262	2.4581	2.9363
0	-115	-54	-259	1.9842	2.6828
5	-113	-53	-259	1.8072	2.5994
10	-123	-65	-248	3.6096	3.6569
SGO	64-QAM				
-10	-573	37	-932	3.9718	4.4537
-5	-588	43	-943	3.0056	3.8995
0	-597	46	-935	2.6260	3.7096
5	-588	47	-945	2.4942	3.6524
10	-618	47	-927	3.9535	4.4146

Tablo 15. DVM sınıflandırıcısında PSK modüleli işaretler için kullanılan özellik değerleri

Mod	BPSK				
SGO	CUM40	CUM31	CUM22	SDD-Ölçek 2	SDD-Ölçek3
-10	-3	0	-4	3.1842	2.6578
-5	-2	-2	-2	1.8034	1.5609
0	-2	-2	-2	1.0795	1.0015

Tablo 15'in devamı

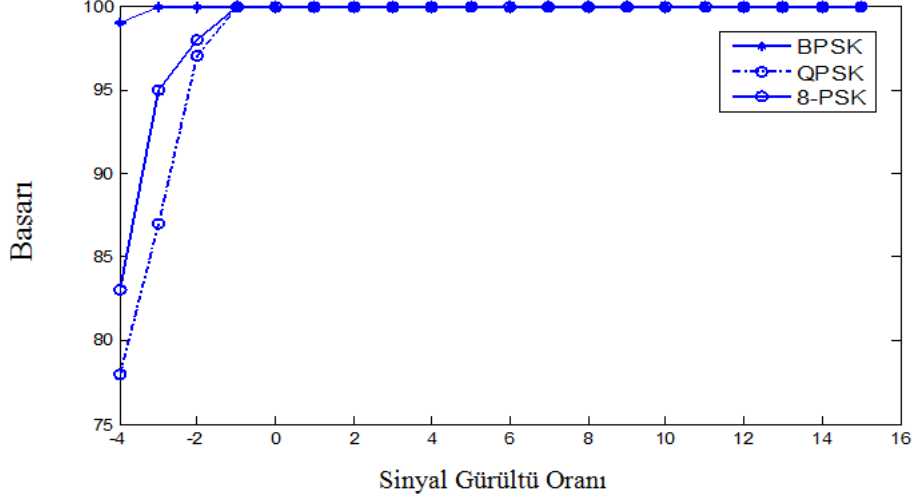
5	-2	-2	-2	0.6856	0.7422
10	-2	-2	-2	3.1807	2.6382
SGO	QPSK				
-10	3	0	-1	3.2084	2.6565
-5	1	0	-1	1.8260	1.5697
0	1	0	-1	1.0731	1.0058
5	1	0	-1	0.6800	0.7343
10	1	0	-1	3.1891	2.6607
SGO	8-PSK				
-10	-5	-1	0	3.1302	2.6029
-5	0	0	-1	1.8289	1.5688
0	0	0	-1	1.0674	1.0055
5	0	0	-1	0.6825	0.7378
10	0	0	-1	3.1841	2.6393

Tablo 14 ve 15'te gösterildiği gibi özellik vektörü oluşturmada, SDD'nin ikinci ve üçüncü ölçeklerinden elde edilen katsayıların standart sapması ve YMK'lerin dördüncü mertebesinde elde edilen özellikler, hiç bir seçim yapılmadan kullanılmıştır. Yani kullanılan her bir modülasyon tipi için beş farklı özellik miktarı kullanılmıştır. Değerlendirme ölçütü olarak BKB temelli DVM sınıflandırıcısı kullanılarak, bu çalışmaya ait karışıklık matrisi Tablo 16'da gösterilmektedir. Test sonucunda ulaşılan sonuçların başarımları karışıklık matrisi ile ifade edilir. Karışıklık matrisinde satırlar test kümesindeki örneklere ait gerçek sayıları, kolonlar ise modelin tahmini sonucunu ifade eder.

Tablo 16. Çalışmaya ait BKB temelli DVM sınıflandırıcısının karışıklık matrisi

Modülasyon Türü	Destek Vektör Makinalar (BKB)					
	Doğruluk = %88.17					
	Karışıklık matrisi					
BPSK	BPSK	QPSK	8-PSK	16-QAM	32-QAM	64-QAM
BPSK	91	9	0	0	0	0
QPSK	11	72	17	0	0	0
8-PSK	8	24	67	1	0	0
16-QAM	0	1	0	99	0	0
32-QAM	0	0	0	0	100	0
64-QAM	0	0	0	0	0	100

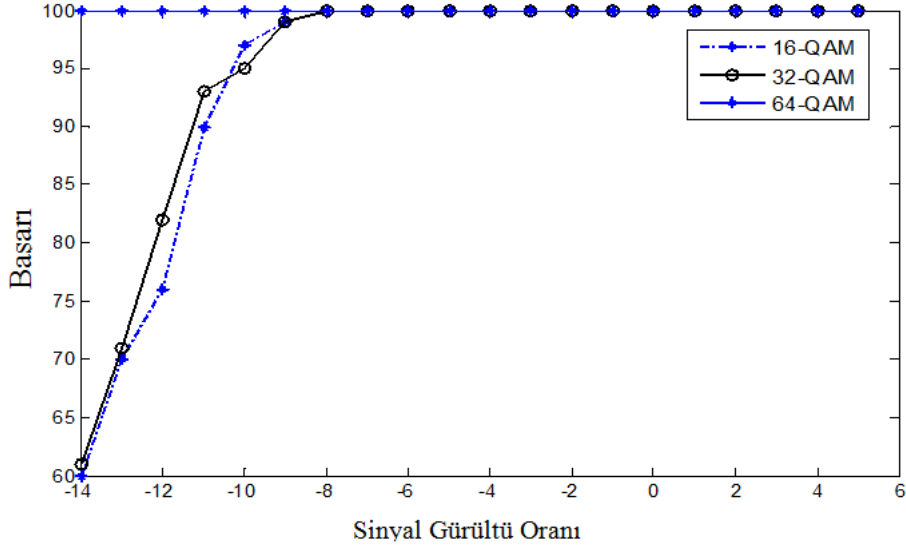
Şekil 34'te DVM sınıflandırıcısıyla, BPSK, QPSK ve 8-PSK modüleli işaretler için elde edilen sınıflandırma sonuçları gösterilmiştir.



Şekil 34. DVM sınıflandırıcısıyla BPSK, QPSK ve 8-PSK modüleli işaretler için elde edilen sınıflandırma sonuçları

Tablo 16'da karışıklık matrisi gösterilen DVM ile yapılan sınıflandırma işleminde YMK'lerin dördüncü mertebesinde elde edilen nitelikler ile SDD'nin ikinci ve üçüncü ölçeklerinden elde edilen katsayıların standart sapması kullanılarak BPSK, QPSK ve 8-PSK modüleli işaretler için Beyaz Gauss gürültülü kanallarındaki $SGO \geq -4 \text{ dB}$ olduğunda modülasyon sınıflandırma başarımları Şekil 34'de gösterilmektedir. Şekil 34'te belirtildiği üzere, $SGO = -2 \text{ dB}$ olduğu durumda BPSK, QPSK ve 8-PSK modülasyonları sırasıyla %100, %94 ve %97 başarı ile ve $SGO > -2 \text{ dB}$ olduğunda %100 başarı ile tanımlanır.

Şekil 35'te DVM sınıflandırıcısıyla, 16-QAM, 32-QAM ve 64-QAM modüleli işaretler için elde edilen sınıflandırma sonuçları gösterilmiştir.



Şekil 35. DVM sınıflandırıcısıyla 16-QAM, 32-QAM ve 64-QAM modüleri için elde edilen sınıflandırma sonuçları

Tablo 16'da karışıklık matrisi gösterilen DVM ile yapılan sınıflandırma işleminde YMK'lerin dördüncü mertebesinde elde edilen nitelikler ve SDD'nin ikinci ve üçüncü ölçeklerinden elde edilen katsayıların standart sapması kullanılarak 16-QAM, 32-QAM ve 64-QAM modüleri işaretler için Beyaz Gauss gürültülü kanallarda $SGO \geq -14$ dB olduğunda modülasyon sınıflandırma başarımları Şekil 35'de gösterilmektedir. Şekil 35'te belirtildiği üzere, $SGO = -10$ dB olduğu durumda 16-QAM, 32-QAM ve 64-QAM modüleri işaretler sırasıyla %97, %95 ve %100 başarı ile tanımlanmıştır. Aynı zamanda $SGO = -8$ dB olduğu durumda 16-QAM, 32-QAM ve 64-QAM türlü modüleri sinyaller %100 başarıyla tanımlanmıştır.

2.5. Modülasyon Tanıma İşleminde Giriş Örnek Sayısı Miktarının Etkisi

Bu çalışmanın diğer bir kısmında modülasyon tanıma işleminde giriş örnek sayısı miktarının etkisi incelenmiştir. Örnek olarak BPSK, QPSK ve 8-PSK modüleri işaretler için giriş örnek sayısının etkisini YMK'lerle çıkarılan özellikler üzerinde incelenmiştir. Elde edilen sonuçlara göre YMK'ler yöntemi ile özellik çıkarma işlemi yüksek sayıda örnek kullanarak yapıldığında elde edilen özelliklerin denge aralığı yüksek olmuştur ve modülasyon tanıma işleminden daha düşük SGO'larında da iyi sonuçlar elde edilmiştir.

Tablo 18, 20, 22'de gösterildiği gibi yüksek örnek sayısıyla çıkarılan özelliklerde SGO'nun etkisi daha azdır.

Tablo 17. BPSK modüleli işaretler için giriş örnek sayısı 2000 olduğunda YMK değerleri

MOD	BPSK													
<i>SGO</i>	-10	-9	-8	-7	-6	-5	-4	-3	-2	-1	0	1	2	3
Cum40	-4	-2	-4	-7	-4	-1	-2	-1	-2	-2	-2	-2	-2	-2
Cum31	1	-1	0	-2	-1	-2	-2	-2	-1	-2	-2	-2	-2	-2
Cum22	0	-2	1	-3	-1	-2	-2	-2	-2	-2	-2	-2	-2	-2

Tablo 18. BPSK modüleli işaretler için giriş örnek sayısı 20000 olduğunda YMK değerleri

Mod	BPSK													
<i>SGO</i>	-10	-9	-8	-7	-6	-5	-4	-3	-2	-1	0	1	2	3
Cum40	6	1	2	3	3	3	2	2	2	2	2	2	2	2
Cum31	-1	-3	-2	-2	-2	-2	-2	-2	-2	-2	-2	-2	-2	-2
Cum22	-3	-2	-1	-2	-2	-2	-1	-2	-2	-2	-2	-2	-2	-2

Tablo 17 ve 18'de gösterildiği gibi, bu tez çalışmasında kullanılan BPSK modüleli işaretlerde YMK'elde edilen özellik vektöründe giriş örnek sayısı 2000 olduğunda özellik değerlerinin miktarı $SGO \geq -1$ dB için sabittir. Yani bu özellik değerlerini kullanarak, tanıma işleminde $SGO \geq -1$ dB olduğunda iyi sonuçlar elde edilebilir ancak giriş örnek sayısı 20000 olduğunda elde edilen özellik değerleri miktarı $SGO \geq -3$ dB için sabittir. Yani bu özellikler miktarını kullanarak, tanıma işleminde $SGO \geq -3$ dB olduğunda da iyi sonuçlar elde edilebilir.

Tablo 19. QPSK modüleli işaretler için giriş örnek sayısı 2000 olduğunda YMK değerleri

Mod	QPSK													
<i>SGO</i>	-10	-9	-8	-7	-6	-5	-4	-3	-2	-1	0	1	2	3
Cum40	-2	16	3	10	1	0	1	1	1	1	1	1	1	1
Cum31	-3	2	-1	2	-1	0	0	-1	0	0	0	0	0	0
Cum22	-2	-3	4	0	0	-2	0	-1	-1	-1	-1	-1	-1	-1

Tablo 20. QPSK modüleli işaretler için giriş örnek sayısı 20000 olduğunda YMK değerleri

Mod	QPSK													
SGO	-10	-9	-8	-7	-6	-5	-4	-3	-2	1	0	1	2	3
Cum40	0	2	3	0	1	1	1	1	1	1	1	1	1	1
Cum31	0	0	-1	0	0	1	0	0	0	0	0	0	0	0
Cum22	-2	-2	0	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1

Tablo 19 ve 20'de gösterildiği gibi, bu tez çalışmasında kullanılan QPSK modüleli işaretlerde YMK yöntemi kullanılarak elde edilen özelliklerin miktarı giriş örnek sayısı 2000 olduğunda özellik değerlerinin miktarı $SGO \geq -2 \text{ dB}$ için sabittir. Yani bu özellik değerlerini kullanarak, sınıflandırma işleminde $SGO \geq -2 \text{ dB}$ olduğunda iyi sonuçlar elde edilebilir ancak giriş örnek sayısı 20000 olduğunda elde edilen özellik değerleri $SGO \geq -4 \text{ dB}$ için sabittir. Yani bu özellik değerlerini kullanarak, sınıflandırma işleminde $SGO \geq -4 \text{ dB}$ olduğunda da iyi sonuçlar elde edilebilir.

Tablo 21. 8-PSK modüleli işaretler için giriş örnek sayısı 2000 olduğunda YMK değerleri

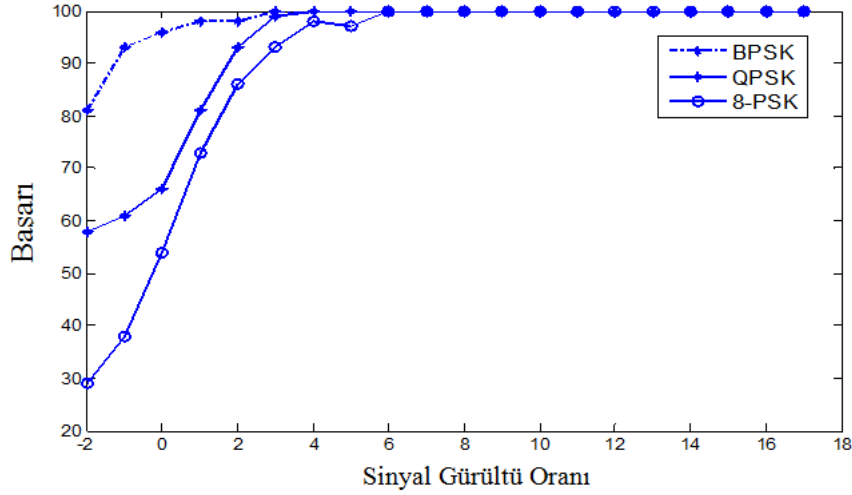
Mod	8-PSK													
SGO	-10	-9	-8	-7	-6	-5	-4	-3	-2	-1	0	1	2	3
Cum40	-11	-5	3	1	2	-1	-1	0	0	0	0	0	0	0
Cum31	-3	1	1	2	-1	0	0	0	0	0	0	0	0	0
Cum22	-2	-3	-3	-1	-1	-2	-1	-1	-1	-1	-1	-1	-1	-1

Tablo 22. 8-PSK modüleli işaretler için giriş örnek sayısı 20000 olduğunda YMK değerleri

Mod	8-PSK													
SGO	-10	-9	-8	-7	-6	-5	-4	-3	-2	-1	0	1	2	3
Cum40	1	-5	1	1	0	1	0	0	0	0	0	0	0	0
Cum31	-2	0	1	1	0	0	0	0	0	0	0	0	0	0
Cum22	0	-3	-2	-2	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1

Tablo 21 ve 22'de gösterildiği gibi, bu tez çalışmasında kullanılan PSK 8 modüleli işaretlerde YMK yönteminden elde edilen özelliklerde giriş örnek sayısı 2000 olduğunda, özellik değerlerinin miktarı $SGO \geq -3 \text{ dB}$ için sabittir. Yani bu özellik değerlerini

kullanarak, sınıflandırma işleminde $SGO \geq -3 \text{ dB}$ olduğunda iyi sonuçlar elde edilebilir ancak giriş örnek sayısı 20000 olduğunda elde edilen özellik değerlerinin miktarı $SGO \geq -4 \text{ dB}$ için sabittir. Yani bu özellik değerlerini kullanarak, modülasyon tanıma işleminde $SGO \geq -4 \text{ dB}$ olduğunda da iyi sonuçlar elde edilebilir. Aynı zamanda BPSK, QPSK ve 8-PSK modüleli işaretler için giriş örnek sayısı 2000 olduğu durumda SDD yöntemi ile gerekli özellikler çıkarıldı. Elde edilen yeni özellik setini kullanarak BKB temelli DVM yöntemiyle sınıflandırma yapılmıştır. Giriş örnek sayısı 2000 olduğu durumda BPSK, QPSK ve 8-PSK modüleli işaretlerin sınıflandırılma başarımları Şekil 36'da gösterilmektedir.



Şekil 36. Giriş örnek sayısı 2000 olduğu durumda BPSK, QPSK ve 8-PSK modüleli işaretlerin sınıflandırma başarımları

2.6. Önerilen Yöntemler Başarımını Literatürdeki Yöntemlerle Karşılaştırma

Modülasyon tanımda, farklı çalışmaları doğrudan karşılaştırma zor bir iştir ve bunun nedeni farklı çalışmalarda farklı modülasyon türlerinin kullanılmasıdır. Bununla birlikte, sistemlerin performansını kıyaslamak için farklı kıyaslama sistemleri mevcuttur ve bu doğrudan sayısal karşılaştırmada problemlere neden olur [75]. Fakat farklı makalelerde aynı modülasyon türleri herhangi bir SGO aralığında tanımlanma başarısı, bir kıyaslama sistemi olarak kullanılmıştır. Bu doğrultuda, yaptığımız çalışmalarda kullanılan modülasyon türlerini tanımda elde edilen sonuçları, aynı modülasyon türlerini içeren farklı makalelerdeki sınıflandırma sonuçlarıyla karşılaştırılmıştır (Tablo 23).

Tablo 23. Bu çalışmada elde edilen sonuçlarla literatürdeki bazı çalışmaların kıyaslanması

Kaynak	Tanımlanan modülasyonlar	Başarı	SGO
[20]	BPSK,QPSK,8-PSK, 16-QAM, 2ASK,4ASK, 2FSK ve 4FSK	%93,75	-1
[13]	BPSK, QPSK, 2FSK, 4FSK, 2ASK, 4ASK ve 16QAM	%96_98.5	0
[18]	16-QAM, 32-QAM ve 64-QAM ASK2, ASK4 ve ASK8 PSK2, QPSK ve 8-PSK FSK2, FSK4 ve FSK8	%99.5, %99,3 ve %99.8 %99.4, %99.1 ve %99.3 %99.9, %99.8 ve %99.8 %99.7, %99.2 ve %99.1	-6 -4 4 2
[21]	ASK2, ASK4, PSK2 ,QPSK, FSK2, FSK4 16-QAM	%91	-3
[11]	16-QAM, 32-QAM ve 64-QAM ASK2, ASK4 ve ASK8 FSK2, FSK4 ve FSK8 PSK2, QPSK ve 8-PSK	%99.5, 99.3% ve 99.8% %99.4, %99.1 ve %99.3 %99.7, %99.2 ve %99.1 %99.9, %99.8 ve %99.5	-10 -8 2 4
[28]	ASK4 ve ASK8 PSK2, QPSK ve 8-PSK QAM8, 32-QAM ve 64-QAM V29	%98 ve %98 %100, %100 ve %97 %96, %94 ve %92 %96	4
[25]	16-QAM , 32-QAM ve 4ASK BPSK ve QPSK BPSK, QPSK, 8-PSK	%99.8,%99,4 ve %100 %97 ve %100 %100	6 8 10
[15]	OFDM, 8-PSK, BPSK, 16-QAM ve 8-QAM 2-ASK, 4-PSK ve 32-QAM	%100 %80, %80 ve %60	-4
[76]	BPSK, QPSK 2-FSK GMSK	%100 %100 %100	-6 -6 -6
[22]	4ASK, 2ASK/ 2PSK ve 4PSK 2FSK, 4FSK ve 8FSK 16QAM	%99.8, %99,4 ve %100 %97 ve %100 %100	5
2.3.	16-QAM, 32-QAM ve 64-QAM 16-QAM, 32-QAM ve 64-QAM BPSK QPSK 8-PSK	%18, %81 ve %100 %100 %95 ve %100 %98 ve %100 %99 ve %100	-13 -12 -3 ve -2 -1 ve 0 -1 ve 0
2.4.	16-QAM, 32-QAM,64-QAM 16-QAM, 32-QAM,64-QAM BPSK, QPSK ve 8-PSK BPSK, QPSK ve 8-PSK	%97, %95 ve %100 %100 %100, %95 ve %100 %100	-10 -8 -2 -1

Tablo 23’de gösterildiği gibi önerilen üç seviyeli YSA yapılı algoritma (2.3.) düşük SGO’larda, yapılan çalışmalara kıyasla daha iyi başarı ile sonuçlanmıştır. Bu başarının asıl nedeni kullanılan SDD ve YMK’lerin gürültü karşısında dayanıklı olmaları ve önerilen üç seviyeli YSA yapılı algoritmada ele alınan özellikler setinin modülasyon türüne bağlı olarak seçilip kullanılmasıdır. Aynı zamanda önerilen üç seviyeli YSA yapılı algoritma ve kullanılan DVM yapılı ikinci algoritma (2.4.) karşılaştırıldığında önerilen birinci algoritmanın daha başarılı olarak sonuçlanmıştır. Tablo 23’te gözüktüğü gibi BPSK, QPSK

ve 8-PSK türlü modüleli işaretler her iki algoritmada hemen hemen aynı sonuçlarla tanımlanmıştır. Fakat 16-QAM, 32-QAM ve 64-QAM türlü modüleli işaretler önerilen üç seviyeli YSA yapılı algoritmada daha yüksek başarılarla tanımlanmıştır. Yani QAM türlü modüleli işaretler DVM yapılı sınıflandırıcıda $SGO = -8 \text{ dB}$ olduğunda %100 başarıyla sınıflandırılırken önerilen üç seviyeli YSA yapılı algoritmada ise $GSO = -12 \text{ dB}$ olduğu durumda %100 başarıyla tanımlanmıştır.

3. SONUÇLAR VE TARTIŞMA

Modülasyon türü bilinmeyen bir sinyal gediği anda sinyalin modülasyon türünü tanımlayabilme yeteneğine sahip olan sistemlerin askeri ve sivil amaçlı kullanımı her geçen gün artmaktadır ve bu sistemler otomatik modülasyon tanıma sistemleri olarak tanımlanmaktadır. Bu amaçla ilgili tez çalışmasında toplanır Beyaz Gauss Gürültülü kanallarda altı farklı QAM ve PSK modüleli işaretleri otomatik olarak sınıflandırabilen iki akıllı sistem gerçekleştirilmiştir. Bu çalışmada kullanılan haberleşme kanalı toplanır Beyaz Gauss gürültülü kanalı olduğu için, literatürde toplanır Beyaz Gauss gürültülü kanallarda daha iyi başarılar gösteren makaleler incelenmiştir. Literatürde yer alan çalışmaları genel olarak iki kısma ayırabiliriz:

1. Sınıflandırılan modüleli işaret tipi sayısını önemseyen çalışmalar
2. Sınıflandırma yapılan ortamın SGO miktarını önemseyen çalışmalar

İlk kısımda yer alan çalışmalar gerçekleştirilen algoritmalar vasıtasıyla oldukça fazla modülasyon tipleri üzerinde sınıflandırma yapan çalışmalardır. Fakat ikinci kısımda yer alan çalışmalar ise sınıflandırılan modüleli işaretlerin hangi SGO'larda sınıflandırıldıklarını göz önüne alan çalışmalardır. Bu tür çalışmalarda oldukça düşük SGO'larda sınıflandırma yapan algoritmaların gerçekleştirilmesini amaçlanmıştır.

Bu tez çalışmasında ise literatürdeki çalışmalar baz alınarak SDD'nin ikinci ve üçüncü ölçeklerinden elde edilen katsayıların standart sapması ve YMK'lerin dördüncü mertebesinde elde edilen değerler, özellik vektörü oluşturmada kullanılmıştır. Ve bu özellik değerlerine bağlı olarak üç seviyeli çok katmanlı YSA sınıflandırıcılar vasıtasıyla bir otomatik modülasyon tanıma sistemi gerçekleştirilmiştir. Karşılaştırma açısından, çıkarılan özellikleri kullanarak DVM sınıflandırıcısı vasıtasıyla başka bir algoritma gerçekleştirilmiştir. Çalışmanın diğer bir kısmında önerilen algoritmalar ve literatürde yer alan çalışmalar, herhangi bir SGO aralığında modülasyon türünü tanımlama başarısına göre karşılaştırılmış ve bu karşılaştırılmadan elde edilen sonuçlar Tablo 23'te gösterilmiştir. Bu tabloya göre bu tez çalışmasında önerilen birinci algoritma, literatürdeki çalışmalar ve bu çalışmada önerilen ikinci algoritmaya göre biraz daha başarılı sonuçlar vermiştir. Önerilen birinci algoritmanın modülasyon sınıflandırma performansı Şekil 32 ve 33'te ve önerilen ikinci algoritmanın modülasyon sınıflandırma performansı Şekil 34 ve 35'te gösterilmiştir.

Şekil 32 ve 33'te görüldüğü gibi birinci algoritmada ele alınan *PSK* modüleli işaretler $SGO \geq 0 \text{ dB}$ olduğunda ve ele alınan *QAM* modüleli işaretler ise $SGO \geq -11 \text{ dB}$ olduğunda en yüksek başarıyla tanımlanmışlardır. Şekil 34 ve 35'te görüldüğü gibi ikinci algoritmada ele alınan *PSK* modüleli işaretler $SGO \geq -1 \text{ dB}$ olduğunda ve ele alınan *QAM* modüleli işaretler ise $SGO \geq -8 \text{ dB}$ olduğunda en yüksek başarıyla tanımlanmışlardır. Çalışmanın diğer bir kısmında ise farklı giriş örnek sayısının etkisi, özellik çıkarma ve sınıflandırma işleminde incelenmiştir. Bu incelemeden elde edilen sonuçlara göre giriş örnek sayısı ve sınıflandırma performansı arasında doğrusal bir ilişki bulunmaktadır. Yani giriş örnek sayısı arttırıldığında sınıflandırma işleminde daha yüksek başarı elde edilmiştir. Fakat literatürde yer alan çalışmaların çoğunda bu önemli nokta yeteri kadar önemsenmemiştir. Muhtemelen bunun nedeni giriş örnek sayısı arttığında eğitim aşamasının süreci ve dolayısıyla sınıflandırma sürecinin uzanmasından kaynaklanabilir. Bu tez çalışmasında seçilen ve kullanılan gürültü karşısında dayanıklı özellik çıkarma yöntemleri vasıtasıyla giriş örnek sayısı arttırmadan kaynaklanan bu negatif etki oldukça düşürülmüştür. Yani *SDD* ve *YMK*'lerin gürültü karşısında dayanıklı olmasından dolayı elde edilen özellikler, daha sabit değerlere sahiptirler. Dolayısıyla çalışmanın eğitim aşamasında yüksek sayıda giriş örneklerinden elde edilen özelliklerin hepsinin kullanılmasına tarafımızca gerek duyulmamıştır. Yani kullanılan özellik çıkarma yöntemlerinden kaynaklanan gürültü karşısında dayanıklı özelliklerin hepsini kullanmak yerine bir kısmını kullanarak sınıflandırma zamanı düşürülmüştür, ve çalışma sonucunda elde edilen başarılar önerilen bu algoritmaların otomatik modülasyon tanıma alanında başarılı bir algoritma olduklarını göstermektedir.

4. ÖNERİLER

- Bu tez çalışmasında altı farklı sayısal modülasyon üzerinde sınıflandırma işlemi yapılmıştır. İleride yapılacak çalışmalarda sınıflandırılan modülasyon tiplerini arttırarak yüksek performanslı algoritmalar gerçekleştirilebilir.
- Literatürde incelenen çalışmalardan belli olmak üzere otomatik modülasyon tanıma kullanılan performanslı özellik çıkarma yöntemleri sınırlı sayıdadırlar. Bundan dolayı genel olarak son yıllardaki çalışmalarda önerilen algoritmalar sınıflandırıcı optimizasyonu konusuna eğilim göstermektedir. Bu yüzden yeni ve başarılı özellik çıkarma yöntemi oluşturma konusu, ilgi çekici bir çalışma alanı olmaktadır. Son yıllarda pek çok makalede yeni özellik çıkarma yöntemleri bulunmasına rağmen bu özellik çıkarma yöntemlerinin performansları düşük olmalarından dolayı hala kendilerine kullanım alanı bulamamışlardır.
- Otomatik modülasyon tanıma alanında yer alan çalışmalarda genel olarak ya fazla modülasyon tipleri üzerinde sınıflandırma yapma işlemi göz önüne alınmıştır ya da az sayıda modülasyon tiplerini oldukça düşük SGO'larda tanımlama işlemi amaçlanmıştır. Gelecek çalışmalarda yeni ve başarılı özellik çıkarma yöntemleri oluşturulmasıyla her iki amacın da gerçekleştirilebileceği kanaatindeyiz.

5. KAYNAKLAR

1. Tomasi, W., Elektronik İletişim Teknikleri, MEB, Ankara, 1994.
2. Erdem Yakut, S., Analog Modülasyonlarda Dalgacık Dönüşüm Temelli Bir Akıllı Sınıflandırma Sistemi, Yüksek Lisans Tezi, Fırat Üniversitesi, Fen bilimleri Enstitüsü, Elazığ, 2007.
3. Azzouz, E.E. ve Nandi, A.K., Automatic Modulation Recognition of Communication Signals, Kluwer Academic Publishers, London, 1996.
4. Soliman, S. S. ve Hsue, S.-Z., Signal Classification Using Statistical Moments, IEEE Transactions On Communications, 40, 5 (1992) 908- 916.
5. Guldemir, H. ve Sengur, A., Online Modulation Recognition of Analog Communication Signals Using Neural Network, Expert Systems with Applications, 33, 1 (2007) 206-214 .
6. Azzouz, E.E. ve Nandi, A.K., Automatic Modulation Recognition-I, Journal of Frankline Inst., 334B, 2 (1997) 241-273.
7. liedtke, F.F., Computer Simulation of Automatic Classification Procedure For Digitally Modulated Communication Signals With Unknown Parameters, Signal Processing, 6, 4 (1984) 311-323.
8. Dorbe, O.A., Abdi, A., Bar-Ness, Y. ve Su.W., Survey of automatic modulation classification techniques: classical approaches and new trends, IET Communication, 1, 2 (2007) 137 –156.
9. Sue, W., Jefferson, L. X. ve Mengchou, Z., Real-time Modulation Classification Based on Maximum Likelihood, IEEE Comm, 12, 11 (2008) 801-803.
10. Juan-ping, W., Ying-zheng, H., Jin-mei, Z. ve Hua-kui,W., Automatic Modulation Recognition of Digital Communication Signals, First International Conference on Pervasive Computing Signal Processing and Applications , Eylül 2010, China, Bildiriler Kitabı :590-593.
11. Hassan, K., Dayoub, I., Hamouda,W. ve Berbineau, M., Automatic Modulation Recognition Using Wavelet Transform and Neural Network, 9th International Conference. Intelligent Transport Systems Telecommunications, Bildiri kitabı: 234-238, 2009.
12. Xiaolong, C., Jiali, W., Xin, L., A New Automatic Modulation Recognition Method in Test and Measurement Technology, The Eighth International Conference on Electronic Measurement and Instruments, Bildiri kitabı: 622-625, 2007.

13. Bagga, J. ve Tripathi, N., Analysis of Digitally Modulated Signals Using Instantaneous and Stochastic Features, for Classification, International Journal of Soft Computing and Engineering (IJSCE) , 1, 2(2011) 57-61.
14. Hou, Y. ve Tian, H., An Automatic Modulation Recognition Algorithm Based on HHT and SVD, 2010 3rd International Congress on Image and Signal Processing, Bildiri kitabı: 3577-3581, 2010.
15. Pei-hua, L., Hong-xin, Z., Xu-ying, W., Nan, X. ve Yuan-yuan, X., Modulation Recognition of Communication Signals Based on Higher Order Cumulants and Support Vector Machine, The Journal of China Universities of Posts and Telecommunication, 19, 1 (2012) 61-65.
16. Ebrahimzadeh, A. ve Mousavi, S. E., Classification of Communications Signals Using an Advanced Technique, Applied Soft Computing, 11, 1 (2011) 428-435.
17. Özen, A. ve Öztürk, C., A New Modulation Recognition Method Based on Artificial Bee Colony Algorithm, 21. Sinyal İşleme ve İletişim Uygulamaları Kurultayı, 2013.
18. Hassan, K., Dayoub, I., Hamouda, W. ve Berbineau, M., Automatic Modulation Recognition Using Wavelet Transform and Neural Networks in Wireless Systems, EURASIP Journal on Advanced in Signal Processing, 42, 2010.
19. Ebrahimzade, A. ve Azimi, H. ve Mirbozorgi, S.A., Digital Communication Signals Identification Using an Efficient Recognizer, Measurement, 44 (2011) 1475-1481
20. Shi-ping, L., Fang-chao, C. ve Long, W., Modulation Recognition Algorithm of Digital Signal Based on Support Vector Machine, Control and Decision Conference (CCDC), Mayıs 2012, Taiyuan, Bildiriler kitabı: 3326 – 3330.
21. Ebrahimzade, A. ve Hossienzadeh, M., A Novel Using GA-Based Clustering and Spectral Features for Modulation Classification, Electrical and Control Engineering (ICECE), Eylül 2011, Yichang, Bildiriler kitabı: 4705-4708.
22. Zhou, X., Wu, Y. ve Yang, B., Signal Classification Method Based on Support Vector Machine and High-Order Cumulants, Wireless Sensor Network, 2, 01 (2010) 48-52.
23. Valipour, M. H., Homayounpour, M. M. ve Mehralian, M. A., Automatic Digital Modulation Recognition in Presence of Noise Using SVM and PSO, 6th International Symposium on Telecommunication, Kasım 2012, Tehran, Bildiriler kitabı: 378-382, 2012.
24. Ebrahimzade, A., Automatic Modulation Recognition Using RBFNN and Efficient Feature in Fading Channels, NDT'09., First International Conference, Temmuz 2009, Ostrava, Bildiriler kitabı: 485-48.

25. Güner, A. ve Kaya, I., Novel Automatic Modulation Classification Method tEmploying Higher-Order Cumulants and Constelation Histogram in the Presence of CFO, IEEE 21th Signal Processing and Communications Applications, Nisan 2013 Cyprus, Bildiriler Kitabı: 31-34.
26. Aslam, M.W., Zhu, Z. ve Nandi, A.K., Automatic Digital Modulation Classification Using Genetic Programming With K-Nearest Neighbor, Military Communications Conference (MILCOM), Kasım 2010, USA, Bildiriler Kitabı: 1-4.
27. Farhang, M., Dehghani, H. ve Bahramgiri, H., Multi-Receiver Modulation Classification for Satellite Communications Signals, IEEE International Conference on Signal and Image Processing Applications (ICSIPA), Kasım 2011, Kuala Lumpur, Bildiriler Kitabı: 569-573.
28. Ebrahimzade shermeh, A. ve Ghazalian, R., Recognition of communication Signal Types Using Genetic Algorithm and Support Vector Machines Based on The Higher order Statistics, Digital Signal Processing 20, 20, 6 (2010) 1748-1757.
29. Wiley, J. ve Ltd, S., Advanced Digital Signal Processing and Noise, Saeed, V.V., ISBNs: 0-471-62962-9 (Hardback), 29-43, 2000.
30. Hwei, P., Hsu, Analog ve Sayısal İletişim, Afacan, E., ,Sayfa: 200-202, Nobel Basımevi, Ankara, 2003.
31. T.C. Milli Eğitim Bakanlığı, Analog ve Sayısal Haberleşme, 523EO0143, Ankara,2011.
32. Turan, İ., Temel İstatistik, <http://temelistatistik.files.wordpress.com/2011/11/3-dac49fc4b11c4b1m-c3b6lc3a7c3bc3bcleri.pdf>, 4 Ağustos 2014.
33. Yılmaz, M., Modülasyon Teorisi, Yayın no:2, Kalite Matbaası, Ankara, 1978.
34. T.C. Milli Eğitim Bakanlığı, Haberleşme Teknikleri, 523EO0083, Ankara,2011.
35. Kayran, A.H., Panayırıcı, E. ve Aygözü, Ü., Sayısal Haberleşme, 3. Baskı, İstanbul, 1996.
36. Ertürk, S., Sayısal Haberleşme, Birsen Yayınevi, 2005.
37. <https://web.stanford.edu/class/ee384e/cgi-bin/readings/r03-radiosintro.pdf>, 20 Eylül 20014.
38. Çelikler, S. ve Öztürk, S., TMS320C6711DSP İşlemci ile GMSK Modem Uygulaması, Tübitak-UEKAE, P.K:74 Gebze, Kocaeli.
39. Şahin, B., Dalgacık Tabanlı Kod Bölmeli Çoklu Erişim (KBÇE) Sistemlerinin Simülasyonu, Yüksek Lisans Tezi, Karaelmas Üniversitesi, Fen Bilimleri Enstitüsü, Zonguldak, 2006.

40. http://ceeserver.cce.cornell.edu/wdp2/cee6150/Lectures/DIP10_PatternRec_Sp11.pdf, Pattern Recognition & Classification, 28 Haziran 2014.
41. Orman, Z., <http://www.slideshare.net/kaafi2002/rnt-tanma-pattern-recognition>, 28 haziran 2014.
42. Yalabık, N., ocw.metu.edu.tr/mod/resource/view.php?id=2818&redirect=1, 28 Haziran 2014.
43. Phan, F., Tzanakou, E.M. ve Sideman, S., Speaker Identification Using Neural Network and Waveletes, *IEEE Engineering in Medicine and Biology*, 19 (2000) 92-101.
44. Biçer, Z., Sayısal Modülasyonlarda Dalgacık Dönüşümü Temelli Bir Akıllı Sınıflandırma Sistemi, Yüksek Lisans Tezi, Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Elazığ, 2007.
45. Erkinay, Z.M., Dismorfik Hastalıkların Sinyal İşleme Yöntemleri Kullanılarak Sınıflandırılması, Doktora Tezi, Ankara Üniversitesi, Fen Bilimleri Enstitüsü, Ankara, 2012.
46. Oğuzlar, A., Veri Ön İşleme, Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi, 21, 6-12, 67-76, 2003.
47. Torrence, C. ve Compo G. P., A practical guide to wavelet analysis, *Bulletin of the American Meteorological Society*, 79 (1998), 1, 61-78.
48. Hartmann, D.L., ATM S 552 notes in .pdf files for download., http://www.atmos.washington.edu/~dennis/552_Notes_ftp.html, 3 Ağustos 2014.
49. Wieland, B., Urban, K. ve Funken, S., Speech Signal Noise Reduction With Wavelets, PhD Thesis, Ulm University, Germany, 2009.
50. Mallet, S., A Wavelet of Signal Processing, Akademik Press, 3. Baskı, 1999.
51. Akıncı, T., Ç., Güç Sistemlerinde Ferrerezonans Olayının Spektral ve Dalgacık Analizi Yöntemleriyle Belirlenmesi, Doktora Tezi, Fen Bilimleri Enstitüsü, İstanbul, 2009.
52. Young, A.F., Classification of Digital Modulation Types in Multipath Environments, Naval Postgraduate School, California, June 2008.
53. Güner, A., Bilinmeyen Bir İşaret Kaynağından Alınan Doğrusal Modülasyonlu İşaretlerin Simge Hızının ve Modülasyon Türünün Kör Olarak Kestirimi, Doktora Tezi, Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Trabzon, 2013.
54. McCulloch, W. S. ve Pitts, W., A Logical Calculus of the Ideas Immanent in Nervous Activity, *Bulletin of Mathematical Biophysics*, 5 (1943), 115-133.

55. Chua, L. ve Yang, L., Cellular Neural Network: Theory, IEEE Transaction on Circuits and Systems, 35.10 (1988): 1273-1290.
56. Charalambous, C., Conjugate Gradient Algorithm for Efficient Training of Artificial Neural Networks, IEEE proceeding, 139, 3 (1992) 301-310.
57. Ercan, S., Destek Vektör Makineleri Kullanarak Patent Değerleme, Yüksek Lisans Tezi, Fen Bilimleri Enstitüsü, İstanbul, 2011.
58. Karlık, B., Neural Network Image Recognition for Control of Manufacturing Plant, Mathematical & Computational Applications, 8.2 (2003) 181-189.
59. Rajas, R., Neural Networks- A Systematic Introduction, Springer, 1996.
60. Kabalcı, E., Yapay Sinir Ağları (Artificial Neural Networks), <http://ekblc.files.wordpress.com/2014/02/ysa.pdf>, 2 Ağustos 2014.
61. Pekçakar, A., Dalgacık Dönüşümü ile EKG Sinyallerinin İşlenmesi ve Özellik Çıkarımı, Yüksek Lisans Tezi, Fen Bilimleri Enstitüsü, Düzce, Haziran 2008.
62. Cortez, C. ve Vapnik, V., Support Vector Networks, Machine Learning, Saitta, L., Kluwer Academic Publishers, Boston, 1995, 55.
63. Osowski, S., Siwekand, K. ve Markiewicz, T., MPL and SVM Networks- a Comparative Study, Proceeding of the 6th Nordic Signal Processing Symposium, Haziran 2004, Finland, Bildiriler kitabı: 37-40, 2004.
64. Nitze, I., Schulthess, U. ve Asche, H., Comparison of Machine Learning Algorithms: Random Forest, Artificial Neural Network and Support Vector Machine to Maximum Likelihood for Supervised Crop Type Classification, Proceeding of the 4th GEOBIA, Mayıs 2012, Brazil, Bildiriler kitabı: 35-40.
65. Vapnik, V. N., An Overview of Statistical Learning Theory, IEEE Transactions on Neural Networks, 10 (1999), 988-999.
66. Özkan, Y., Veri Madenciliği Yöntemleri, 2. Basım, Papatya Yayıncılık, 2013.
67. Kavzoğlu, T. ve Çölkesen, İ., Investigation of Effects of Kernel Function in Satellite Image Classification Using Support Vector Machines, Harita Dergisi, 144 (2010), 73-82.
68. Tayyar, N. ve Tekin, S., İMKB-100 Endeksinin Destek Vektör Makineleri ile Günlük, Haftalık ve Aylık Veriler Kullanarak Tahmin Edilmesi, AİBÜ Sosyal Bilimler Enstitüsü Dergisi, 13 (2013), 189-217.

69. Hsu, C. W., Chang, C.C. ve Lin, C.J., A Practical Guide to Support Vector Classification Technical Report Department of Computer Science and Information Engineering, National Taiwan University, <http://www.csie.ntu.edu.tw/~cjlin/papers/guide/guide.pdf>, 7 Ağustos 2014.
70. Avcı, D., İnsanlarda Görülen Parazit Yumurtalarının Otomatik Sınıflandırması İçin Bir Uzman Sistem Tasarımı, Yüksek Lisans Tezi, Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Elazığ, 2009.
71. Ayhan, S. ve Erdoğan, Ş., Destek Vektör Makineleriyle Sınıflandırma Problemlerinin Çözümü İçin Çekirdek Fonksiyonu Seçimi, Eskişehir Osmangazi Üniversitesi IIBF Dergisi, 9 (2014) 175-198.
72. Vanik, V., The Nature of Statistical Learning Theory, New York: Springer Verlage, 187s.,1995.
73. Kneer, S., Pesonnaz, L. ve Deryafus, G., Single-layer Learning Revisited: A Stepwise Procedure For Bulding And Training A Neural Network, In Neurocomputing, 68 (1990) 41-50.
74. Emir, Ş., Yapay Sinir Ağları ve Destek Vektör Makineleri Yöntemlerinin Sınıflandırma Performansının Karşılaştırılması: Borsa Endeks Yönünün Tahmini Üzerine Bir Uygulama, Doktora Tezi, İstanbul Üniversitesi, Sosyal Bilimler Enstitüsü, İstanbul, 2013.
75. Mobasser, B.G., Digital Modulation Classification Using Constellation Shape, Signal Processing 80, 80, 2 (2000) 251-277.
76. He, F., Yin, Y., Zhou, L., Xu, X. ve Man, H., Principal Component Analysis of Cyclic Spectrum Features in Automatic Modulation Recognition, The 2010 Military Communications Conference- Unclassified Program- Waveforms and Signal Processing Track, 2010.

ÖZGEÇMİŞ

Saeed GHASEMİ, 1982 yılında Zencan'de doğdu. Liseyi Nebi-Ekrem Lisesi'nde okudu. 2005 yılında Öğretmenler Üniversitesi ve 2010 yılında Ruzbeh Üniversitesinde İCT (*Information Communication Technology*) Bilgi ve İletişim Teknolojisi Mühendisliği Bölümünü bitirdikten sonra, 2011 yılında Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim dalında yüksek lisans yapmaya başladı. Anadili Azerbaycan Türkçesi olmakla beraber, Türkçe, İngilizce ve Farsça dillerini çok iyi derecede bilmektedir.

YAYINLAR

Bu tez çalışmasında gerçekleştirilen uygulamalar bir adet uluslararası konferans yayını olarak sonuçlandırılmıştır.

Ghasemi, S., Gangal, A., An Effective Algorithm for Automatic Modulation Recognition, Signal Processing and Communications Applications Conference (SIU), IEEE, 2014.