

T.C.  
FIRAT ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ

**SAYISAL MODÜLASYONLARDA DALGACIK DÖNÜŞÜM  
TEMELLİ BİR AKILLI SINIFLANDIRMA SİSTEMİ**

Zeynep BİÇER

Tez Yöneticisi  
Yrd. Doç.Dr. Engin AVCI

YÜKSEK LİSANS TEZİ  
ELEKTRONİK ve BİLGİSAYAR EĞİTİMİ ANABİLİM DALI

ELAZIĞ, 2007

T.C.  
FIRAT ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ

**SAYISAL MODÜLASYONLARDA DALGACIK DÖNÜŞÜM  
TEMELLİ BİR AKILLI SINIFLANDIRMA SİSTEMİ**

Zeynep BİÇER

Tez Yöneticisi  
Yrd. Doç.Dr. Engin AVCI

YÜKSEK LİSANS TEZİ  
ELEKTRONİK ve BİLGİSAYAR EĞİTİMİ ANABİLİM DALI

ELAZIĞ, 2007

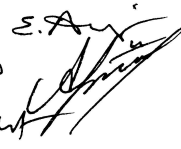
T.C.  
FIRAT ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ

**SAYISAL MODÜLASYONLARDA DALGACIK DÖNÜŞÜM  
TEMELLİ BİR AKILLI SINIFLANDIRMA SİSTEMİ**


Zeynep BİÇER

YÜKSEK LİSANS TEZİ  
ELEKTRONİK ve BİLGİSAYAR EĞİTİMİ ANABİLİM DALI

Bu tez . ~~25.09.2007~~ tarihinde aşağıda belirtilen jüri tarafından oybirliği / ~~oyçokluğu~~ ile başarılı / ~~başarısız~~ olarak değerlendirilmiştir.

Danışman: Yrd. Doç. Dr. Engin AVCI 

Üye: Yrd. Doç. Dr. Arif GÜLTEN

Üye: Prof. Dr. Z. Hakan AKPOLAT 

Bu tezin kabulü, Fen Bilimleri Enstitüsü Yönetim Kurulu'nun ...../...../..... tarih ve ..... sayılı kararıyla onaylanmıştır.

## **TEŐEKKÖR**

Bu alıőmayı yapmama olanak saęlayan, tezin her aőamasında ynlendirmeleri ve gler yzyle srekli destek olan baőta Sayın Danıőmanım Yrd.Do.Dr. Engin AVCI' ya, Yrd.Do.Dr. İbrahim TRKOęLU' na Arő.Gr. Davut HANBAY' a ve Arő.Gr. Korhan KAYIőLI' ya, yaőamım boyunca bana katkıda bulunan, bu alıőmaya ayırdıęım vakti anlayıőla karőılayan ve beni destekleyen aileme ve deęerli fikirlerinden ve bilgisinden istifade ettięim arkadaőım Sultan ERDEM YAKUT'a teőekkr ederim.

**Zeynep BİER**

## İÇİNDEKİLER

### TEŞEKKÜR

<b>İÇİNDEKİLER</b> .....	<b>I</b>
<b>ŞEKİLLER LİSTESİ</b> .....	<b>IV</b>
<b>TABLolar LİSTESİ</b> .....	<b>VI</b>
<b>SİMGELER LİSTESİ</b> .....	<b>VII</b>
<b>KISALTMALARIN LİSTESİ</b> .....	<b>VIII</b>
<b>ÖZET</b> .....	<b>IX</b>
<b>ABSTRACT</b> .....	<b>X</b>
<b>1. GİRİŞ</b> .....	<b>1</b>
1.1. Sayısal Modülasyon Tanıma Alanında Yapılan Çalışmalar.....	2
1.2. Yönelim Gereksinimleri ve Amaç.....	7
1.3. Tezin Organizasyonu ve Orijinal Katkıları.....	8
<b>2. MODÜLASYON TÜRLERİ</b> .....	<b>9</b>
2.1. Sürekli Dalga Modülasyonu.....	9
2.1.1. Genlik Modülasyonu.....	10
2.1.1.1. Taşıyıcı Genlik Modülasyonu.....	11
2.1.1.2. Çift Yan Band Modülasyonu.....	12
2.1.2. Frekans Modülasyonu.....	12
2.1.2.1. Darband FM.....	13
2.1.2.2. Genişband FM.....	14
2.1.3. Evre veya Faz Modülasyonu.....	14
2.2. Darbe Modülasyonu.....	15
2.2.1. Darbe Genlik Modülasyonu.....	15
2.2.2. Darbe Genişliği Modülasyonu.....	15
2.2.3. Darbe Konumu Modülasyonu.....	15
2.2.4. Darbe Kod Modülasyonu.....	15
<b>3. SAYISAL İLETİŞİM TEKNİKLERİ</b> .....	<b>16</b>
3.1. Genlik Kaydırmalı Anahtarlama.....	17
3.2. Frekans Kaydırmalı Anahtarlama.....	18
3.3. Faz Kaydırmalı Anahtarlama.....	21
3.4. İkili Faz Kaydırmalı Anahtarlama.....	23
3.5. Kuadratür (Dörtlü) Faz Kaydırmalı Anahtarlama.....	24

<b>4. DALGACIK DÖNÜŞÜMÜ KULLANILARAK ÖZELLİK ÇIKARMA.....</b>	<b>26</b>
4.1. Örüntü Tanıma.....	26
4.2. Örüntü Tanıma Probleminin Formülasyonu .....	27
4.3. Örüntü Tanıma Sistemleri.....	28
4.4. Örüntü Tanıma Sisteminin Bileşenleri.....	30
4.4.1. Ön İşlem.....	31
4.4.2. Özellik Çıkarma .....	31
4.5. Dalgacık Dönüşüm.....	33
4.6. Dalgacık Dönüşümden Entropi Hesaplanması.....	36
4.7. Genetik Algoritma.....	37
4.7.1. Genetik Algoritma Operatörleri .....	38
4.7.2. Kromozomun Şifrenmesi (Encoding) .....	39
4.7.3. Genetik Algoritma Parametreleri .....	42
4.7.4. Genetik Algoritmaların Uygulama Alanları.....	42
<b>5. YAPAY SİNİR AĞI İLE SINIFLANDIRMA .....</b>	<b>47</b>
5.1. Yapay Sinir Ağları .....	48
5.2. Sinir Ağlarının Biyolojik Yapısı .....	48
5.3. Yapay Sinir Ağının Tanımı ve Modeli.....	49
5.4. Yapay Sinir Ağlarının Yapısı.....	52
5.5. Yapay Sinir Ağlarında Öğrenme ve Öğrenme Algoritmaları .....	54
5.6. Yapay Sinir Ağlarının Temel Özellikleri.....	56
<b>6. GENETİK DALGACIK YAPAY SİNİR AĞI (GDYSA) YAKLAŞIMIYLA SAYISAL</b>	
<b>MODÜLASYON TANIMA UYGULAMALARI .....</b>	<b>58</b>
6.1. Sayısal Modüleli İşaretlerin Oluşturulması.....	58
6.2. Özellik Çıkarımı.....	60
6.2.1. Genetik Algoritma.....	61
6.2.2. Dalgacık Dönüşüm.....	62
6.3. Sınıflandırma.....	66
6.4. Deneysel Sonuçlar.....	67
<b>7. SONUÇ.....</b>	<b>70</b>
7.1. Sonuçlar ve Tartışma.....	70

7.2.Öneriler .....	70
7.3. Yayınlar.....	71
<b>KAYNAKLAR .....</b>	<b>72</b>
<b>ÖZGEÇMİŞ.....</b>	

## ŞEKİLLER LİSTESİ

Şekil 1.1. İletişim sisteminin blok diyagramı.....	1
Şekil 2.1. Analog modülasyon çeşitleri .....	9
Şekil 2.2. Darband FM spektrumu.....	13
Şekil 2.3. Genişband FM spektrumu.....	14
Şekil 2.4. Darbe modülasyon çeşitleri .....	15
Şekil 3.1. Sayısal iletişim sistemleri; a) sayısal iletim; b) sayısal radyo.....	16
Şekil 3.2. Sayısal iletişim sistemleri. ....	17
Şekil 3.3. ASK' nın modüle edilmiş dalga biçimleri. ....	17
Şekil 3.4. ASK modülatör.....	18
Şekil 3.5. ASK' nın eşzamansız demodülasyonu. ....	18
Şekil 3.6. Frekans kaydırmalı anahtarlama. ....	19
Şekil 3.7. İkili FSK verici. ....	20
Şekil 3.8. FKD- FSK demodülatör. ....	21
Şekil 3.9. PSK modülatör. ....	22
Şekil 3.10. PSK demodülatör.....	22
Şekil 3.11. BPSK modülatör.....	23
Şekil 3.12. QPSK modülatör.....	24
Şekil 3.13. QPSK alıcı. ....	25
Şekil 4.1. Örüntü tanıma kavramı.....	27
Şekil 4.2. Karar yüzeyinin özellik uzayının haritası olarak gösterimi. ....	28
Şekil 4.3. Örüntü tanıma sistemi.....	29
Şekil 4.4. Yapısal örüntü tanıma sistemi. ....	29
Şekil 4.5. Örüntü tanıma sisteminin bileşenleri.....	31
Şekil 4.6. Yayıgın olarak kullanılan dalgacık örnekleri.....	34
Şekil 4.7. Dalgacık dönüşümünün blok diyagramı.....	34
Şekil 4.8. n=3 seviyede dalgacık dönüşümünün yapısı. ....	35
Şekil 4.9. İkili kodlama için kromozom örneği. ....	39
Şekil 4.10. Permutasyon kodlama için kromozom örneği. ....	39
Şekil 4.11. Değer kodlama için kromozom örneği. ....	40
Şekil 4.12. Ağaç kodlama için kromozom örneği.....	40
Şekil 5.1. Akıllı sınıflama yapısı.....	47
Şekil 5.2. Biyolojik sinir hücresi.....	49



<b>Şekil 5.3.</b> Bir yapay sinir ağı hücresi modeli.....	50
<b>Şekil 5.4.</b> Aktivasyon fonksiyonları. a) Sigmoid fonksiyonu, b) Doğrusal aktivasyon fonksiyonu c) Doyumlu doğrusal aktivasyon fonksiyonu, d) Eşik aktivasyon fonksiyonu...	52
<b>Şekil 5.5.</b> Yapay sinir ağı katmanlarının birbiri ile ilişkisi. ....	53
<b>Şekil 5.6.</b> Bir yapay sinir örneği. ....	53
<b>Şekil 6.1.</b> $M=8$ , $F_c =10$ için bir ASK8 modüleli işaret örneği.....	59
<b>Şekil 6.2.</b> $M=8$ , $F_c =10$ için bir FSK8 modüleli işaret örneği.....	59
<b>Şekil 6.3.</b> $M=8$ , $F_c =10$ için bir PSK8 modüleli işaret örneği.....	60
<b>Şekil 6.4.</b> $M=8$ , $F_c =10$ için bir QASK8 modüleli işaret örneği.....	60
<b>Şekil 6.5.</b> Entropi tabanlı özellik çıkarma yönteminin blok diyagramı. ....	62
<b>Şekil 6.6.</b> 7 seviyede ayrışım yapısı.....	63
<b>Şekil 6.7.(a)</b> ASK8 işaretinin dalgacık dönüşüm ağacında bulunan işaretleri.....	63
<b>Şekil 6.7.(b)</b> FSK8 işaretinin dalgacık dönüşüm ağacında bulunan işaretleri. ....	64
<b>Şekil 6.7.(c)</b> PSK8 işaretinin dalgacık dönüşüm ağacında bulunan.....	64
<b>Şekil 6.7.(d)</b> QASK8 işaretinin dalgacık dönüşüm ağacında bulunan işaretleri.....	65
<b>Şekil 6.8.</b> YSA'nın eğitim başarımı. ....	67
<b>Şekil 6.9.</b> GDYSA kullanarak sayısal modülasyon tanımının eğitim performansı. ....	69

## TABLÖLAR LİSTESİ

<b>Tablo 1.</b> YSA yapısı ve eğitim parametreleri.....	66
<b>Tablo 2.</b> GDYSA algoritması kullanarak elde edilen optimum değerler ve GDYSA' nın sınıflama performansı.....	68

## SİMGELER LİSTESİ

$\lambda$	:	Anten boyunu temsil eder.
$\gamma_{\max}$	:	Anlık genliğin normalize edilmiş spektrum güç yoğunluğunun maksimum değeri
$\sigma_{ap}$	:	Sinyalin zayıf olmayan aralığında, anlık fazın doğrusal olmayan parçasının mutlak değerinin standart sapması
$\sigma_{dp}$	:	Sinyal parçalarının kuvvetli aralıklarında anlık fazın doğrusal olmayan bileşeninin standart sapması
P	:	Alınan radyo sinyalinin taşıyıcı frekansının etrafındaki sinyal tayf simetri ölçüsü
$a(t)$	:	Anlık genliği temsil eder.
$\varphi(t)$	:	Anlık fazı temsil eder.
$f(t)$	:	Anlık frekansı temsil eder.
$\sigma_{aa}$	:	Anlık genliğin normalize edilmiş merkezinin mutlak değerinin standart sapması
$\gamma_s$	:	Sayısal sembol serisinin sembol oranını temsil eder.
dB	:	Desibel
$\omega_0$	:	Taşıyıcı dalga frekansını temsil eder.
$\varphi$	:	Taşıyıcının fazını temsil eder.
$f(x)$	:	Fonksiyonu temsil eder.
X(t)	:	Sürekli dalgacık dönüşümünde işareti temsil eder.
A	:	Ölçekleme etmenini temsil eder.
$F_s$	:	Örnekleme oranını temsil eder.
m	:	Seviye
$F_c$	:	Taşıyıcı frekansını temsil eder.

## KISALTMALAR LİSTESİ

AF	:	Alçak Frekanslı Sinyal
RF	:	Radyo Frekansı
SGO	:	Sinyal/Gürültü Oranı
SMTA	:	Sayısal Modülasyon Tanıma Algoritması
AMTA	:	Analog Modülasyon Tanıma Algoritması
ÇYB	:	Çift Yan Bant
TYB	:	Tek Yan Bant
AYB	:	Artık Yan Bant
FM	:	Frekans Modülasyonu
EM	:	Evre Modülasyonu
DSM	:	Darbe Süresi Modülasyonu
DUM	:	Darbe Uzunluğu Modülasyonu
ASK	:	Genlik Kaydırmalı Anahtarlama
FSK	:	Frekans Kaydırmalı Anahtarlama
PSK	:	Faz Kaydırmalı Anahtarlama
QPSK	:	Kuadratör Faz Kaydırmalı Anahtarlama
SDD	:	Sürekli Dalgacık Dönüşümü
ADD	:	Ayrık Dalgacık Dönüşümü
AFD	:	Ayrık Fourier Dönüşümü
YSA	:	Yapay Sinir Ağları
GA	:	Genetik Algoritma
GDYSA	:	Genetik Dalgacık Yapay Sinir Ağı
OKH	:	Ortalama Karesel Hata
HHD	:	Hedef Hata Değeri

**ÖZET**  
**YÜKSEK LİSANS TEZİ**

**SAYISAL MODÜLASYONLARDA DALGACIK DÖNÜŞÜM TEMELLİ BİR**  
**AKILLI SINIFLANDIRMA SİSTEMİ**

Zeynep BİÇER

Fırat Üniversitesi

Fen Bilimleri Enstitüsü

Elektronik ve Bilgisayar Eğitimi

Ana Bilim Dalı

2007, Sayfa : 77

Sayısal modülasyon tanıma haberleşme sistemleri için önemli bir konudur. Bu tez çalışmasında optimum dalgacık entropi parametre değerleri kullanılarak gerçekleştirilen sayısal modülasyon sınıflama uygulamaları sunulmuştur. Burada genetik-dalgacık-sinir ağı (GDYSA) modeli geliştirilmiştir. GDYSA genetik algoritma, dalgacık dönüşümü ve çok katmanlı algılayıcı olmak üzere üç aşamadan oluşmaktadır. Genetik algoritma aşaması, uygun dalgacık entropi parametre değerlerini elde etme ve özellik çıkarmayı belirlemek için kullanılmıştır. Dalgacık dönüşüm aşaması dalgacık ayrışımı ve dalgacık entropisi olmak üzere iki kısımdan oluşmaktadır. Çok katmanlı algılayıcı katmanı sayısal modülasyonu sınıflandırmak ve genetik algoritmanın uygunluk fonksiyonunu değerlendirmek için kullanılmıştır..

**Anahtar Kelimeler** : Modülasyon Tanıma, Uyarlamalı Özellik Çıkarma, Dalgacık Dönüşümü, Entropi, Genetik Algoritma, Yapay Sinir Ağı, Uzman Sistem.

## SUMMARY

Masters Thesis

# AN INTELLIGENT CLASSIFICATION SYSTEM BASED ON WAVELET TRANSFORM FOR DIGITAL MODULATIONS

Zeynep BİÇER

Firat University

Graduate School of Natural and Applied Sciences

Department of Electronic and Computer Education

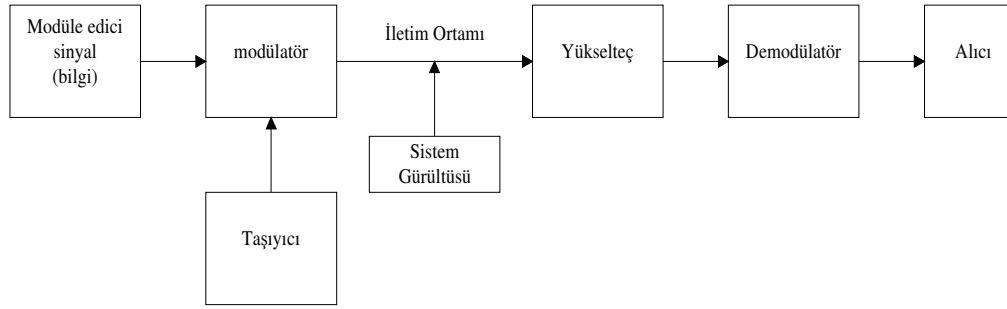
2007, Page:77

The digital modulation recognition is an important topic for communication system. In this thesis, the digital modulation applications, which are conducted by using optimum wavelet entropy parameter values are presented. A genetic- wavelet –neural network(GWNN) model is developed in here. GWNN includes three layers which are genetic algorithm, wavelet and multi-layer perception. The genetic layer is used for selecting the feature extraction method and obtaining the optimum wavelet entropy parameter values. The wavelet transform layer consists of two part: wavelet decomposition and wavelet entropies. The multi- layer perceptron layer is used for evaluating the fitness function of the genetic algorithm and for classification digital modulation.

**Keywords:** Modulation recognition, adaptive feature extraction, wavelet decomposition, entropy, genetic algorithm, artificial neural network, expert system .

## 1.GİRİŞ

Haberleşme, bilginin elektronik devrelerle iletimi, alınması ve işlenmesidir. Bir haberleşme sistemi verici, alıcı ve iletim ortamı olmak üzere üç temel kısımdan oluşur. Alçak frekanslı bilgi işaretini iletmek için yeryüzü ortamı elverişli değildir [1]. Bundan dolayı, radyo iletişiminde alçak frekanslı işaretler yüksek frekanslı işaretlere bindirilerek iletilir. Bu şekilde bilginin (ses, resim, manzara,...) taşıyıcı kullanılarak iletilmesine *modülasyon* denir. Başka bir ifadeyle modülasyon, haberin iletim ortamına verilmeden önce biçiminin değiştirilmesi anlamına gelir. Bir iletişim sisteminin basitleştirilmiş blok diyagramı Şekil 1.1' de gösterilmiştir [1].



Şekil 1.1. İletişim sisteminin blok diyagramı.

Haberin modülasyondan önce işgal ettiği banda temel bant (baseband), modülasyondan sonra işgal ettiği banda ise geçiş bandı (passband) denir. Elektronik haberleşme sistemlerinde modülasyon işlemine başvurulmasının iki temel sebebi vardır [2]:

- Haber işaretlerinin doğrudan iletimi, yaklaşık olarak aynı frekanslarda radyo dalgaları meydana getireceği için büyük girişim problemlerine yol açar.
- Çoğu haber işaretleri nispeten düşük frekanslara sahiptir. Öte yandan, antenlerin verimli çalışabilmesi için boyutlarının dalga boyu mertebelerinde olması gerekir. Bu sebeple modülasyon yapılmazsa aşırı derecede büyük antenlerin kullanılması gerekir.

Modülasyon işlemi gerçekleştirilmek için iki işarete ihtiyaç vardır; Bunlar 'bilgi işareti' ve 'taşıyıcı işaret' tir. Alçak frekanslı bilgi işaretine, modüle eden, modüle edici, modülasyon

işareti, gönderilecek işaret, alçak frekanslı (AF) işaret adı da verilir. Yüksek frekanslı taşıyıcı işarete, modüle edilen, RF (Radyo Frekans) işareti, hamal işaret de denilebilir. Modülasyon işleminde modüle eden işaret bilgi işareti, modülasyona uğrayan veya modüle edilen işaret ise taşıyıcı işarettir [3].

Modülasyonun çeşitli yararlarını ve değişik modülasyon çeşitlerini vermeden önce, modülasyonun gereğini betimlemek için aşağıdaki örneğe bakalım.

İnsan konuşma sesi 300-3000 Hz'lik frekans bandını kapsamaktadır. (Konuşma işaretinin belirtilen bant dışında da frekans bileşenleri vardır ama bunlar konuşmanın anlaşılabilirliğini fazla etkilemezler). Konuşma işaretlerini bir radyo vericisi ile iletmek istediğimizi düşünürsek [3].

$$\text{Dalga boyu; } \lambda = C / F \text{ ise} \quad (1.1)$$

$$\lambda_1 = (3.108 \text{ m/sn}) / (300 \text{ 1/sn}) = 1000 \text{ km}$$

$$\lambda_2 = (3.108 \text{ m/sn}) (3000 \text{ 1/sn}) = 100 \text{ km}$$

Yani konuşma işaretinin dalga boyu 100-1000 km arasında değişmektedir. İyi bir iletim için anten boyunun dalga boyu ile aynı derece olması gerekir (örneğin; anten boyu =  $\lambda / 4$ ). O halde radyo vericisi için anten boyu 25 – 250 km arasında olmalıdır. Bir an için böyle büyük bir anteni kurduğumuzu düşünelim. İkinci bir radyo vericisi kurulmak istenirse, her ikisi de aynı frekans bandını kullandıkları için (300 – 3000Hz) bu iki antenden çıkan dalgalar birbiriyle karışacaklardır [3].

İşte modülasyon işlemi ile bu iki kısıtlama kolaylıkla aşılabılır. Yani modülasyonun sağladığı yararlar aşağıdaki gibi sıralanabilir [2]:

- Yayılımı kolaylaştırır. Elektromanyetik alanlar yaklaşık hızında yayıldığı ve uygun şartlarda dağ tepe çukur gibi doğal engelleri kolaylıkla aşarlar. Uzayda ise uygun bir antenle çok uzaklara gidebilir.
- Gürültü ve bozulmanın olumsuz etkilerini azaltır.
- Kanal ayırımı sağlar. Yani modülasyon sayesinde aynı iletim hattında birden çok bilgi yollama olanağı sağlar (FDM ve TDM ile).
- Çevresel faktörlerin ortaya çıkardığı pek çok sınırlayıcı etkiyi ortadan kaldırır.

### **1.1. Sayısal Modülasyon Tanıma Alanında Yapılan Çalışmalar**

Kaynağı bilinmeyen işaretlerin modülasyon tipini tanıma işlemi önemlidir. İlk modülasyon tanıma çalışmalarında, her modülasyon tipi için ayrı bir demodülatör kullanılmıştır [4, 5, 6, 7, 8, 9, 10]. Modülasyon tipini belirleme, uzmanların radyo frekans spektrumunu



taramasına ve göstergeleri kontrol etmesine bağıydı [4, 5, 10]. Bu yöntem, uzmanların yetenek ve deneyimleriyle sınırlı kalmıştır. Bundan dolayı, modülasyon tanıma alanında, otomatik modülasyon tanıma sistemleri geliştirilmiştir.

Modülasyon tanıma çalışmalarında uzmanlara bağı kalmadan tanımlama yapabilmek için 1980'lerden sonra geliştirilen modülasyon sınıflandırma algoritmaları, istatistiksel örnek tanıma ve karar teori yaklaşımı olmak üzere temelde iki gruba ayrılmıştır [7, 11, 12, 13].

Haberleşme işaretleri, bir konumdan başka bir konuma farklı frekanslarda ve farklı modülasyon tiplerinde iletilirken kayıplara ve bozulmalara uğrayabilirler. Sivil ve savunma alanında kullanılan haberleşme işaretlerinin izlenmesi, tanımlanması gerekmektedir [11].

Modülasyon tanıma yöntemini herkese duyuran ilk bilim adamı Liedtke' dir. Liedtke Genlik Kaydırmalı Anahtarlama (ASK2), Frekans Kaydırmalı Anahtarlama (FSK2), Faz Kaydırmalı Anahtarlama (PSK2, PSK4, PSK8 ) gibi modülasyon türleri arasında sınıflandırma yapmak için genlik histogram, frekans histogram, faz ayırım histogram, genlik varyansı ve frekans varyansı gibi anahtar özellikleri kullanmıştır [4, 5]. ]. Liedtke'nin modülasyon sınıflandırma prosedürü aşağıdaki adımlardan oluşmaktadır.

- Yaklaşık olarak işaret bant genişliği,
- İşaret demodülasyonu ve parametre çıkarma,
- İstatistiksel hesaplama.

Polydoros ve Kim, PSK2 ve PSK4 gibi modülasyon türleri arasında ayırım yapmak için modülasyon tanıma yöntemini önermişlerdir. Bu modülasyon türleri arasında ayırım yapmak için taşıyıcı frekansı, başlangıç fazı, sembol oranı, ve işaret gürültü oranı gibi parametreler kullanmıştır [4].

Assaleh, otomatik modülasyon tanıma çalışmasında PSK2, PSK4, FSK2 ve FSK4 gibi modülasyon türlerini kullanmıştır. Assaleh yapmış olduğu çalışmasında, anlık frekansın spektrum ortalamasından elde edilen, anlık frekansın ortalamasının standart sapması ve ortalama gibi anahtar özellikleri kullanmıştır. Bu modülasyon türleri 15 dB SGO' da %99' luk bir başarı oranı ile sınıflandırılmıştır [4].

Nagy, tek bileşenli işareti analiz etmek için modülasyon tanımayı önermiştir. Bu çalışmasında sınıflayıcı olarak tek sesli sınıflayıcıyı kullanmıştır. Her işaret bileşeni için kullanılan bu sınıflayıcı iki kısımdan oluşmaktadır. Bu kısımlar;

- Algılama
- Tek harmonik işaretin farklı tipleri arasında diferansiyel faz farkının hesaplanmasıdır.

ASK2, PSK2, PSK4 ve FSK2 bu yöntemle sınıflandırılan modülasyon tipleridir. Bu modülasyon tiplerinden ASK2 hariç 10 dB SGO' da %90 başarı oranı ile sınıflandırma yapılmıştır.

Azzouz ve Nandi, sayısal modüleli işaretler için modülasyon tanımını önermiştir. ASK2, ASK4, PSK2, PSK4, FSK2 ve FSK4 gibi işaretler arasında sınıflandırma yapmak için dört anahtar özellik kullanılmıştır.

Bu çalışmada kullanılan anahtar özellikler üç önemli niteleme parametresinden elde edilmiştir. Bu parametreler anlık genlik  $a(t)$ , anlık faz  $\phi(t)$  ve anlık frekans  $f(t)$ ' tır [4]. Bu anahtar özellikler şunlardır:

- $\gamma_{max}$  : Anlık genliğin normalize edilmiş spektrum güç yoğunluğunun maksimum değeri,
- $\sigma_{ap}$ : İşaretin zayıf olmayan aralığında, anlık fazın doğrusal olmayan parçasının mutlak değerinin standart sapması,
- $\sigma_{dp}$ : İşaret parçalarının kuvvetli aralıklarında anlık fazın doğrusal olmayan bileşeninin standart sapması,
- $P$ : Alınan radyo işaretinin taşıyıcı frekansının etrafındaki işaret tayf simetri ölçümü.

Diğer bir çalışmada ise sayısal modüleli işaretler için bir modülasyon tanımlayıcı önerilmiştir [14]. Bu modülasyon tanımlayıcı da dört anahtar özellik kullanmıştır. Bu yöntemde, önceki çalışmalardan farklı olarak, her bir özellik için uygun eşik değeri seçilmiş ve eşik değerinin her değişiminde, eşik değeri otomatik olarak uyarlanmıştır. Modülasyon tanımlayıcı olarak yapay sinir ağları (YSA) kullanılmıştır.

## 1.2. Yönelim Gereçekleri ve Amaç

Bu tez çalışmasında amaç, günümüzde askeri ve sivil haberleşme ortamlarında yaygın olarak kullanılan sayısal modülasyon tekniklerinin bilgisayar ortamında otomatik olarak tanınmasını sağlayan akıllı bir sayısal modülasyon tanıma uygulaması gerçekleştirmektir. Böylelikle vericiden gelen henüz demodüle edilmemiş işaretin içinde ne tür sayısal modülasyon türlerinin olduğu kestirilerek, herhangi bir operatör kişiye ihtiyaç duyulmadan bu modülasyon türleri otomatik olarak belirlenebilecektir.

### 1.3. Tezin Organizasyonu ve Orijinal Katkıları

Tezin birinci bölümünde, teze genel bir bakış açısı kazanmaya yönelik olarak temel bilgiler verilmiştir. Diğer bölümlerin organizasyonu ve tezdeki orijinal katkıları ise aşağıda sunulmuştur.

**Bölüm 2** de, modülasyon türünün seçiminin bir iletişim sistemi için önemli olduğu anlatılmış ve bu yüzden modülasyon sınıflara ayrılmıştır. Modülasyon türlerinin taşıyıcı dalgaya ve bilgi işaretine bağlı olarak sınıflara ayrıldığından bahsedilmiş ve modülasyon türleri açıklanmıştır.

**Bölüm3** de, sayısal iletim ve sayısal radyo kavramları tanımlanarak, sahip oldukları özellikler açıklanmıştır. Sayısal iletim teknikleri verilerek, özellikleri anlatılmıştır.

**Bölüm4** de, örüntü tanıma kavramı tanımlanarak, sahip olduğu her bir bileşeni açıklanmıştır. Örüntü tanıma problemi bir matematiksel olay olarak nitelendirilerek yorumlanmıştır. Örüntü tanıma türleri verilmiştir. Örüntü tanımanın en önemli bileşeni olan ve bu tezde de odaklanılan özellik çıkarımı için önerilen dalgacık dönüşüm ve entropi hesaplama teknikleri açıklanmıştır. Ayrıca geliştirilen optimum entropi tabanlı özellik çıkarımı için kullanılan genetik algoritma kavramından da bahsedilmiştir.

**Bölüm5** de, Yapay Sinir Ağı sınıflandırıcısı tanımlanarak, sahip olduğu özellikler, biyolojik yapısı ve öğrenme algoritmalarından bahsedilmiştir.

**Bölüm6** da, tez çalışmasında geliştirilmiş olan algoritmalar ve bu algoritmaların sayısal modülasyon türleri üzerinde uygulamaları yapılmıştır. Akıllı örüntü tanıma sisteminde kullanılan, özellik çıkarım ve sınıflandırma yöntemlerinin sayısal modülasyon türlerine uygulanmasıyla elde edilen sınıflandırma sonuçları verilmiştir.

**Bölüm 7** de, tezin sonuçları irdelenmiş ve orijinal katkıları vurgulanmıştır. Ayrıca ileriye dönük uygulama alanları ve öneriler tartışılmıştır.

## 2. MODÜLASYON TÜRLERİ

Modülasyon türünün seçimi bir iletişim sisteminin tasarımında ilk yapılması gereken işlerden biridir. Değişik modülasyon türlerinin değişik özellikleri düşünülerek uygun bir seçim yapılmalıdır. Çeşitli modülasyon türleri, farklı biçimlerde sınıflandırılabilir. Modülasyon türleri kullanılan “*taşıyıcı dalgaya*” ve “*bilgi işaretine*” göre sınıflandırılabilirler. Taşıyıcıya göre sınıflandırma sonucunda iki modülasyon türü elde edilir. Bu modülasyon türleri sürekli dalga modülasyonu ve darbe modülasyonudur. Bilgi işaretine göre modülasyon türleri de analog ve sayısal olmak üzere ikiye ayrılırlar.

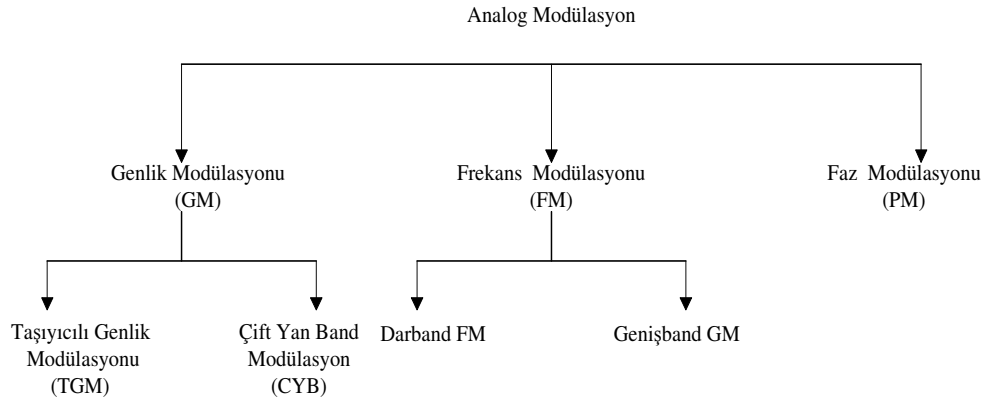
### 2.1. Sürekli Dalga Modülasyonu

Analog modülasyon, sürekli dalga modülasyonu olarak adlandırılır. Bu modülasyon türünde taşıyıcı işaret sinüzoidal dalgadır. Analog modülasyon dalga çeşitleri, taşıyıcı dalganın genlik, frekans ve faz parametreleri değiştirilerek elde edilir. Örneksele veya sürekli dalga modülasyonu genel olarak,

$$C(t) = A \cdot \cos(\omega_0 \cdot t + \varphi) \quad (2.1)$$

şeklinde ifade edilir [2].

Burada  $A$  : Taşıyıcının Genliğini ,  $\omega_0$  : Taşıyıcı dalga frekansını, ve  $\varphi$  : Taşıyıcının fazını göstermektedir. Şekil 2.1’ de analog modülasyon çeşitleri gösterilmiştir.



Şekil 2.1. Analog modülasyon çeşitleri.

### 2.1.1. Genlik Modülasyonu

Genlik modülasyonu (GM), bilgi işaretine bağlı olarak taşıyıcı işaretin genliğinin değiştirilmesidir. Genlik modülasyon tür olarak doğrusal ( lineer ) bir modülasyondur. Genliği modüle edilmiş dalga biçiminin genel şekli aşağıdaki gibidir.

$$C(t) = A(t) \cdot \cos(w_0 t + \phi) \quad (2.2)$$

A(t) genliği ile modüle edilen f(t) bilgi işareti arasındaki ilişkiye bağlı olarak genlik modülasyonunun değişik biçimleri elde edilir. Burada, f(t) modüle eden işaret (bilgi işareti),  $w_0$  ise taşıyıcı frekansını belirtir. Genlik modülasyonun üç türü vardır. Bunlar;

- Taşıyıcı Genlik Modülasyonu ( TGM)
- Çift Yan Bantlı Modülasyon (ÇYB)
- Taşıyıcısı Bastırılmış Tek Yan Bantlı Modülasyon (TYB)

Genlik modülasyonu, ses ve görüntü iletiminde diğer modülasyon türlerine göre daha ucuz ve basittir. Genlik modülasyonu dünyada uzun dalga, orta dalga vericilerinde kullanılmaktadır. Ayrıca televizyon yayıncılığında video işareti negatif genlik modülasyonuna tabi tutulmaktadır.

Bilgi işaretinin frekansı, taşıyıcı işaretin frekansından daha düşüktür. Genlik modülasyonunun uygulama alanlarından biri yüksek güçlü orta dalga ve uzun dalga radyo vericileridir. Son yıllarda üretilen orta ve uzun dalga vericilerinde uygulanan genlik modülasyonu uygulaması ile vericinin verimi %85' in üzerine çıkarılabilmektedir.

Genlik modülasyonu sonucunda iki yeni frekans oluşur. Taşıyıcı frekansının altında ve üstünde meydana gelen bu iki yeni frekansa yan bant (kenar bant) ismi verilir. Bu yan bantlardan  $f_c + f_m$  frekansına *üst yan bant* denir ve ÜYB ile gösterilir.  $f_c - f_m$  frekansına *alt yan bant* denir ve AYB ile gösterilir. Denklem (2.3)' de AYB ve ÜYB işaretlerinin matematiksel ifadesi gösterilmiştir.

$$C(t) = A \cdot \cos w_0 t + \frac{mA}{2} \cos(w_0 - w_m)t + \frac{mA}{2} \cos(w_0 + w_m)t \quad (2.3)$$

Modüleli işaretin frekans spektrumunda kapladığı alana *bant genişliği* (BG) denir. Bant genişliği Denklem (2.4)' de gösterilmiştir [23].

$$BG = f_{ÜYB} - f_{AYB} = 2.f_m \quad (2.4)$$

Modülasyon işlemi sonucunda, taşıyıcı işaretin genliğinde meydana gelen değişim miktarına *modülasyon indeksi* denir [23]. Modülasyon indeksi m ile gösterilir. Modülasyon indeksi, bilgi işaretinin genliğinin ( $E_m$ ), taşıyıcı işaretin genliğine ( $E_c$ ) oranıdır (Denklem 2.5).

$$m = \frac{E_m}{E_c} \quad (2.5)$$

### 2.1.1.1. Taşıyıcı Genlik Modülasyonu

Bu genlik modülasyonu türünde modüle edilmiş dalga biçimi aşağıdaki gibi ifade edilir:

$$A(t) = [1 + m.f(t)] \longrightarrow C(t) = A.[1 + m.f(t)].\text{Cos}(w_0 t) \quad (2.6)$$

Burada;  $f(t)$  modüle eden işaret (bilgi işareti),  $w_0$  ise taşıyıcı frekansını belirtir. m ve A değişmez sabitler olup, m modülasyon derecesidir. Normal şartlar altında bu parametrelerin aşağıda açıklanan bazı şartları sağlamaları gerekir:

**1.**  $w_0$  taşıyıcı frekansı  $f(t)$ ' nin en büyük frekans bileşeni  $w_m$ ' den çok daha büyüktür. Eğer bu şart sağlanmaz ise, yani  $w_0 \gg w_m$  değilse, modüle edilmiş dalga biçimi  $C(t)$ ' nin zarfı tam olarak saptanamaz. Oysa zarf kavramı özellikle bu modülasyon türünde çok önemlidir. En yaygın ve en kolay demodülasyon yöntemleri  $C(t)$ ' nin zarfının  $f(t)$  ye benzediği gerçeğini kullanırlar.

- $A[1+m.f(t)] \longrightarrow$  içindeki 1 terimi taşıyıcıyı gösterir. A sabiti bu taşıyıcının genliğidir ve değeri üzerinde herhangi bir kısıtlama yoktur.
- $\varphi = 0$  kabulü, zaman başlangıcı istenildiği gibi alınabileceğinden bu varsayım herhangi bir sorun çıkarmaz.

**2.** m sabiti ise; modülasyon derecesi (indeksi, yüzdesi) olup , üzerinde şu kısıtlamalar vardır: Taşıyıcı genlik modülasyonunda en önemli kısıtlama bütün t değerleri için,

- $[1 + mf(t)] \geq 0$  (veya  $mf(t) \leq 1$ ) olmasıdır. Bu şart sağlandığında modüle edilmiş işaretin zarfı, modüle eden  $f(t)$  işaretine benzer. Yalnız büyüklüğü farklıdır.
- $0 < m \leq 1$
- $m > 1$  ise aşırı modülasyon yapılır.

### 2.1.1.2. Çift Yan Band Modülasyonu

Bu modülasyon türünde modüle edilmiş işarete taşıyıcı dalga bulunmaz. Taşıyıcı dalga olmadığı için bilgi işareti eksiye de düşebilir. Taşıyıcı kullanılmayarak güçten büyük oranda tasarruf sağlanır. Bilgi işareti yan bantlarda taşınır [2]. Bu modülasyon türü

$$C(t) = f(t) \cdot \cos \omega_0 t \quad (2.7)$$

şeklinde bir dalga biçimine sahiptir.

### 2.1.2. Frekans Modülasyonu

$\omega_0$  taşıyıcı frekansı değiştiriliyorsa, bilgi işaretine bağlı olarak FM elde edilir. FM bir sürekli dalga modülasyon türüdür ve sinüzoidal taşıyıcının frekansı bilgi işareti  $f(t)$ 'ye bağlı olarak değiştirilir. Taşıyıcının frekansı  $\omega_0 = k \cdot f(t)$  biçiminde olup,  $k =$  sabittir. Modüle edilmiş FM dalga biçimi:

$$C(t) = \cos \theta(t) \quad (2.8)$$

olup, burada  $\theta(t) = \omega_0 t + \theta$  dir.

Frekans Modülasyonunun iki türü vardır. Bunlar;

- Darband FM  $\beta \ll \pi / 2$   $m \cong \beta$  : modülasyon derecesi.
- Genişband FM  $\beta \ll \pi / 2$  şartı geçerli değil

#### 2.1.2.1. Darband FM

$f(t)$  işareti bir sinüzoidal ve  $\beta \ll \pi / 2$  (rad) olduğunu varsayalım.  $\beta = 0.2$  rad gibi.

$$C(t) = \cos(\omega_0 t + \beta \sin \omega_m t) \text{ trigonometrik açılımdan sonra,} \quad (2.9)$$

$$= \cos(\omega_0 t \cos(\beta \sin \omega_m t) - \sin \omega_0 t \sin(\beta \sin \omega_m t))$$


NOT :

1.  $\beta \ll 1$  ise  $\cos \beta \cong 1$  ve  $\sin \beta = \beta$  olur.

2.  $\cos(\beta \sin \omega_m t) = 1$

3.  $\sin(\beta \sin \omega_m t) = \beta \sin \omega_m t$


$C(t) = \cos \omega_0 t - \sin \omega_0 t \cdot \beta \sin \omega_m t \rightarrow$  Darband FM' in genel ifadesi.



Şekil 2.2. Darband FM spektrumu.

### 2.1.2.2. Genişband FM

Darband olmayan FM demektir. Yani  $\beta \ll \pi/2$  şartı kaldırılıyor. Örneğin;  $\beta = 6$  gibi.





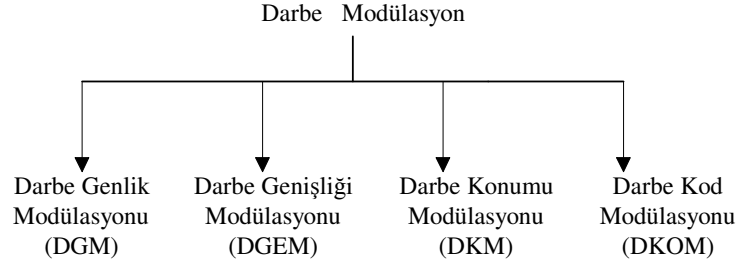
Şekil 2.3. Genişband FM spektrumu.

### 2.1.3. Evre veya Faz Modülasyonu

Bilgi işaretine bağlı olarak taşıyıcı işaretinin fazının değiştirilmesidir. Faz modülasyonlu işaret elde edilirken bilgi işaretinin türevi alınır. Frekans modülasyonunda frekans sapması meydana gelirken, faz modülasyonunda faz sapması meydana gelmektedir [15].

## 2.2. Darbe Modülasyonu

Bu türde taşıyıcı sürekli olmayıp, periyodik darbe dizisidir. Bu türün modülasyon çeşitleri şekil 2.4' te gösterilmiştir.



Şekil 2.4. Darbe modülasyon çeşitleri.

### 2.2.1. Darbe Genlik Modülasyonu

Sabit süreli, sabit konumlu bir darbenin genliği, bilgi işaretine bağlı olarak değiştirilir. Darbe Genlik Modülasyonu (DGM)' da örnek alma sürelerinin dışındaki boşluklarda başka bilgi işaretlerini göndermek mümkündür [3]. Böylece zaman çoğullamalı (bölmeli) sistemler (ZCS) elde edilir.

### 2.2.2. Darbe Genişliği Modülasyonu

Bu yönetime bazen darbe süresi modülasyonu (DSM), ya da darbe uzunluğu modülasyonu (DUM) da denir. Bu yöntemde darbe genişliği, bilgi işaretinin genliği ile orantılıdır.

### **2.2.3. Darbe Konumu Modülasyonu**

Sabit genişlikli bir darbenin konumu, önceden belirlenmiş bir zaman bölmesi içinde bilgi işaretinin genliği ile orantılı olarak değiştirilir.

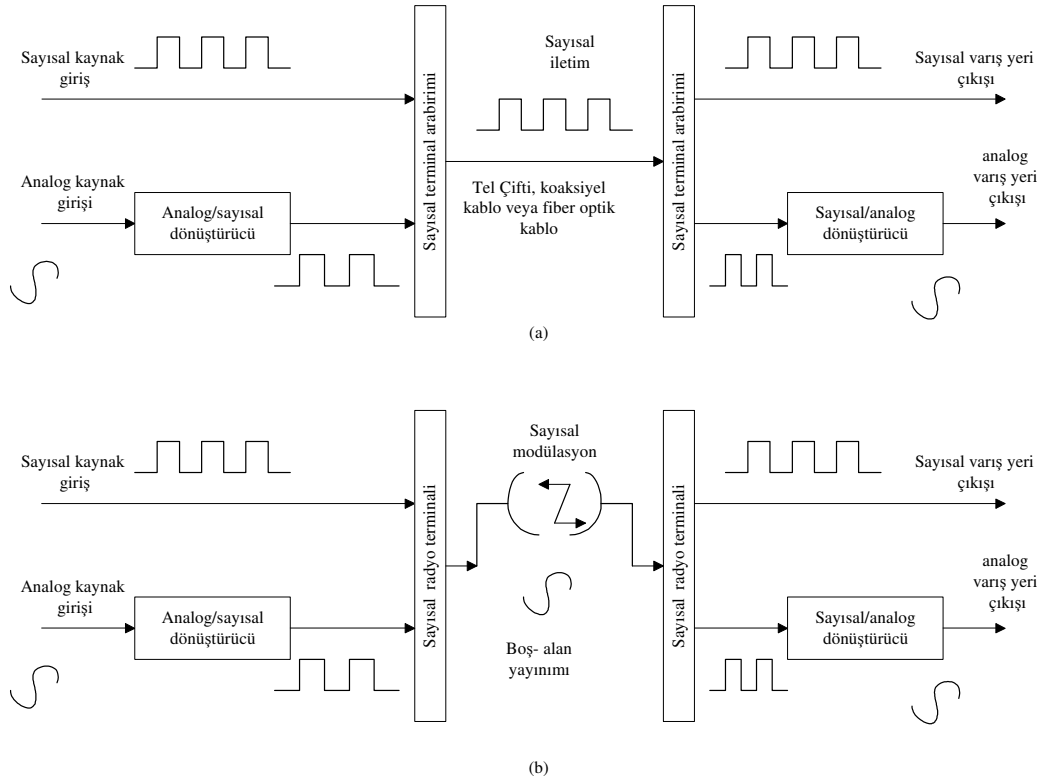
### **2.2.4. Darbe Kod Modülasyonu**

Darbe Kod Modülasyonun (DKOM)' da bilgi işareti örneklenir ve iletim için sabit uzunlukta, seri ikili bir sayıya dönüştürülür. İkili sayı, analog işaretin genliğine uygun olarak değişir. DKOM' da darbeler, sabit uzunluk (genişlik) ve sabit genliktedirler. DKOM ikili bir sistemdir.

### 3. SAYISAL İLETİŞİM TEKNİKLERİ

Sayısal iletim, bir iletişim sisteminde iki nokta arasında sayısal darbelerin iletilmesidir. *Sayısal radyo* ise, bir iletişim sisteminde iki nokta arasında sayısal modülasyonlu analog taşıyıcıların iletimidir. Sayısal iletim sistemleri, verici ile alıcı arasında metalik tel çifti, koaksiyel kablo ya da fiber optik kablo gibi fiziksel bir malzeme gerektirirler. Sayısal radyo sistemlerinde iletim ortamı boş alan ya da yeryüzü atmosferidir [1].

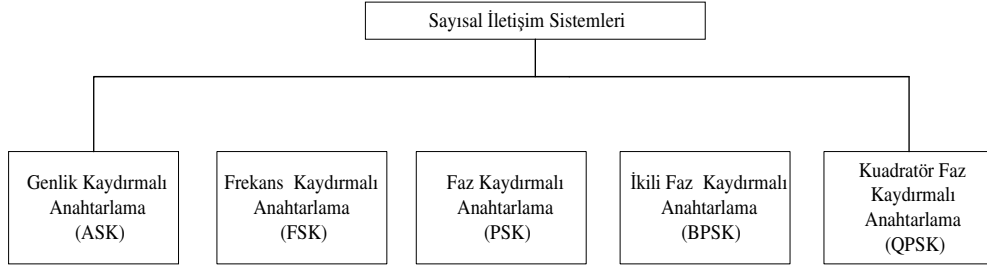
Şekil 3.1, sayısal bir iletim sistemi ile sayısal bir radyo sisteminin blok diyagramını göstermektedir. Sayısal bir iletim sisteminde, başlangıçtaki kaynak bilgi sayısal biçimde ya da analog biçimde olabilir. Eğer kaynak bilgi analog biçimdeyse, iletimden önce sayısal darbelere; alma ucunda ise tekrar analog biçime dönüştürülmelidir. Sayısal bir radyo sisteminde, module edici giriş işareti ve demodüle edilmiş çıkış işareti sayısal darbelerdir [1].



Şekil 3.1. Sayısal iletişim sistemleri; (a) sayısal iletim; (b) sayısal radyo.

Sayısal radyo sistemini klasik, GM, FM ya da PM radyo sistemlerinden ayıran özellik, sayısal radyo sisteminde module edici ve demodüle edilmiş işaretlerin, analog dalga biçimleri


değil, sayısal darbeler olmalarıdır. Klasik sistemlerde olduğu gibi sayısal radyoda da analog taşıyıcılar kullanılmaktadır. Fakat modüle edici ve demodüle edilmiş işaretler, analog dalga biçimleri değil, sayısal darbelerdir. Bunlar "Modern dünyanın yapı taşları" olan , dijital "0" ve "1" işaretleridir. En çok kullanılan sayısal iletişim sistemleri Şekil 3.2' de gösterilmiştir.



Şekil 3.2. Sayısal iletişim sistemleri.

### 3.1. Genlik Kaydırmalı Anahtarlama

Genlik Kaydırmalı Anahtarlama (ASK), ikili bilgi işaretlerinin genlik modülasyonuna uygulanmasıdır. (Var – Yok) anahtarlama (on-off keying-okk) adı verilen bu teknikte modüle edilmiş dalga biçimleri Şekil 3.3' de verilmiştir.




Şekil 3.3. ASK' nın modüle edilmiş dalga biçimleri.

Burada var durumu L -1 koduna, yok durumu L- 0 koduna karşılık düşmektedir.

- **ASK verici**

Analog sistemlerdeki ÇYB işaret üretimine benzemektedir.



Şekil 3.4. ASK modülör.

Şekilde gösterilen bir dengeli modülasyon veya çarpıcı ile ASK işaret elde edilir. C süresi kadar anahtar kapalı diğer durumlarda açıktır.

ASK işaretinin bant genişliği şu şekilde hesaplanır :

$$C(t) = A.f(t).CosWot \quad (3.1)$$

$$C(w) = \frac{A}{2} [F(w - w_0) + F(w + w_0)] \quad (3.2)$$

ASK ile ikili işaretin spektrumu  $\pm w_0$  ' ra kaydırılmaktadır.

- **ASK Alıcı**

Bunların demodülasyonu için başlıca iki yol vardır.

1. Eşzamanlı demodülasyon
2. Eşzamansız demodülasyon

Bunlar analog haberleşmedekiler ile aynıdır.




Şekil 3.5. ASK' nın eşzamansız demodülasyonu.

### 3.2. Frekans Kaydırmalı Anahtarlama

Frekans Kaydırmalı Anahtarlama (FSK), basit, düşük performanslı bir sayısal modülasyon biçimidir. FSK, frekans modülasyonuna benzer (FM) sabit zarflı bir aç

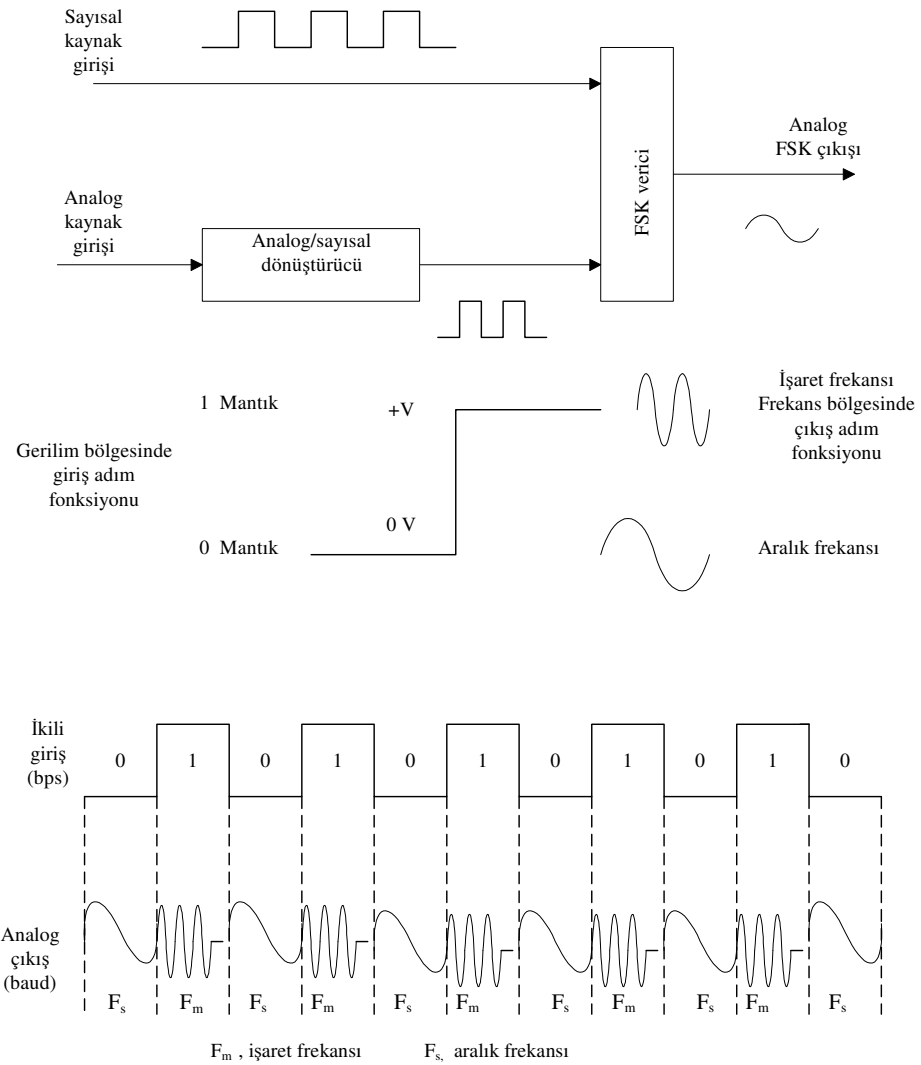
modülasyonu biçimidir; aradaki fark, modüle edici işaretin sürekli değişen bir dalga biçimi değil iki ayrı gerilim düzeyi arasında değişen ikili darbe akışı olmasıdır. Kısacası FSK, ikili bilgi işaretlerinin frekans modülasyonuna uygulanmasıdır [1]. Şekil 3.6' da frekans kaydırmalı anahtarlamamanın şekli gösterilmektedir.



Şekil 3.6. Frekans kaydırmalı anahtarlama.

- **FSK verici**

İkili FSK' da, orta frekans ya da taşıyıcı frekansı, ikili giriş verisi tarafından kaydırılır. Dolayısıyla, FSK bir modülatörün çıkışı, frekans domeninde bir basamak fonksiyonudur. İkili giriş işareti, 0 mantık düzeyinden 1 mantık düzeyine ya da 1 mantık düzeyinden 0 mantık düzeyine değiştiğinde, FSK çıkışı iki frekans arasında kayar: *işaret* ya da *mantık 1 frekansı* ile *aralık* ya da *mantık 0 frekansı*. FSK' da, ikili giriş işaretinin mantık durumu her değiştiğinde, çıkış frekansında bir değişiklik olur. Dolayısıyla, çıkış değişim hızı giriş değişim hızına eşittir. Sayısal modülasyonda, modülatörün girişindeki değişim hızına *bit iletim hızı* denir; bit iletim hızının birimi, bit bölü saniyedir (bps). Modülatörün çıkışındaki değişim hızına *baud* ya da *baud hızı* denir; baud hızı, bir çıkış işaretleme ögesinin süresinin tersine eşittir. FSK' da, giriş ve çıkış değişim hızları eşittir; dolayısıyla, bit iletim hızı ve baud hızı eşittir. Basit bir FSK verici, Şekil 3.7' de gösterilmiştir [1].


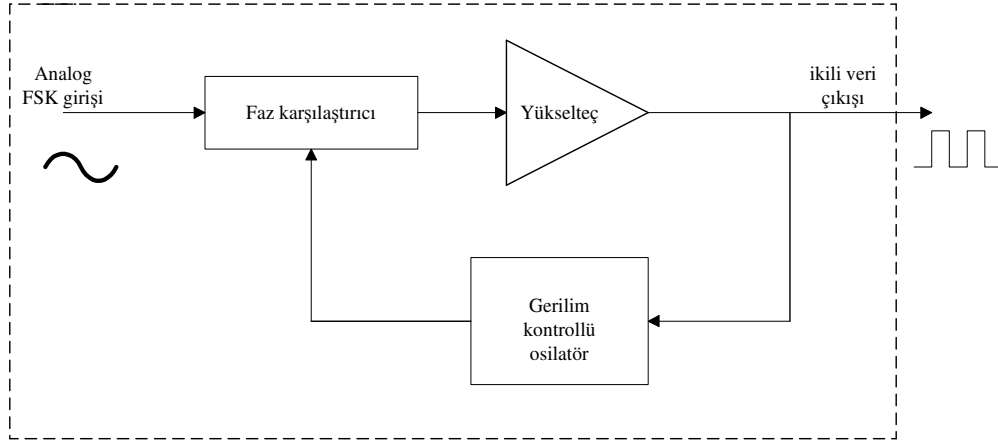


Şekil 3.7. İkili FSK verici.

- **FSK Alıcı**

FSK işaretleri demodüle etmek için en yaygın olarak kullanılan devre, Şekil 3.8' de gösterilen faz kilitlemeli döngüdür (FKD). FKD- FSK bir demodülatör, FKD'nin girişi, işaret ve aralık frekansları arasında kaydığında, faz karşılaştırıcının çıkışındaki *dc hata gerilimi* frekans kaymasını izler. Yalnızca iki giriş frekansı (işaret ve aralık) olduğu için yalnızca iki çıkış hata gerilimi vardır. Biri 1 mantık düzeyini; öteki ise 0 mantık düzeyini temsil eder. Bu nedenle çıkış, FSK girişinin iki - düzeyli (ikili) bir temsildir [1]. Genelde, FKD' nin doğal frekansı FSK modülatörün orta frekansına eşit yapılır. Bunun sonucunda, dc hata gerilimindeki değişiklikler, analog giriş frekansındaki değişiklikleri izler ve 0 V dc etrafında simetrikler.

FSK yalnızca, düşük performanslı, düşük maliyetli, asenkron veri iletişim modemlerinde kullanılır; bu modemler analog, ses bandı telefon hatlarında yapılan veri iletişiminde kullanılmaktadır [1].



Şekil 3.8. FKD- FSK demodülatör.

### 3.3. Faz Kaydırmalı Anahtarlama

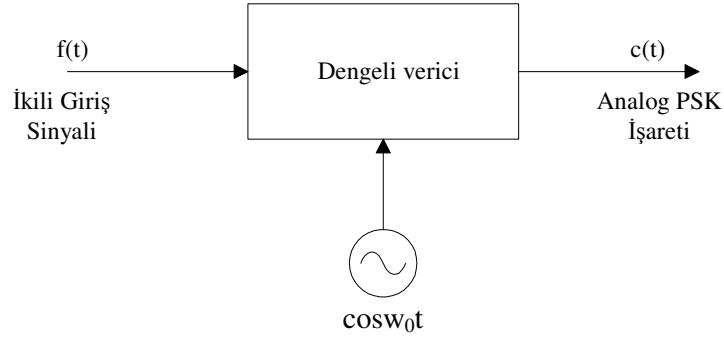
Faz kaydırmalı anahtarlama (PSK), açılı modülasyonlu, sabit zarflı, sayısal modülasyonun bir başka biçimidir. PSK, klasik faz modülasyonuna benzemektedir; aralarındaki fark şudur: PSK' da giriş işareti ikili sayısal bir işarettir ve sınırlı sayıda çıkış fazı mümkündür. Kısacası PSK, ikili bilgi işaretlerinin faz modülasyonuna uygulanmasıdır [1].

Bu tür sayısal iletişim sistemlerinde, taşıyıcının fazı, ikili işarete bağlı olarak 180 derece kaydırılır.



- **PSK Verici**

Aşağıda dengeli bir modülatör( verici) ile gerçekleştirilen PSK vericisi görülmektedir.



Şekil 3.9. PSK modülatör.

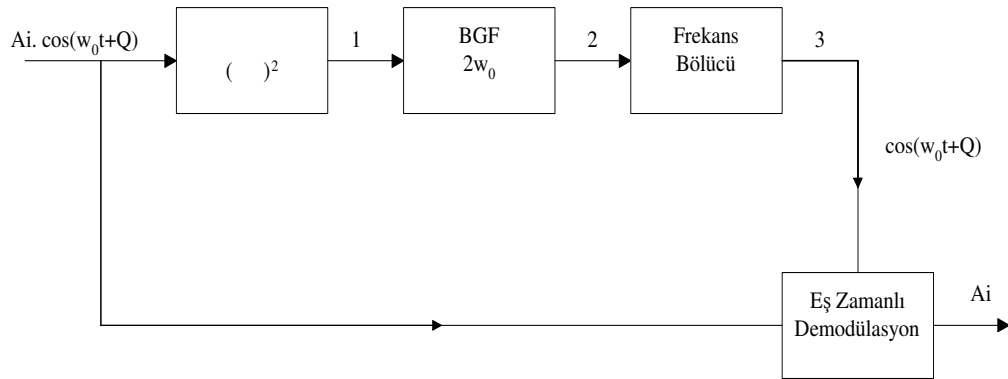
$$C(t)=A.Cos(Wot+Qi) \longrightarrow Qi=0 \text{ veya } 180^\circ \quad (3.3)$$

$$C(t)=An.CosWot \longrightarrow An=\pm A \quad (3.4)$$

PSK işaretinin modülatör çıkışı yukarıdaki gibi matematiksel olarak ifade edilebilir.

- **PSK Alıcı**

Demodülasyon işlemi eşzamanlı bir demodülatör ile yapılabilir. Şöyleki:



Şekil 3.10. PSK demodülatör.

Giriş

$$C(t) = Ai . Cos(W_0 t + Q) \quad (3.5)$$

Burada eşzamanlı demodülasyonun  $\cos(W_0t + Q)$ 'sini üretmek için bir devre kullanılmıştır. Şöyle ki;

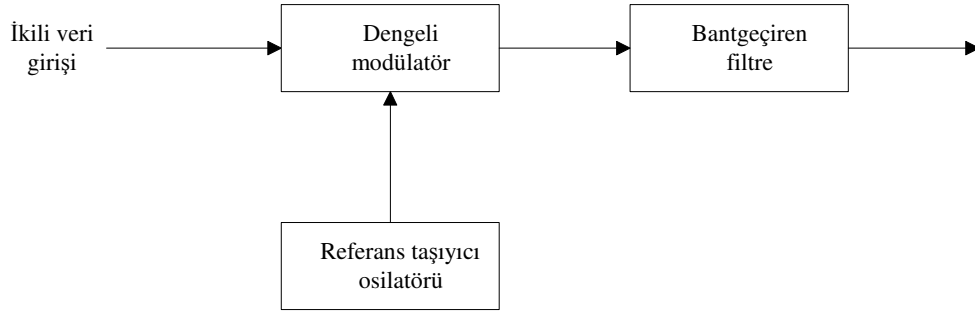
- 1)  $C(t)^2 = A_i^2 \cdot \cos^2(W_0t + Q)$
- 2)  $\cos^2(w_0t + Q)$  BGF çıkışı
- 3)  $\cos(W_0t + Q)$  elde edilir.

Eşzamanlı demodülatörde gerekli eşzamanlama yerel taşıyıcısı burada gelen işaretten elde edilmiştir. Eşzamanlı demodülatörde; gelen işaretle  $\cos(W_0t + Q)$  çarpılıp, bir AGF' den geçirilirse;

$FA = A_i$  elde edilir. Bu da ikili bilgidir.

### 3.4. İkili Faz Kaydırmalı Anahtarlama

İkili faz kaydırmalı anahtarlama (BPSK), tek bir taşıyıcı frekansı için iki çıkış fazı mümkündür. Bir çıkış fazı 1 mantık düzeyini; diğeri ise 0 mantık düzeyini temsil eder. Sayısal giriş işareti değiştiğinde, çıkış taşıyıcısının fazı,  $180^\circ$  farklı iki açı arasında kayar. Şekil 3.11 bir BPSK modülatörün basitleştirilmiş blok diyagramını göstermektedir [1].



Şekil 3.11. BPSK modülatör..

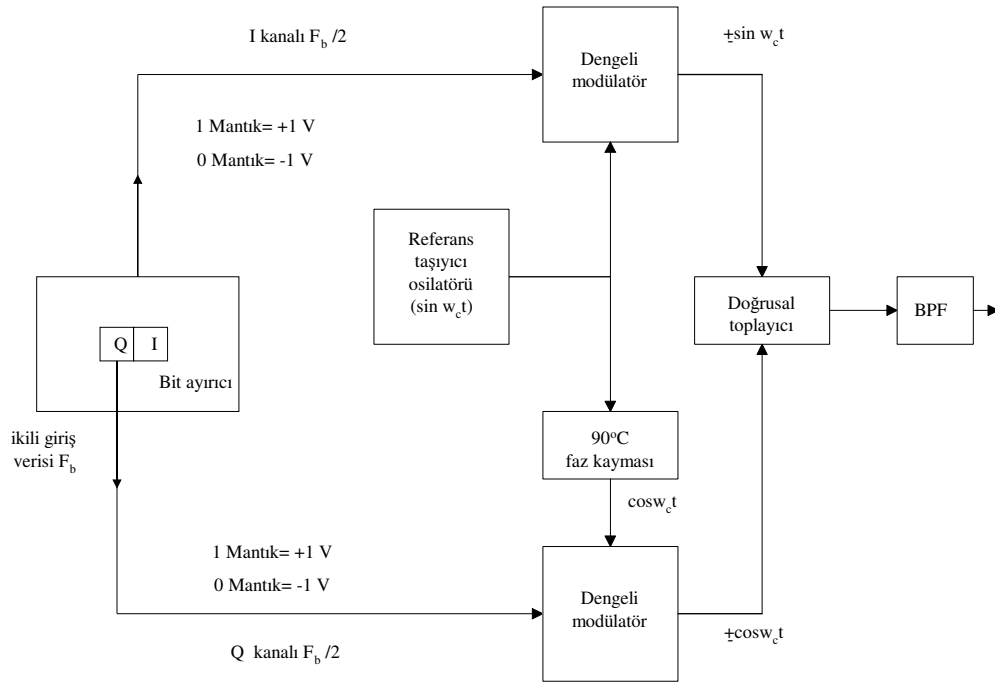
### 3.5. Kuadratür (Dörtlü) Faz Kaydırmalı Anahtarlama

Dört faz kaydırmalı Anahtarlama (QPSK), sabit zarflı sayısal modülasyon biçimidir. QPSK, M'nin 4 olduğu M-li bir kodlama tekniğidir. QPSK' da tek bir taşıyıcı frekansı için

dört çıkış fazı mümkündür. Dört farklı çıkış fazı olduğu için, dört farklı giriş durumu olmalıdır. QPSK modülatörün sayısal girişi ikili bir işaret olduğu için, dört farklı giriş durumunu üretmek için tek bir giriş bitinden fazlası gerekir. 2 bit ile, dört olası durum vardır: 00, 01, 10, ve 11. Bu nedenle QPSK' da ikili giriş verileri, *dibit* adı verilen 2 bitlik gruplar halinde birleştirilir. Her dibit kodu, dört olası çıkış fazından birini üretir. Dolayısıyla, modülatöre giren her 2 bitlik dibit için, tek bir çıkış değişikliği meydana gelir. Bu nedenle, çıkıştaki değişim hızı (baud hızı), giriş bit iletim hızının yarısıdır.

- **QPSK Verici**

Bir QPSK modülatörün blok diyagramı, Şekil 3.12' de gösterilmiştir. İki bit (bir dibit), bit ayırıcıya gönderilir. İki bitin ayırıcıya seri girişinden sonra, bu bitler çıkışa aynı zamanda paralel olarak gelirler. Bir bit I kanalına, öteki bit ise Q kanalına yönlendirilir. I biti referans modülatörü ile aynı fazda olan bir taşıyıcıyı modüle eder. Q biti ise referans taşıyıcıdan  $90^\circ$  farklı fazda olan ya da onunla dik açı yapan bir taşıyıcıyı modüle eder.

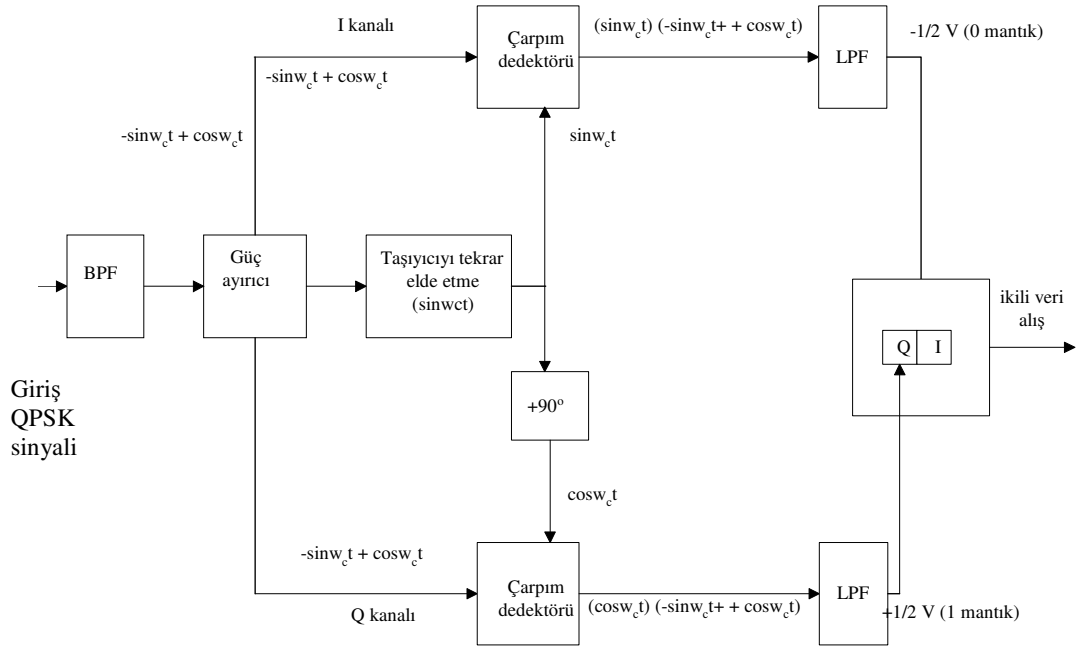


Şekil 3.12. QPSK modulator.

Bir dibit I ve Q kanallarına ayrıldıktan sonra, QPSK modülatörün çalışmasının BPSK modülatörün çalışması ile aynı olduğu görülebilir. Temel olarak, bir QPSK modülatör paralel olarak birleştirilmiş iki BPSK modülatördür [1].

- **QPSK Alıcı**

Bir QPSK alıcının blok diyagramı Şekil 3.13’ de gösterilmiştir. Güç ayırıcı, giriş QPSK işaretini I ve Q çarpım dedektörlerine ve taşıyıcıyı tekrar elde etme devresine yönlendirir. Taşıyıcıyı tekrar elde etme devresi, başlangıçtaki gönderme taşıyıcı osilatörü işaretini tekrar oluşturur. Tekrar elde edilen taşıyıcının frekansı ve fazı, gönderme referans taşıyıcısı ile koherent olmalıdır. QPSK işareti, I ve Q çarpım dedektörlerinde demodüle edilir; dedektörler, başlangıçtaki I ve Q veri bitlerini üretir. Çarpım dedektörlerinin çıkışları, bit birleştirici devreye beslenerek, paralel I ve Q veri kanallarından, tek ikili çıkış veri akışına dönüştürülür [1].



Şekil 3.13. QPSK alıcı.

Gelen QPSK işaret, (00, 01, 10, 11) dört olası çıkış fazından herhangi biri olabilir.

## 4. DALGACIK DÖNÜŞÜMÜ KULLANILARAK ÖZELLİK ÇIKARMA

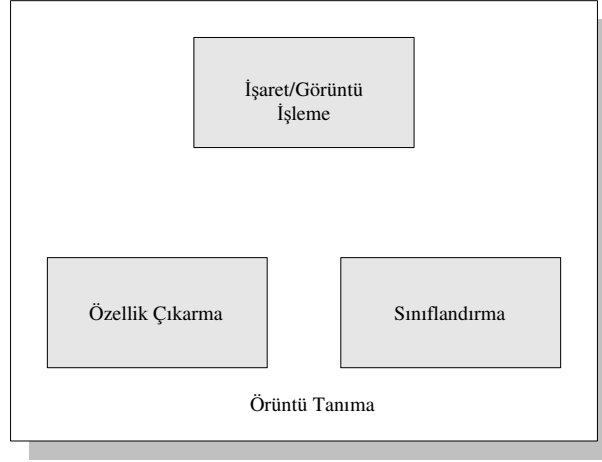
Otomatik modülasyon tanıma sınıflandırma yapabilmek için önce işarete ait özelliklerin çıkarılması gerekmektedir. Özellik çıkarabilmek için dalgacık dönüşümü kullanılarak işarete ait özellikler çıkarılmaktadır.

### 4.1. Örüntü Tanıma

Örüntü, ilgilenilen varlıklar ile ilgili gözlenebilir veya ölçülebilir bilgilere verilen addır. Gerçek dünyadaki bu örüntüler, genellikle ilgilenilen verilerin nicel tanımlama şekilleridir [16, 17]. Örüntü tanıma, insanların çeşitli ses, görüntü ve benzeri tüm örüntülerin biçimsel şekillerinden çıkardıkları dilsel şekillendirir. Aslında, örüntü tanıma bilimin, mühendisliğin ve günlük hayatın geniş bir alanındaki etkinlikleri kapsamaktadır. Örüntü tanıma uygulamalarını insanların yaşantısında da görebiliriz: hava değişimin algılanması, binlerce çiçek, bitki, hayvan türünü tanımlama, kitap okuma, yüz ve ses tanıma gibi bulanık sınırlara sahip bir çok etkinlikte örüntü tanıma kullanılır. İnsan örüntü tanımı, geçmiş tecrübelerle dayalı öğrenme esaslıdır. Böylece, insanlar pratikte karşılaştığı örüntü tanıma olaylarını tecrübeleri ışığında değerlendirebilme yeteneğine sahiptirler. Belirli bir sesi tanımak için kullanılan kuralları tanımlamak mümkün değildir. İnsanlar bu işlemlerin bir çoğunu oldukça iyi yapmalarına rağmen, bu işlemleri daha ucuz, iyi, hızlı ve otomatik olarak makinaların yapmasını arzularlar. Örüntü tanıma, böyle akıllı ve öğrenebilen makinaları gerçekleştirmek için, çok boyutlu bir mühendislik disiplini [17, 18].

Örüntü tanıma, aralarında ortak özellik bulunan ve aralarında bir ilişki kurulabilen karmaşık işaret örneklerini veya nesnelere bazı tespit edilmiş özellikler veya karakterler vasıtası ile tanımlama veya sınıflandırmadır [17, 19]. Bu bağlamda, örüntü tanımının en önemli amaçları; bilinmeyen örüntü sınıflarına belirli bir şekil vermek ve bilinen bir sınıfa ait olan örüntüyü teşhis etmektir.

Örüntü tanıma tekniklerinin uygulamaları bir çok mühendislik, tıp, askeri ve bilim alanına açıktır. Bunlardan bazıları; ses tanıma [17, 20], radar hedef sınıflama [17, 21] ve biyomedikal kontrol [17, 22] verilebilir. Örüntü tanıma olarak bilinen bu uygulamalar, makina öğrenmesi, örüntü sınıflandırma, ayırım analizi ve nitelik tahmini gibi isimlerle de anılmaktadır [17, 19]. Örüntü tanıma kavramı, Şekil 4.1' de gösterildiği gibi üç önemli kısımdan oluşmaktadır [17, 23]:



**Şekil 4.1.** Örüntü tanıma kavramı.


1. *İşaret / Görüntü İşleme* : Ön işlem aşamasıdır. İşaret veya görüntünün filtre edildiği, çeşitli dönüşüm ve gösterim teknikleri ile işlendiği, bileşenlerine ayrıldığı veya modellendiği kısımdır.
2. *Özellik Çıkarma*: İşaret ve görüntünün veri boyutunun indirgeniği ve tanımlayıcı anahtar özelliklerinin tespit edildiği ve aynı zamanda normalizasyona tabii tutulduğu aşamadır. Sistemin başarımında en etkili rolü oynar.
3. *Sınıflandırma*: Çıkarılan özellik kümesinin indirgeniği ve formüle edildiği tanımlayıcı karar aşamasıdır.

#### 4.2. Örüntü Tanıma Probleminin Formülasyonu

Örüntü tanıma probleminin şekilsel amacı, gerçek giriş uzayındaki  $M$  adet  $\{x_i\}_{i=1}^M$ ,  $x \in X \subset \mathfrak{R}^M$  gözlemleri veya ölçümleri, birkaç sınıftan  $y \in Y \equiv \{w^{(1)}, w^{(2)}, \dots, w^{(K)}\}$  birine ayırmak suretiyle tanımlayabilmektir. Sınıfsal çıkış, karar uzayındaki her bir  $w^{(k)}$  sınıfı temsil etmektedir.  $D$  operatörü Şekil 4.2' de bir harita olarak gösterilen, her bir ayrıma bir sınıf etiketi atayarak giriş uzayının ayrı bölümlere ayrılmasını sağlayan bir sınıflandırıcıyı veya giriş uzayını birbiri ile kesişmeyen bölümlere ayırarak her bir sınıfa bir etiket atayıcıyı göstermektedir ( $D : x \rightarrow y$ ) [17, 24].

İşaret uzaylarını sınıflamada, işaret örüntüsünün boyutunun çok fazla olması ve gürültü gibi birkaç engelleyici unsur vardır. Bu problemlerden kurtulmak için işareten özellik çıkarımı

yapılır. Böylece elde edilen özellik uzayı, giriş işaret uzayı ve çıkış karar uzayı arasında  $F \subset \mathfrak{R}^N$  olarak betimlenir ( $N \leq M$ ). Bir özellik çıkarıcı  $f : X \rightarrow F$  olarak tanımlanır ve sınıflandırıcı ise  $g : F \rightarrow Y$  şeklinde verilir. Böylelikle sınıflandırma süreci  $d = g \circ f$  olarak gösterilebilir [17, 25].



**Şekil 4.2.** Karar yüzeyinin özellik uzayının haritası olarak gösterimi.

Örüntü tanıma sistemine öğrenme yeteneğinin kazandırılabilmesi için genellikle  $P$  adet giriş işareti ve çıkış sınıf etiketi içeren  $(x, y)$  eğitim çiftinden oluşan  $\mathcal{T}$  eğitim kümesi kullanılır.

$$\mathcal{T} = \left\{ (x^{(1)}, y^{(1)}), (x^{(2)}, y^{(2)}), \dots, (x^{(P)}, y^{(P)}) \right\} \quad (4.1)$$

Burada  $(i)$  ifadesi eğitim kümesi içindeki  $i$ . örüntü – sınıf çiftini göstermektedir.

### 4.3. Örüntü Tanıma Sistemleri


Örüntü tanıma sistemleri gözlenen veya ölçülen verileri tanımlanmasında bir çok uygulamanın merkezinde yer alır. Şekil 4.3' de yaygın olarak kullanılan genel anlamda örüntü tanıma sistemi verilmiştir [19, 26]. Algılayıcılar, herhangi bir anda mümkün olan birçok doğal durumlardan biri olabilen bazı fiziksel işlemleri ölçerler. Bu blok diyagramın en önemli görevlerinden biride, elde edilen ölçümlerin hepsinden oluşan giriş uzayından daha az boyutta özellik çıkartmaktır. Sonunda, sınıflandırıcının rolü örüntüyü özelliklerine göre kategorize ederek uygun sınıflara kaydetmektir. Mevcut örüntü tanıma sistemleri üç grupta toplanmaktadır.



Şekil 4.3. Örüntü tanıma sistemi.

**1. İstatistiksel örüntü tanıma :** İstatistiksel örüntü tanıma yönteminde, sınıflama algoritmaları istatistiksel analiz üzerine kurulmuştur. Aynı sınıfa ait örüntüler, istatistiksel olarak tanımlanan benzer karakteristiklere sahiptirler. Bu yöntemde, özellik olarak nitelendirilen karakteristik ölçümler giriş örüntü örneklerinden çıkarılır. Her örüntü bir özellik vektörü ile tanımlanır. Genelde sınıflandırıcıyı oluşturan karar ve sınıflandırma yöntemleri üzerinde önemle durulur. Sınıflandırıcı tasarımı, ölçümler ve olasılıklar gibi işlenebilir örüntü bilgilerini birleştirmeyi esas alır. Böylece sınıflama, giriş veri uzayının olasılık yoğunluk fonksiyonlarının tahmini üzerine kurulu bir istatistiksel yapıdır [17, 27]. İstatistiksel örüntü tanıma Bayes Karar Teorisi üzerine kurulmuştur.

**2. Yapısal örüntü tanıma :** Yapısal (geometrik, kural dizilim) örüntü tanıma yaklaşımında, verilen bir örüntü, şekilsel yapıdan temel karakteristik tanımlanmaya indirgenir. Çoğu zaman, örüntülerden çıkarılan bilgi yalnızca özellikler kümesinin sayısal değerlerinden değildir. Özelliklerin birbirine bağlanması veya aralarındaki karşılıklı ilişki, tanımlamayı ve sınıflandırmayı kolaylaştıran önemli yapısal bilgiye sahiptir. Bir başka deyişle örüntünün işlenmemiş halinden elde edilen tanımlayıcı biçimsel sentaks veya bunların sentezinden çıkarılan gramer ile tanımlama gerçekleşir. Örneğin, örüntünün köşe sayısı, kenar açıları vb. Genel olarak yapısal yöntemde daha basit alt örüntüler karışık örüntülerin hiyerarşik tanımlamalarını formüle eder. Yapısal yöntemde her örüntü, bileşenlerinin bir kompozisyonu olarak ele alınır [17, 28].



Şekil 4.4. Yapısal örüntü tanıma sistemi.



Yapısal örüntü tanıma yönteminde çeşitli birimler arasındaki ilişki çok büyük önem taşır ve gerçek tanımda kullanılan bazı şekilsel notasyonlar tarafından belirtilir. Örneğin, ekrandaki bir masayı tanıma, “köşelerinden eşit uzunlukta bacaklar tarafından desteklenen yatay bir dikdörtgen yüzey” gibi yapısal tanımlamayı temel alarak gerçekleştirilebilir. Bu yöntemde, çevre uzunluğu, alan, ağırlık merkezi, eylemsizlik momenti ve Fourier tanımlayıcıları gibi genel özellikleri kullanır. Otoregresif model, poligon sal yaklaşım ve zincir kodları yapısal örüntü tanıma yöntemine örnek olarak verilebilir [29].

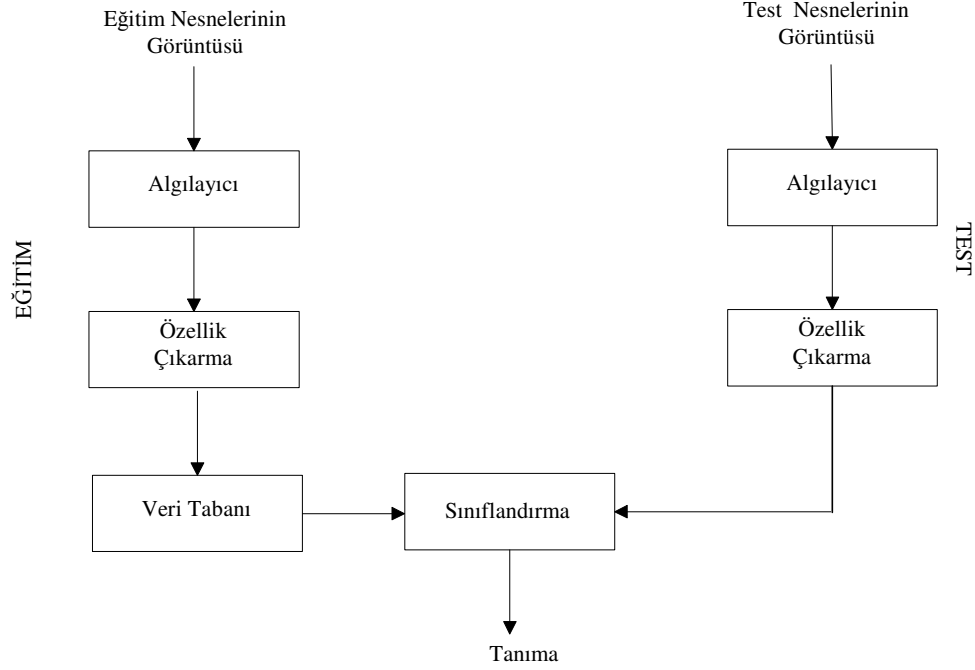
**3. Akıllı örüntü tanıma :** Akıllı örüntü tanıma yaklaşımları, öğrenme tabanlı olup, karar aşamasında geçmiş tecrübelerinden sonuç üretmektedirler. Günümüzde, öğrenmeli örüntü tanıma algoritmaları yapay sinir ağı merkezli olarak gelişmektedir ve bu doğrultuda çalışmalar yoğunluktadır [17, 20, 30, 31]. Yapay Sinir Ağları (YSA) yaklaşımları istatistik yaklaşıma karşı belirleyici olarak ifade edilebilir. Çünkü öğrenme algoritmaları örüntü sınıflarının istatistiksel özellikleri hakkında hiçbir şey kullanmamaktadır. Bununla birlikte, istatistiksel ve YSA örüntü tanıma yaklaşımları şekil ve amaç olarak çok benzer olup, hatta YSA 'nın geleneksel istatistiksel örüntü tanımanın bir uzantısı olarak ifade edilen görüşlerde bulunmaktadır [27].

İstatistiksel, yapısal ve yapay sinir ağları ile örüntü tanıma yaklaşımları arasında kesin bir ayrım yoktur. Bunlar arasındaki sınırlar bulanıklık arz eder. Bu yaklaşımlar, genel ve ortak özellikleri ve amaçları paylaşırlar. Verilen belirli bir örüntü tanıma probleminin çözümünde istatistiksel yaklaşıma göre örüntünün yapısı anlamsız olabilir. Yapı ancak uygun özellik seçimiyle yansıtılabilir. İstatistiksel örüntü tanımda; yapısal bilginin ifade edilmesinde görülen zorluk, yapısal örüntü tanımda kendini yapısal kuralların öğrenilmesinde gösterir. Buna karşın yapay sinir ağı yaklaşımı, istatistiksel ve yapısal yaklaşımlardan türetilmiştir. Açık bir şekilde örüntü hakkındaki yapısal bilgi değerli olduğunda yapısal örüntü tanıma yaklaşımını seçmek daha doğrudur. Yapısal bilgi değersiz ve maksada uygun değilse istatistiksel yöntemi seçmek daha doğrudur. Yapay sinir ağları, istatistiksel ve yapısal yaklaşıma alternatif teknikler sağlayan ve örüntü tanıma öğrenme boyutu katarak akıllı tanıma niteliği kazandıran bir teknik olarak düşünülebilir.

#### **4.4. Örüntü Tanıma Sisteminin Bileşenleri**

Örüntü tanıma sistemi eğitim ve tanıma olmak üzere iki kısımdan oluşmaktadır. Örüntü tanıma sistemi, Şekil 4.5’ de görülmektedir. Sistemin en önemli elemanları; özellik çıkarma,

veri tabanı oluşturma ve sınıflandırma (eşleme) bileşenleridir. Eğitim ve tanıma evrelerindeki algılayıcılar ve özellik çıkarma elemanları değişik olabilir [17].



Şekil 4.5. Örüntü tanıma sisteminin bileşenleri.

#### 4.4.1. Ön İşlem

Algılayıcılar vasıtasıyla, bilgisayara sayısal olarak alınmış olan örüntü, daha basit bir şekle getirmek için bir dizi ön işlem sürecinden geçirilir. Örneğin, alınan örüntü bir nesne görüntüsü ise; sırasıyla, görüntü eşikleme, kenar çıkarma gibi aşamalardan geçirilir.

#### 4.4.2. Özellik Çıkarma

Özellik çıkarma örüntü tanımanın en önemli kısmı olup, bir anlamda örüntü tanıma sisteminin başarımında anahtar rolü oynar. Örüntü sınıfları arasında ayrımı gerçekleştirmek için örüntü özelliklerinin çıkarılması gerekir. Günümüzde, çok başarılı sonuçlar veren örüntü sınıflandırıcı türleri mevcut olup, sınıflandırıcının da doğrudan başarımını etkileyen özellik çıkarımı üzerine çalışmalar odaklanmıştır. Özellik çıkarmanın ana sebepleri:

1. Sınıflandırıcının küçük hatalar ile eğitimi ve karar aşamasının kısa sürede gerçekleşmesi için gereklidir.

2. Sabit olmayan zaman serilerinde karakteristikleri bulabilmek için özellik çıkarımı şarttır. Böylece karar aşamasının güvenilirliği artacaktır.
3. Örüntü sınıflandırma sisteminin, sistem içi veya dışındaki kontrolsüz girişimlerden etkilenmemesini sağlayacak bir özellik çıkarımı kararlı bir yapının oluşmasında etken olacaktır. Bu tür kararlı özellikler, sınıflandırıcının genelleme ve ayırışım yeteneğinin yüksek olmasında önemlidirler.

Örüntü özelliklerini belirlemede ana problem verilen esas örüntüden en iyi özellikleri seçmektir [17]. İşaretler örüntülerinin özellikleri belirlendiğinde, özellik çıkarımı için genelde zaman ve frekans bölgesi gösterimi ön plandadır. Böylece karmaşık örüntü yapısının hem geçici ve hem de zamana bağlı olarak frekans değişimlerini içeren tanımlayıcı özellik bilgileri çıkarılabilir. Bu özellikler, işaretin zaman ve frekans bölgelerindeki yerel bilgilerini karakterize eder.

Nesne örüntülerinin özellik çıkarımı yapıldığında, özellikler kullanılan veritabanı ve uygulama alanına göre farklılık gösterir. Temel özellikler kenar, köşe, doğru ve eğri çizgiler, delik ve sınır eğriselliğidir. Nesne örüntüsü tanımlamaları bu özelliklerin birinden veya birkaçının birleştirilmesinden elde edilir.

Endüstriyel uygulamalarda çoğu zaman nesne örüntüsü sınırları ve bu sınırlardan türetilmiş ölçümler, özellik olarak kullanılır. Bu özellikler genel, yerel ve ilişkisel olmak üzere üç guruba ayrılabilir. Genel özelliklere örnek olarak çevre, ağırlık merkezi, sınır noktalarının ağırlık merkezine uzaklığı, eğrisellik, alan, eylemsizlik momenti gibi özellikler verilebilir. Doğru parçaları, sabit eğriselliği olan çember parçaları yerel özellikler için örnek verilebilir. İlişkisel özelliklere örnek olarak, nesne örüntüsünün alt parçalarının birbirlerine göre uzaklıkları, açıları gibi parametreler verilebilir. Özellikler çıkarılırken aşağıdaki yöntemler kullanılır.

*Otoregresif model;* Bu modelin esası, nesnenin sınırının bir boyutlu simgelenmesinde merkezsiz uzaklığın kullanımına dayanır. Algoritmanın ilk aşamasında merkez noktası hesaplanır. Daha sonraki aşamada nesnenin kenarını oluşturan her bir noktanın merkeze göre öklit uzaklığı bulunur [17].

*Poligonal yaklaşım;* Bu modelde, nesneye ait kritik noktaların hesabı yapılmaktadır. Nesnenin en sol üst sınır pikseli ile en sağ alt sınır pikseli başlangıç kritik noktaları olarak alınır. Bu iki nokta arasında düz bir çizgi çizilir. Daha sonra bu düz çizgiye dik doğrular saptanır. Bu doğruların kenar piksellerini kestiği noktalar belirlenir. Düz çizgi ile bu noktalar arasındaki dik doğru parçalarının uzunluğu hesaplanır. Belirli bir eşik değerinin üstündeki noktalar kritik

noktalar olarak tespit edilir. Bu noktaların tek boyutlu simgelenmesi ile elde edilen özelliklerden öznitelik vektörü oluşturulur [17].

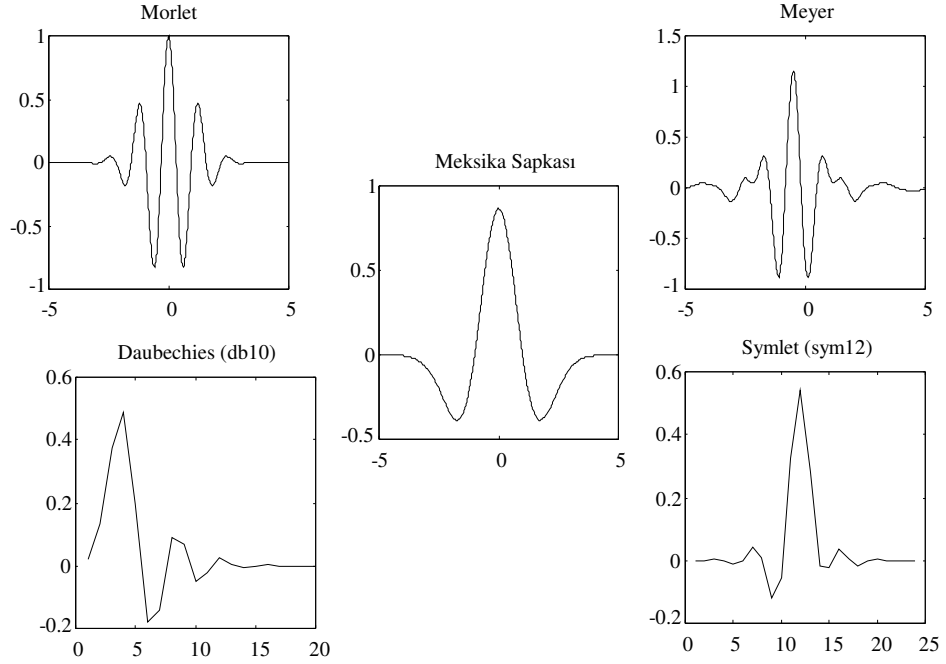
*Zincir kodları;* Sayısal görüntü, kenar çıkarma işleminden geçirildikten sonra, nesnenin sadece dış çizgileri kalır. Bundan sonraki adımda nesnenin kenar bilgilerinin kodlanması gerekir. Kodlama işlemi için zincir kodları kullanılabilir dörtlü ve sekizli olmak üzere iki tip zincir kodlama türü bulunmaktadır. Sekizli zincir kodunun dörtlü zincir koduna göre en önemli üstünlüğü yatay ve dikey kenar çizgilerinin yanı sıra çapraz kenar çizgilerini de kodlama imkânı tanınmasıdır. Zincir kodları ile nesnenin kenarlarının hangi yönde ne kadar devam ettiği tespit edildikten sonra elde edilen bu öznitelik vektörüne, çeşitli işlemler uygulanarak daha küçük boyutta ve tüm nesnelere için daha genel bir vektör oluşturulabilir [17].

#### **4.5. Dalgacık Dönüşüm**

Dalgacıklar, veriyi farklı frekans bileşenlerine ayıran ve sonra kendi ölçekleriyle eşleştirilmiş bir çözünürlüğe sahip bileşenler üzerinde çalışan matematiksel fonksiyonlardır [33, 34]. Başka bir ifadeyle dalgacık dönüşümü, fonksiyonları, operatörleri veya veriyi farklı frekanstaki bileşenlerine ayıran ve ayrı ayrı her bileşen üzerinde çalışmamıza izin veren bir araçtır [34, 35, 36, 37].

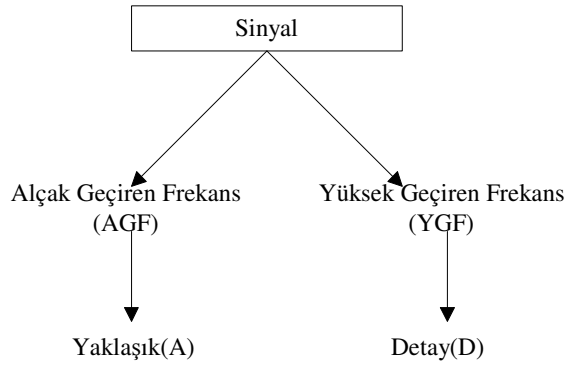
Dalgacık teorisi farklı alanlarda birçok köke sahiptir. Fakat sürekli dalgacık dönüşümü Morlet (1982), Grossmann ve Morlet (1984), ve Goupillaud, Grossmann ve Morlet (1984) tarafından ilk olarak jeofizik alanında geliştirildi. Temelleri, Chui (1992) ve Meyer (1993) tarafından sağlamlaştırıldı. Dönüşümün ayrık yorumunu, Mallat (1989) ve Daubechies (1992) geliştirdi. Dalgacık paket dönüşümü, ayrık dalgacık dönüşümünün genelleştirilmiş bir hali olup, Coifman ve Wickerhauser (1992) tarafından önerilmiştir.

Dalgacık dönüşümü, işaret işleme, özellik çıkarma, ses tanıma, resim sıkıştırma, bilgisayar görme gibi birçok alanda kullanılmaktadır. Şekil 4.6' da en yaygın olarak kullanılan dalgacıkların bir kısmı verilmiştir.



**Şekil 4.6.** Yaygın olarak kullanılan dalgacık örnekleri.


Dalgacık dönüşümüyle yaklaşık ve detay olmak üzere iki işaret elde edilir. Yaklaşık A ile detay D ile gösterilir. Yaklaşık (A) , işaretin yüksek skala – düşük frekans bileşenlerinden oluşur. Detaylar (D) ise işaretin düşük skala – yüksek frekans bileşenleridir. Dalgacık dönüşümünün en basit blok diyagramı Şekil 4.7’ de gösterilmiştir.



**Şekil 4.7.** Dalgacık dönüşümünün blok diyagramı.

Dalgacık dönüşümüyle istenilen seviyede ayrışım yapılır [35]. Çok seviyeli ayrışımında elde edilen detay ve yaklaşık katsayılarından yaklaşık katsayısı ile ayrışımaya devam edilmekte

ve bunun sonucunda yeniden A, D işaretleri elde edilmektedir. Ayırışım n seviyesine kadar yapılabilen ve buna “Dalgacık ayırıştırma ağacı” adı verilmektedir. 3 seviyeli dalgacık dönüşümü Şekil 4.8’ de gösterilmiştir. Örneğin n= 3 yani üç aşamalı bir dalgacık dönüşümü sonucunda 3 A, 3 D işaretleri olmak üzere toplam 6 işaret elde edilir. Dalgacık dönüşümü kullanılarak yapılan ayırıştırmada en küçük detaylar ortaya çıkarılır [35].



**Şekil 4.8.** n=3 Seviyede dalgacık dönüşümünün yapısı.

Dalgacık dönüşümleri, sürekli dalgacık dönüşümleri, ayrık dalgacık dönüşümleri ve dalgacık paket analizi olmak üzere üç farklı kategoride incelenebilir.

1) *Sürekli Dalgacık Dönüşümü:* Sürekli Dalgacık Dönüşümü (SDD) sıkıştırma, genişleme ve dönüşümler ile tüm zaman ve ölçeklerdeki işaretler ile ana dalgacık arasında uygunluk sağlar.

$$SDD(a, b) = - \int_{-\infty}^{\infty} x(t) \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right) dt \quad (4.2)$$

Burada  $x(t)$  işaret,  $\psi(t)$  dalgacıktır,  $b$  dönüşüm etmeni olup, farklı frekans seviyelerinde ayırışım filtreleri tanımlar ve  $a$  ise ölçekleme etmeni olup her seviye için ayırışım filtrelerini ölçeklendirir. Dönüşüm sonucu, zamanın bir fonksiyonu olarak işaret ve dalgacık arasında nasıl karşılıklı bir ilişki (korelasyon) olduğunu gösterir. İşaret ve dalgacık iyi eşleşmişse işaret ve dalgacık arasındaki korelasyon yüksek olur. Uygulamalara bağlı olarak dalgacık türü seçilir. SDD deki ölçekleme kavramı Fourier Dönüşüm (FD)’ deki frekansın tersine benzerdir. Dalgacık yüksek oranda sıkışık olduğunda işaretin yüksek frekans detaylarını elde eder. Dalgacık tamamen genişse dalgacığın uzunluğu, işaretin uzunluğu ile daha uygun benzerlik sağlar ve böylece işaretin düşük frekans eğilimleri ortaya çıkar [35, 38,].

2) *Ayrık Dalgacık Dönüşümü:* SDD 'nin hesaplama yükü fazla ve dönüşümü sağlamak için kullandığı bilgi miktarı oldukça büyük olduğundan SDD den daha etkili bir yol olarak, Ayrık

Dalgacık Dönüşümü (ADD) kullanılmaktadır. ADD, ana dalgacığın sadece belirli genişlemelerinde işarete bakar. ADD' yi anlamak ve dalgacıkların yerini görmek için filtre bankası kavramını tanıtmak gereklidir. Çünkü filtre bankası dalgacıkların ayrı eşdeğerleridir.

3) *Dalgacık Paket Analizi*: Dalgacık Paket Analizi (DPA) ADD' ye benzer olup, işaret üzerinde mümkün olan bir çok ayrışmaları üretir ve ADD bunlardan sadece biridir. Filtre bankası her bir zaman için düşük frekans bileşenlerini tam olarak ayırştırmak yerine, yüksek frekans bileşenlerini daha iyi ayırştırmayı mümkün kılar. Böylece tüm zaman-frekans düzlemi mümkün olan tüm alt bölümlere, farklı zaman-frekans pencereleri ile bölünür [23, 35].

#### 4.6. Dalgacık Dönüşümden Entropi Hesaplanması

Entropi kavramı, bir sistemin düzenliliğini ölçmek amacı ile termodinamik fiziğinde iyi bilinen bir kavramdır. İşaret işleme, özellikle haberleşme sahasında ilk olarak Shannon kullanmıştır [39]. Entropi tabanlı kriterler verilen bir işaret gösteriminin özellikleri ile ilgili bilgileri tanımlar. Entropi ölçüm metodu durağan olmayan bir işaretin düzensizlik derecesini ölçmek için ideal bir araç olarak görünmektedir [40]. Ayrıca, entropi kavramı bir olayın içerdiği bilginin ortalama miktarını ölçmek amacı ile de kullanılmaktadır [41].

Entropi işlemi için Shannon entropisi, Norm entropi, Log energy entropisi ve Thershold entropisi gibi kriterler kullanılmaktadır. Bu entropilerin matematiksel gösterimi aşağıda sırasıyla verilmiştir.

$$E(s) = -\sum_i s_i^2 \log(s_i^2) \quad (4.3)$$

$$E(s) = \sum_i \log(s_i^2) \quad (4.4)$$

$$E(s) = \sum_i |s_i|^p \quad (4.5)$$

$$E(s_i) = 1 \quad |s_i| > p \quad (4.6)$$

Burada  $s$ , işaret,  $(s_i)$ , işareti oluşturan örnek sayısı,  $i$ , indis,  $E$ , entropi değerleri, (özellik vektörü),  $p$  isteğe bağlı bir parametredir. Denklem (4.3)' de Shannon entropide ve Denklem

(4.4)'de Log energy entropide  $p$  parametresi kullanılmaz. Norm entropide  $p$  parametresi  $1 \leq p$  ve Threshold entropide  $p$  parametresi  $0 \leq p$  olmalıdır.

#### 4.7. Genetik Algoritma

Evrimsel programlamanın (evolutionary computing) bir parçası olan Genetik Algoritmalar (GA) Darwin'in evrim teorisinden esinlenerek ortaya çıkmıştır. Evrimsel programlama, 1960'lı yıllarda I. Rechenberg'in "Evrim stratejileri" adlı çalışmasıyla gündeme gelmiştir. Genetik Algoritmaların bugünkü biçimi ilk olarak Michigan Üniversitesi'nden, psikolog ve bilgisayar bilimleri uzmanı J.H.Holland tarafından 1975 yılında ortaya konulmuştur. Genetik Algoritmalar, en iyinin korunumu ve doğal seçim ilkesinin benzetim yoluyla bilgisayarlara uygulanması ile elde edilen bir arama yöntemidir. Standart bir GA' da aday sonuçlar eşit boyutlu vektörler olarak ifade edilir. Başlangıçta, bu vektörlerden bir grup, rastlantısal olarak seçilerek belirli büyüklükte bir populasyon (toplum) oluşturulur. Kromozom adı verilen bu vektörler, yeni nesiller (jenerasyon) oluşturarak değişikliklere uğrar. Bir kromozomun üzerindeki genler,  $n$  boyutlu vektörlerin bir boyutuna karşılık gelmektedir [42, 43, 44].

Her yeni nesilde kromozomların iyiliği ölçülür, yani her vektör (kromozom), amaç fonksiyonuna yerleştirilerek vermiş olduğu sonuç hesaplanır. Bir sonraki nesil oluşturulurken, bazı kromozomlar yeniden üretilir, çaprazlanır ve mutasyona uğratılır. Bu işlemler için bazı özel tip operatörler geliştirilmiştir [44].

Tekrarlama, çaprazlama ve mutasyon gibi operatörlerden geçecek olan kromozomlar, amaç fonksiyonu değerlerine göre rastlantısal olarak seçilir. Örneğin amaç fonksiyonu değeri daha iyi olan kromozomun çaprazlanma ya da tekrar üretilme olasılığı, değeri kötü olana göre daha fazladır. Benzer kromozomlarla çeşitliliği azalan populasyonlarda yine rastlantısal olarak seçilen kromozomlar mutasyona uğratılırlar. Bunun yanı sıra, populasyon içinde iyiliği düşük olan kromozomların bir sonraki nesilde yer almamaları mümkündür, yani yok olurlar [42, 43, 44].

Standart bir "Genetik Algoritma Yordamı" aşağıdaki gibi verilebilir:

1. *Olası çözümlerin kodlandığı bir çözüm grubu oluşturulur* (çözüm grubu, biyolojideki benzerliği nedeniyle, toplum (population), çözümlerin kodları da kromozom olarak adlandırılır). Toplumda bulunacak birey sayısı için bir standart yoktur. Genel olarak



önerilen 100-300 aralığında bir büyüklüktür. Büyüklük seçiminde yapılan işlemlerin karmaşıklığı ve aramanın derinliği önemlidir. Toplum bu işlemde sonra rastgele oluşturulur. Birey sayısı belirlendikten sonra probleme bağlı olarak kromozomların kodlanması gerekmektedir. Değişik kodlama biçimleri vardır.

2. *Toplumdaki her kromozomun ne kadar iyi olduğu bulunur.* Bu amaçla kullanılan fonksiyona uygunluk fonksiyonu denir. Bu fonksiyon yardımıyla kromozomların uygunluklarının bulunmasına ise evrimleşme (evaluation) adı verilir. Uygunluk fonksiyonu genetik algoritmanın beynini oluşturmaktadır. Genetik algorithmada probleme özel çalışan tek kısım bu fonksiyondur. Uygunluk fonksiyonu, kromozomları problemin parametreleri haline getirerek onların bir bakıma şifresini çözmekte (decoding) ve sonra bu parametrelere göre hesaplamayı yaparak kromozomların uygunluğunu bulmaktadır. Çoğu zaman genetik algoritmanın başarısı bu fonksiyonun verimli ve hassas olmasına bağlıdır.
3. *Seçilen kromozomları eşleyerek yeniden kopyalama ve değiştirme operatörleri uygulanır.* Sonuçta yeni bir toplum oluşturulur. Bu eşleme kromozomların uygunluk değerlerine göre yapılır. Bu seçimi yapmak için rulet tekerleği seçimi (roulette Wheel selection), turnuva seçimi (tournament selection) gibi seçme yöntemleri vardır. Yeniden kopyalama (recombination) genlerdeki genetik bilginin birinden diğerine geçmesi işlemine benzediği için çaprazlama (crossover) olarak adlandırılır. Bu işlem, toplumda çeşitliliği sağlar. Değiştirmenin (mutation) etkisi, yalnızca bir çözüm üzerinde olmaktadır.
4. Yeni kromozomlara yer açmak için eski kromozomlar çıkartılarak sabit büyüklükte bir toplum sağlanır.
5. Tüm kromozomların uygunlukları tekrar hesaplanır ve yeni toplumun başarısı bulunur.
6. İşlemler tekrarlanarak verilmiş zaman içerisinde daha iyi olan yeni nesillerin oluşturulması gerçekleştirilir.
7. Sonuçta toplumların hesaplanması sırasında en iyi bireyler bulunduğu çözüm elde edilmiş olur.

#### **4.7.1. Genetik Algoritma Operatörleri**

Çaprazlama ve mutasyon GA'nın en önemli kısımlarıdır. Performans bu iki operatörden etkilenir. Çaprazlama genetik algoritmanın motoru kabul edilir. Basitçe olay, iki ebeveyn kromozomun arasında belirlenen parçaların takasıdır. Gen takası toplumda çeşitliliği yani, iyi özelliklerin bir araya gelmesini kolaylaştırarak en iyiye yaklaşmayı sağlar. Mutasyon

kromozomun bir parçasının dışarıdan değiştirilmesi diye tanımlanır. Değiştirme görünüşte genetik algoritmanın dayanak noktasıdır, ancak etkisi tek bir çözüm üzerindedir. Çok düşük bir değiştirme olasılığı toplumda bazı özelliklerin kaybolmasına neden olabilir. Bu da en iyi sonuçların bulunmasını engeller. Ancak yüksek bir değiştirme olasılığı da eldeki çözümleri bozarak sonuca ulaşmayı zorlaştırır. Gen takası ve değiştirmenin olasılıkları için kesin bir sayı yoktur. Değiştirme olasılığı 0.01-0.001, gen takası olasılığı 0.5-1.0 aralığında tavsiye edilir [42, 43, 44].

#### 4.7.2. Kromozomun Şifrelenmesi (Encoding)

Bir problemi GA ile çözmeye başladığımızda karşılaşacağımız problemlerden bir tanesi kromozomların kodlanmasıdır. Kromozomların kodlanması probleme göre değişmektedir. Kullanılan kodlama yöntemleri aşağıda sunulmaktadır.

**İkili Kodlama:** Bu yöntem ilk GA uygulamalarında kullanıldığı için hala en çok kullanılan yöntemlerdendir. Burada her kromozom, 0 ve 1'lerden oluşan bit dizisidir ve ikili diziyle ifade edilir. Bu dizideki her bit, çözümün bir özelliğini taşır. Dizinin tümü ise bir sayıya karşılık gelir. İkili kodlama için kromozom örneği Şekil 4.9' da verilmiştir.

Kromozom	A	101110010110
Kromozom	B	010110100000

Şekil 4.9. İkili kodlama için kromozom örneği.

İkili kodlama, az eleman sayılı problemlerde bile çok sayıda mümkün kromozom oluşturur. Bu kodlama ile bazı problemlerde çaprazlama ve mutasyon işlemlerinden sonra düzeltmeler yapılmak zorunda kalınabilir.

**Permutasyon Kodlama:** Bu kodlamada her kromozom bir numaralar dizisidir. Permutasyon kodlama için kromozom örneği Şekil 4.10' da verilmiştir.

Kromozom	A	35127604
Kromozom	B	01562347

Şekil 4.10. Permutasyon kodlama için kromozom örneği.

Burada da çok kolay olan ikili düzende kodlama kullanılabilir. Örneğin, her onluk sayı için ikili düzendeki sayılar yazılabilir.


**Değer Kodlama:** Bu kodlama, gerçel gibi kompleks sayıların yer aldığı problemlerde kullanılır. Bu tür problemler için ikili kodlama çok zor olur. Burada her kromozom bazı, değerler dizisidir. Bu değerler ise problemle ilişkilidir. Örneğin gerçel sayı, karakter veya bazı kompleks nesnelere bile olabilir. Değer kodlama için kromozom örneği Şekil 4.11’ de verilmiştir.

Kromozom	A	3.274	6.121	2.456	0.299	2.115
Kromozom	B	ABCJFKHDERJFDLFFEGHK				
Kromozom	C	(geri),	(sağ),	(ileri),	(geri),	(sol)

**Şekil 4.11.** Değer kodlama için kromozom örneği.

Bu kodlama bazı özel problemler (örneğin bir yapay sinir ağının ağırlık katsayılarının bulunması) için çok kullanışlıdır.

**Ağaç Kodlama:** Ağaç kodlama genellikle genetik programlamada programlar ve ifadeler oluşturmak için kullanılır. Ağaç kodlamada her kromozom, adından da anlaşıldığı gibi nesnelere ve nesnelere arası işlemleri içeren bir ağaç yapısından oluşmaktadır.



**Şekil 4.12.** Ağaç kodlama için kromozom örneği.

Ağaç kodlama için kromozom örneği Şekil 4.12’ de verilmiştir.

**Çaprazlama ve Mutasyon:** Hangi şifrelemenin kullanılacağına karar verdikten sonra, çaprazlama veya gen takası adımına geçilir. Çaprazlama, genleri ebeveyn kromozomlardan seçer ve yeni bir döl oluşturur. Bu işlem rastgele çaprazlama noktası (veya noktaları) seçer ve bu noktadan (veya noktalardan) itibaren kromatitlerin (alt dizilerin) yerdeğişmesiyle yeni kopyaların oluşturulmasını sağlar. Kodlama türlerine bağlı olarak çaprazlama ve mutasyon işleminin farklı şekilleri bulunmaktadır.

İkili kodlanmış kromozomlarda dört çeşit çaprazlama gerçekleştirilebilmektedir.

- a. **Tek noktalı çaprazlama:** Bir çaprazlama noktası seçilir. Bu noktaya kadar olan bitler (genler) birinci ebeveynden, geriye kalanlar ise diğerinden alınarak yeni bir kromozom oluşturulur.

Kromozom-1:      **1 1 0 1 1** | 0 0 1 0 0 1 1 0 1 1 0

Kromozom-2:      1 1 0 1 1 | **1 1 0 0 0 0 1 1 1 1 0**

Döl-1:            **1 1 0 1 1** | **1 1 0 0 0 0 1 1 1 1 0**

Döl-2:            1 1 0 1 1 | 0 0 1 0 0 1 1 0 1 1 0

- b. **Çift noktalı çaprazlama:** Burada iki kırılma noktası seçilir. İlk noktaya kadar olan bitler birinci ebeveynden iki nokta arasındaki bitler ikinci ebeveynden, kalanlar ise tekrar birinci ebeveynden yeni kromozoma kopyalanır.

$$1 1 0 0 1 0 1 1 + 1 1 0 1 1 1 1 1 = 1 1 0 1 1 1 1 1$$

- c. **Tek biçimli (uniform) çaprazlama:** Bu çaprazlama biçiminde bitler rastgele şekilde her iki ebeveyden yeni kromozoma kopyalanmaktadır.

$$1 1 0 0 1 0 1 1 + 1 1 0 1 1 1 0 1 = 1 1 0 1 1 1 1 1$$

- d. **Aritmetik çaprazlama:** Yeni bir kromozom oluşturmak için değişik aritmetik işlemler uygulanır.

$$1 1 0 0 1 0 1 1 + 1 1 0 1 1 1 0 1 = 1 1 0 0 1 0 0 1 \text{ (AND) VE işlemi}$$

**Mutasyon:** Mutasyon işlemi, problemin popülasyondaki çözümlerinin yerel optimuma düşmesini engellemek için kullanılır. Mutasyon yeni dölü rastgele değiştirir. İkili şifreleme için, rastgele seçilen birkaç bit 0'dan 1'e veya 1'den 0'a değiştirilebilir, yani seçilen bitler terslenir.

Orjinal döl: 1 1 0 1 1 1 1 0 0 0 0 1 1 1 1 0  
Mutasyona uğramış döl: 1 1 0 0 1 1 1 0 0 0 0 1 1 1 1 0

Mutasyon da çaprazlama gibi şifrelemeye bağlıdır.

#### 4.7.3. Genetik Algoritma Parametreleri

Genetik algoritmaların iki temel parametresi vardır: çaprazlama olasılığı ve mutasyon olasılığı. Bu parametreler aşağıda kısaca açıklanmaktadır.

*Çaprazlama olasılığı* çaprazlamanın hangi sıklıkta yapılacağını belirtir. Eğer hiç çaprazlama yapılmaz ise (çaprazlama olasılığı %0) yeni bireyler eski bireylerin aynısı olur ama bu yeni kuşağın eskisiyle aynı olacağı anlamına gelmez. Eğer bu oran %100 olursa yeni bireyler tamamıyla çaprazlama ile elde edilir. Çaprazlama eski bireylerden iyi taraflar alınarak elde edilen yeni bireylerin daha iyi olması umuduyla yapılır [42].

*Mutasyon olasılığı* ise mutasyonun hangi sıklıkta yapılacağını belirtir. Mutasyon olmaz ise yeni birey çaprazlama veya kopyalama sonrasında olduğu gibi kalır. Eğer mutasyon olur ise yeni bireyin bir kısmı değiştirilmiş olur. Eğer bu oran %100 olursa kuşak içindeki bireyler tamamen değişir, %0 olursa hiç değişmeden kalır [42].

GA çaprazlama olasılığı ve mutasyon olasılığı dışında başka parametreler de içerir. Bunların en önemlilerinden birisi de popülasyon büyüklüğüdür.

Bu parametre popülasyon içinde (yalnızca bir kuşakta) kaç adet kromozom yani birey olduğunu söyler. Eğer kromozom sayısı az olursa GA çözüm aranan uzayın ancak bir kısmını gezebilir ve çaprazlama için fazla bir seçeneği yoktur. Kromozom sayısı çok fazla olursa GA çok yavaş çalışır. Araştırmalar belli bir noktadan sonra popülasyon sayısını artırmanın bir yararı olmadığını göstermiştir [42].

#### 4.7.4. Genetik Algoritmaların Uygulama Alanları

Karmaşık problemleri hızlı ve optimale yakın olarak çözebilen genetik algoritmalar, çeşitli problem tiplerine uygulanabilmektedir.

Büyük çözüm uzaylarının geleneksel yöntemlerle taranması hesaplama zamanını arttırmaktadır. Ancak bu tip problemlere, genetik algoritmalar ile kısa sürede, kabul edilebilir çözümler bulunabilmektedir. Genetik algoritmalar özellikle çözüm uzayının geniş, süreksiz ve

karmaşık olduğu problem tiplerinde başarılı sonuçlar vermektedir. Genetik algoritmaların uygulama alanları şunlardır [45]:

## **1. Optimizasyon**

Bir arama yöntemi olan genetik algoritmalar, farklı bilim dallarındaki optimizasyon problemlerini çözmeye kullanılmaktadır. Genetik algoritmaların uygulandığı optimizasyon problemleri, fonksiyon optimizasyonu ve birleşimi (combinatorial) optimizasyonu altında toplanabilir.

Genetik algoritma araştırmalarının önemli bir bölümü fonksiyon optimizasyonu ile ilgilidir. Genetik algoritmalar, geleneksel optimizasyon tekniklerine göre zor, süresiz ve gürültü (noisy) içeren fonksiyonları çözmeye daha etkindirler. Optimize edilecek amaç fonksiyonunun süresiz olması halinde, süresizlik noktalarında fonksiyonun türevi alınmayacağından, türev almaya dayalı optimizasyon yöntemleri kullanılamamaktadır. Oysa, genetik algoritmalar, problemlerin çözümü için türev veya diğer yardımcı bilgilere gereksinim duymadığından özellikle bu tip problemlerin çözümünde geleneksel yöntemlere göre önemli bir üstünlük sağlamaktadır [45].

Genetik algoritmaların uygulandığı diğer bir optimizasyon problem sınıfı olan birleşimi optimizasyon problemleri ise, istenen amaçlara ulaşmak üzere, sınırlı kaynakların etkin tahsis edilmesiyle ilgilidir. Bu sınırlar genel olarak, işgücü, tedarik veya bütçe ile ilgilidir. Sözü geçen “birleşimi” kelimesi, yalnızca sonlu sayıda alternatif uygun çözümün mevcut olması ile ilgilidir. Birleşimi optimizasyon, iyi tanımlanmış bir problem uzayında bir veya daha fazla optimal çözüm bulma sürecidir. Bu tip problemler yönetim biliminin tüm dallarında da (finans, pazarlama, üretim, stok kontrolü, veri-tabanı yönetimi vb.) ortaya çıkmaktadır.

Gezgin satıcı problemi, araç rotalama problemi, Çinli postacı problemi, iş atölyesi çizelgeleme problemi, atama problemi, yerleşim tasarımı problemi ve sırt çantası problemi birleşimi optimizasyon problemlerine örnektir. Birleşimi optimizasyon problemlerinde, incelenen değişken sayısı arttıkça çözüme ulaşma zamanı üstsel olarak artmaktadır. Çözüm uzayının tamamının taranmasını gerektiren geleneksel çözüm yöntemlerinde problem çözümü değişken sayısının artmasıyla imkansız hale gelebilmektedir [45].

Genetik algoritmalar ise çözüm uzayının yalnızca belirli bir kısmını taradığı ve eş zamanlı arama yaptığı için, bu tip problemlerde çözüme daha kısa sürede ulaşabilmektedir.

## **2. Otomatik Programlama ve Bilgi Sistemleri**

Genetik algoritmaların yaygın olarak kullanıldığı alanlardan biri, belirli ve özel görevler için gerekli olan bilgisayar programlarını geliştirmedir. Ayrıca, diğer hesaplama gerektiren

yapıların tasarımı için de kullanılmaktadır. Bunlara örnek olarak, bilgisayar çipleri tasarımı, ders programı hazırlanması ve ağların çizelgelenmesi verilebilir.

Genetik algoritmalar kullanılarak dağıtılmış bilgisayar ağlarının tasarımı da gerçekleştirilmektedir. Bu problem tipinde ağ güvenilirlik parametrelerini (çap, ortalama uzaklık ve bilgisayar ağ güvenilirliği gibi) optimize etmek için birden fazla amaç fonksiyonu kullanılmaktadır. Genetik algoritmalar ile 100 düğüme kadar olan ağlar başarıyla tasarlanmıştır.

Ağ tasarımında genetik algoritmaların kullanılması, tasarım sürelerinin ve maliyetlerinin azalmasında önemli bir katkı sağlamıştır. Özellikle, maksimum miktardaki verinin minimum iletişim hattıyla taşınmasında yüksek bir performans göstermiştir.

### **3. Mekanik Öğrenme**

Mekanik öğrenme; ilki, gözlenmiş bir veri takımını anlamak ve yorumlamak, ikincisi de görülmemiş objelerin özelliklerini tahmin etmek olan iki temel amaç için model kurmayı amaçlar. Parametrik istatistikten ziyade çok büyük veri takımlarının yönetimi üzerinde çalışır. Kullandığı metotların çoğu dağılımdan bağımsız metotlar olarak sınıflanabilir. Uygun model seçimi için işe problem hakkındaki varsayımlarla başlar. Onun yerine uygun model yapısını belirlemek için doğrudan mevcut veriden hareketle bir araç kutusu yaklaşımı kullanır [54].

Sınıflama sistemi, genetik algoritmaların mekanik öğrenme alanında bir uygulamasıdır. Basit dizi kurallarını öğrenen bir mekanik öğrenme sistemi olan sınıflama sisteminin kural ve mesaj sistemi, özel bir üretim sistemi olarak adlandırılabilir. Bu üretim sistemi, “eğer-sonra” kural yapısını kullanır. Bir üretim kuralı, “eğer” yapısından sonra belirtilen durum için, “sonra” yapısından sonra gelen faaliyetin gerçekleştirilmesini içerir. Genetik algoritmalar, sınıflama sistemlerinde kural-bulma mekanizması olarak kullanılmaktadırlar [45].

### **4. Ekonomik ve Sosyal Sistem Modelleri**

Bir sistemi ölçen ampirik olarak gözlenmiş değişkenler arasındaki matematiksel ilişkiyi keşfetme problemi ekonomide en önemli problemlerden biridir. Pratikte gözlenmiş veri gürültü içerebilir ve kapsanan ilişkileri kesin ve açık bir şekilde açıklayacak bir yol bilinmeyebilir. Bu tip problemler, sembolik sistem tanımlama, kara kutu, veri madenciliği ve modelleme problemleri olarak bilinir. Eğer keşfedilen model, sistemin durum değişkenlerinin gelecek değerlerini tahmin etme için kullanılacaksa problem öngörüleme problemi adını alır. Geleneksel doğrusal, kuadratik ve üstsel regresyon modellerinde sapma hataları minimize edilerek fonksiyonlara uygun sayısal katsayılar bulunur. Buradaki yaklaşım, model seçildikten sonra uygun sayısal katsayıların aranmasıdır. Gerçek problem ise verinin değerlendirilmesi için hangi tip modelin uygun olduğunun kararıdır. Keyfi bir matematiksel ilişkiyi açıklamada bilgisayarlar,

bu ilişkiyi formüller ve denklemler aracılığı ile açıklamaktan daha esnektir. Bu nedenle, bu tip ilişki açıklamaları için sembolik regresyon kullanılabilir. Sembolik regresyonlar, hem fonksiyon formunu hem de o fonksiyondaki uygun katsayıyı araştırmaktadır. Bunu bulma işlemi ise, verilen girdiler için arzu edilen çıktıları üreten özel bir hesaplama programı ile program uzayında arama yapmaya benzerdir. Genetik algoritmaların kullanıldığı genetik programlamayla bu tip problemlere tatmin edici çözümler çok daha kolay getirilebilmektedir [42].

Genetik algoritmalar yenilik sürecinin modellenmesi amacıyla da kullanılmaktadır. Ayrıca genetik algoritmaların, fiyat verme stratejilerinin gelişim süreçlerini ve kazanç getiren pazarların ortaya çıkış süreçlerini modelleme alanlarında da kullanımları oldukça yaygındır.

Genetik algoritmalar sosyal sistemlerin evrimsel yönlerini anlamak amacıyla kullanılmaktadır. Bunlara örnek olarak işbirliğinin evrimi, iletişimin evrimi ve karıncalardaki iz takibi davranışının evrimi verilmektedir.

## **5. Finans**

Genetik algoritmalar, finansal modelleme uygulamaları için son derece uygundur. Genetik algoritmalar amaç fonksiyonu odaklıdır. Finans problemlerinde genel olarak, amaç fonksiyonları tahmin etme gücüne veya bir kıyaslama sonucuna bağlı getirilerdeki gelişmeleri içerir. Kullanılan araç ve problemler arasında mükemmel bir eşleşme mevcuttur. Özellikle hisse senedi fiyatlarındaki değişim kalıplarını tahmin etmede ve bulmada, kaynak tahsisi ve uluslararası sermaye tahsisi stratejilerini belirlemede genetik algoritmalar kullanılabilir. Bu yaklaşımla, kısıtlanmış portföy optimizasyonu, endeks izleme, işlem maliyetleri ve risk tercihleri kısıtlarının da katıldığı çok dönemli portföy yönetim sistemlerinin kurulması, yine minimum işlem lotlu portföy seçimi problemlerinin çözümü yapılabilmektedir. Daha yüksek getiriler elde etmek için FX piyasalarındaki ticari kuralları geliştirmede (al-tut stratejilerinden daha karlı olanları bularak) genetik algoritmalar kullanılabilir. Ayrıca, müşterilerinin kredi değerliliğini ölçmede, yatırım araçlarının performansını belirlemede, işletmedeki mali kayıpların araştırılmasında, finansal opsiyonların geliştirilmesinde kullanılan veri madenciliğine uygulanabilmektedir. Müşteri kredi değerliliğini ölçme, kredi kartı puanlama, piyasalar ile ilgili tahminleri ve şirketlerdeki iflas tahminlerini yapma genetik algoritmaların en sık uygulandığı finans problemlerindedir [45].

Finans problemlerinin çözümünde genetik algoritmalar, bulanık ve yapay sinir ağları yaklaşımlarıyla birlikte kullanılmaktadır. Yumuşak hesaplama ve hibrid genetik algoritma yaklaşımı sık görülmektedir. Ayrıca, çözüm performansı açısından finans problemlerindeki



genetik algoritma çözümleri yasaklı arama, tavlama benzetimi arama metotları ile karşılaştırılmakta ve o probleme uygun çözüm yöntemi önerilmektedir.

## **6. Pazarlama**

Tüketicilere ait verileri analiz etmek, çeşitli tüketici kalıpları çıkarmak ve bu kalıplara dayanarak pazarlama stratejileri uygulamak, pazarlamanın en önemli fonksiyonlarından biridir.


Tüketicilerin profilleri çıkarılarak, belirli satın alma kalıpları yakalanabilmektedir. Ancak tüketici profilini çıkarabilmek için, çok büyük veri tabanlarını işletme amaçları doğrultusunda hızlı ve etkin biçimde kullanmak gerekmektedir. Burada kullanılan teknik veri madenciliğidir. Veri madenciliği, çok geniş veri tabanlarından veriyi süzme tekniğidir. Pazarı ve tüketiciyi tanımada son derece önemli rol oynayan veri madenciliği, veriyi bilgiye bilgiyi de güvenli kararlara dönüştürür. Veri madenciliğinin verimlilik, karlılık, müşteri tatmini ve rekabet edebilme yeteneği gibi yaşamsal konularda işletme üzerinde çok önemli etkileri bulunmaktadır. Rekabet edebilme yeteneği karar alma kalitesine bağlıdır ve bundan dolayı işletmeler sürekli karar kalitelerini geliştirmeye çalışırlar. Veri madenciliğinde kullanılan tekniklerden birisi de GA'dır. GA tabanlı yaklaşım kullanılarak veri yığınlarından modeller elde edilmektedir.

## 5. YAPAY SİNİR AĞI İLE SINIFLANDIRMA

Sınıflandırma aşamasının amacı, örüntüleri özellik uzaylarına göre kendilerine en yakın sınıflara minimum hata ile eşlemektir. Sınıflandırıcının başarımında iyi belirlenmiş özellikler kilit rolü oynarlar [10, 21].

Örüntü sınıflandırıcılarını geleneksel ve akıllı olarak gruplara ayırmak mümkündür. Geleneksel sınıflandırma algoritmaları istatistiksel bir yapı olan Bayes karar teorisi üzerine kuruludur. Bunların dezavantajları, özellik uzayını sınıflandırma uzayını dönüştürürken, bir gürültünün çıkması ve her bir sınıf için hata kriterinin belli olmamasıdır [16, 17]. Geleneksel sınıflandırıcılara; çok değişkenli Gauss modelleri, en yakın komşu, maksimum olabilirlik, ikili ağaç sınıflandırıcıları ve Fisher'in doğrusal sınıflandırıcıları örnek olarak verilebilir [17]. Buna karşın akıllı sınıflandırma yapıları genellikle Yapay sinir ağ tabanlı olup, günümüzde en yaygın kullanılan ve başarımını ispatlamış çok güçlü sınıflandırıcı türleridirler. Özellikle de genelleme yetenekleri, örüntü tanıma uygulamalarının çok büyük boyutlu verileri açısından önemlidir. Hoekstra, (1998) çalışması ile geleneksel ve YSA sınıflandırıcılarını kıyaslamış ve YSA sınıflandırıcılarının üstünlüklerinin geleneksel yöntemlere göre tartışılmaz olduğunu göstermiştir.

Şekil 5.1' de akıllı sınıflandırma yapısı gösterilmektedir. Eğitim verisi sınıflandırıcının hafızası içinde şifrelenir.



**Şekil 5.1.** Akıllı sınıflama yapısı.

Parametrik sınıflandırıcılar;

1. Bayes
2. Maksimum olabilirlik
3. En yakın komşu (k- NN)
4. Parzen pencereleri

Akıllı Sınıflandırıcılar;

1. Yapay sinir ağları
2. Bulanık mantık
3. Nöral – Bulanık (ANFIS) sınıflandırıcılarıdır.

## 5.1. Yapay Sinir Ağları

İnsan davranışlarını taklit etmek amacıyla geliştirilen yapay zekâ uygulamalarının, bir alt dalı olan yapay sinir ağları, ortaya çıkışından günümüze kadar birçok aşamalardan geçmiştir ve son yıllardaki teknolojik gelişime paralel olarak gelişimini çok hızlı bir şekilde devam ettirmiştir [46, 47, 48].

Yapay sinir ağları (YSA), anatomi, psikoloji ve nörobiyoloji alanlarındaki araştırmalarla paralel gelişmektedir. 1943 yılında McCulloch ve Pitts'in yayınladıkları makale yapay sinir ağları konusundaki ilk makale sayılmaktadır. Bu makalede; sinirlerin giriş faaliyet seviyesi, belirli bir eşik değerine eriştiğinde aktif hale geçen açık/kapalı anahtar gibi davrandıkları ve mantık fonksiyonlarını hesaplamak için çeşitli şekillerde bir araya getirilebilecekleri gösterilmiştir. 1949'da, nöropsikolog Hebb yayınladığı makalede beynin öğrenme yeteneğini bir modelle açıklamıştır. 1954'te, M. Minsky yapay sinir ağları konusunda doktora yapmış ve 1960'lı yıllarda yapay sinir ağlarına ilgi büyük ölçüde artmıştır. Bu yıllarda F.Rosenblat, McCulloch ve Pitts'in eşik değeri yaklaşımını kullanarak tecrübeye dayanan, öğrenebilen eleman ağlarını geliştirmişlerdir. Aynı yıllarda S. Grossberg, verbal öğrenmede deney sonuçlarıyla ifade edilen ağların diferansiyel denklemlerini kurmuş; daha sonra gerçek biyolojik sinir ağlarını ifade eden genel denklem setini çıkarmış ve yaptığı araştırmaların sonunda "Adaptif Rezonans Teorisi"ni geliştirmiştir. 1969 yılında M. Minsky ve S. Papert yapay sinir ağlarındaki sınırlamaları inceledikleri "perceptrons" adlı kitabı yayınlamışlardır. Bu kitapta tek katmanlı ağların özel veya işlemini gerçeklemek gibi basit sorunları çözemeyecekleri ispatlanmıştır [47, 48].

Tüm bu gelişmelere rağmen yapay sinir ağlarının sadece bağlantılar arasındaki ağırlık matrislerinin değiştirilebilmesi ve yapının sabit kalması yapay sinir ağlarının yeteneklerini önemli ölçüde sınırlamaktadır. Yapay sinir ağlarının dinamik ve öğrenme özelliklerinin matematiksel tanımı ve modellenmesi konusundaki ilerlemeler bu konudaki ümit verici gelişmeler olarak gösterilebilir [47, 48].

## 5.2. Sinir Ağlarının Biyolojik Yapısı


Canlıları dış ortamdaki değişikliklere karşı kendi iç ortamını belirli sınırlar içerisinde koruyan sinir sistemi, sinir hücrelerinden meydana gelmiş bir yapıdır. Canlı bir sinir sisteminin temelini oluşturan bir sinir hücresi Şekil 5.2' de görülmektedir.

Bir sinir hücresi, bir hücre gövdesi ile dentrit ve akson adı verilen uzantılardan meydana gelir. Sinir hücresi, dentrit adı verilen bir kısım uzantılarla diğer sinir hücrelerinden aldığı

işaretleri hücre gövdesine taşır ve hücre gövdesinde toplanan bu işaretler değerlendirilerek bir çıkış işareti üretilir ve bu işaretler akson adı verilen uzantılar vasıtasıyla diğer sinir hücresine gönderilir. Bir sinir hücresinde birçok dentrit olmasına karşın tek bir akson vardır. Yani bir sinir hücresinde birçok giriş bulunmasına rağmen tek bir çıkış vardır.

Sinir hücrelerinin en büyük özelliği, çevreden gelen işaretlere ya cevap vermesi ya da vermemesidir. Eğer sinir hücresine gelen işaret, eşik değerini aşarsa hücre tarafından kabul edilir ve cevaplandırılır, eşik değerini aşamıyorsa yok kabul edilerek hiçbir cevap üretilmez. İki sinir hücresi arasında birinin dentriti ile diğerinin aksonu arasında bir bağlantı vardır ve bu bağlantı yerine *sinaps* adı verilir. Bu bağlantı yerinde sinirler birbirine bağlı değildir. İki hücre arasında küçük bir bağlantı bulunmamasına rağmen iki sinir hücresi darbeleri iletmek için birbirine yeterince yakındır.

Birinci sinir hücresinin aksonu, sinir hücresinden aldığı işaret sonucunda şişer ve bu şişlik ikinci sinir hücresinin dentritinde bulunan algılayıcılar tarafından kaydedilerek hücre zarının  $Na^+$  ve  $K^+$  iyonları geçirebilme yeteneğini değiştirme yönünde etkileyen kimyasal reaksiyon başlar. Böylece hücre zarı iyonların zarı geçmesine izin verir ve zar potansiyelini geçici olarak değiştirir [48, 49, 50].



Şekil 5.2. Biyolojik sinir hücresi.

Biyolojik beynin en önemli özelliklerinden birisi de, öğrenme olayıdır. İnsanlar ve hayvanlar, sürekli olarak içerisinde buldukları çevre ile ilişki neticesinde bir öğrenme işlemi içerisindeyler. Öğrenilen her yeni bilgi, beynin fonksiyonlarını hemen etkileyerek, yapılan davranışlara yansır. Yapay sinir ağlarının gerçekleştirilmesinde bu özellik esas teşkil eder [47].


### 5.3. Yapay Sinir Ağının Tanımı ve Modeli

Yapay sinir ağları, insan beyninin çalışma prensibini taklit etme esası üzerine kurulmuş bilgi işleme yöntemleridir. Bu ağlar birbirine paralel olarak bağlanmış işlem elemanlarından (yapay sinir ağı hücresi, nöron, ünite, birim, düğüm) ve onların hiyerarşik bir organizasyonundan oluşurlar. Yapay sinir ağlarının paralel yapıları, bilgisayarları geleneksel

yöntemlerden çok daha farklı kullanarak özellikle seri bilgisayarlarda bilinen yöntemlerle yapılması mümkün olmayan ve çok zor olan bir takım işlevleri (ses ve örüntü tanıma gibi) rahatlıkla yapmaları, bu ağları üstün kılmıştır. Yapay sinir ağının temel düşüncesiyle insan beyninin fonksiyonları arasında benzerlikler vardır. Yapay sinir ağları, her ne kadar temel yapı itibariyle bir kısım özellikleri insan beyninin fiziki özelliklerinden esinlenerek ortaya atılmış ise de, kesinlikle şu andaki halleri ile insan beyninin ne tam ne de yaklaşık bir modeli olarak değerlendirilemezler [48, 49].

Günümüzde her ne kadar karmaşık matematiksel hesaplamaları ve hafıza işlemlerini eldeki mevcut bilgisayarlarla hızlı ve doğru yapmak mümkün ise de, aynı bilgisayarlarla beynin birçok basit fonksiyonunu (görmek, duymak koklamak, ...vs.) yerine getirmek oldukça zor olmaktadır. Ayrıca biyolojik beyin, tecrübe ile öğrenme ve bilgiyi kendi kendine yorumlama, hatta eksik bilgilerden sonuçlar çıkartma kabiliyetine sahiptir. Bu, daha çok biyolojik sistemlerin, hücreler üzerinde dağıtılmış bilgiyi paralel olarak işleme özelliklerinden kaynaklanır. Hücreler birbirine bağlı ve paralel çalıştıklarından bazılarının işlevini yitirmesi halinde, diğerleri çalıştığı için sinir sistemi, fonksiyonunu tamamen yitirmez. İşte yapay sinir ağları, bu özellikleri bünyesinde toplayacak şekilde geliştirilmektedir [47].

Yapay sinir ağları, biyolojik sinir ağları gibi yapay sinir hücrelerinin veya işlem elemanlarının bir araya gelmesinden oluşur. Her bir işlem elemanı Şekil 5.3' te görüldüğü gibi beş parçadan oluşur. Bunlar; girişler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıkıştır.



**Şekil 5.3.** Bir yapay sinir ağı hücresi

- $X_i$  : Giriş
- $W_i$  : Ağırlıklar
- $\Sigma$  : Toplama Fonksiyonu
- $f$  : Aktivasyon Fonksiyonu
- $V$  : Çıkış

İşlem elemanına birden fazla giriş gelmekte ve sadece bir çıkış üretilmektedir. Girişler, dentritlere benzer şekilde diğer yapay hücrelerden bağlantılar vasıtasıyla işlem elemanına bilgi gelmesini sağlarlar. Bazı durumlarda bir işlem elemanı kendisine de bilgi geri gönderebilir (feedback). Bahsedilen bu bilgiler elemanlar arasında bulunan bağlantı hatları üzerinde depolanır ve her bağlantının bir ağırlığı vardır. Bu ağırlık, bir işlem elemanının diğeri üzerindeki etkisini gösterir ve ağırlık büyüdükçe etki de büyür. Ağırlığın sıfır olması hiç bir etkinin olmaması, negatif olması ise etkinin ters yönde olması demektir. Bu ağırlıklar sabit olabildikleri gibi değişken de olabilirler. Toplama fonksiyonu, bir işlem elemanına gelen net girişi hesaplayan bir fonksiyondur. Net giriş genellikle gelen bilgilerin ilgili bağlantıların ağırlıkları ile çarpılıp toplanması ile belirlenir ve bu nedenle toplama fonksiyonu olarak isimlendirilir. Aktivasyon fonksiyonu, toplama fonksiyonu tarafından belirlenen net girişi alarak, işlem elemanının çıkışını belirleyen fonksiyondur ve genel olarak türevi alınabilen bir fonksiyon olması tercih edilir. Toplama ve çıkış fonksiyonları, ilgili probleme bağlı olarak farklı şekiller alabilirler. İşlem elemanının çıkış ünitesi ise çıkış fonksiyonunun ürettiği dürtüyü diğer işlem elemanlarına veya dış dünyaya aktarma işlevini yapar. İşlem elemanları ağırlık yapılarına bağlı olarak tamamen birbirinden bağımsız ve paralel olarak çalışabilirler. Şekil 5.3'te verilmiş olan yapay sinir hücresine  $x_1, x_2, x_3 \dots x_m$  giriş işaretleri uygulanmaktadır. Her giriş işareti  $w_1, w_2, w_3 \dots w_m$  ilgili ağırlık değerleriyle çarpılırken basit hücre modelinde, v çıkış ifadesi Denklem 5.1 deki gibi olur.

$$u = \sum_{i=0}^m x_i w_i - b \quad (5.1)$$

$$v=f(u) \quad (5.2)$$

Burada, girişler  $x$ , ağırlıklar  $w$  vektörü ile gösterilir.  $b$ , ise eşik değer olarak adlandırılır. Giriş işaretleri biyolojik hücrelerin sinapsislerindeki işaretlere karşı düşen giriş hattındaki elektriksel etkinliği, ağırlık vektörüyle biyolojik sinirlerdeki sinaptik gücü ifade etmektedir.  $f(.)$  fonksiyonu, bir lineer veya lineer olmayan fonksiyondur. Şekil 5.4' te,  $f(.)$  fonksiyonu için kabul görmüş gerçek biyolojik sinirlerin transfer fonksiyonuna yakın fonksiyonlar görülmektedir. Burada, v çıkış etkinliği VAR/YOK olarak iki durum arasında sınırlandırılmış olmaktadır. Bu iki durum arasındaki durum değiştirmenin ayrıntıları  $f(.)$  fonksiyonunun ayrıntılarıyla belirlenir. Yani v hücre çıkış etkinliği, hücreye girişlerden gelen toplam etkinliğe, bir  $f(.)$  aktivasyon fonksiyonu üzerinden bağlıdır. Şekil 5.4-b' de verilen lineer aktivasyon fonksiyonu için,

$$f(.)=u \quad (5.3)$$

Şekil 5.4-a' da verilen aktivasyon fonksiyonu için,


$$f(.)=\tanh(u) \quad (5.4)$$

Bunlardan başka tanımlanabilecek farklı bir aktivasyon fonksiyonu ise,

$$f(u)=v \quad (5.5)$$

ile ifade edilebilir.

Aktivasyon fonksiyonları, işlem elemanlarının sınırsız sayıdaki girişini önceden belirlenmiş sınırdaki çıkış olarak düzenlerler. En çok kullanılan dört tane aktivasyon fonksiyonu vardır. Bunlar, sigmoid, doğrusal, doyumlu doğrusal, eşik fonksiyonları olup, Şekil 5.4'de görülmektedir.



**Şekil 5.4.** Aktivasyon fonksiyonları. a) Sigmoid fonksiyonu, b) Doğrusal aktivasyon fonksiyonu, c) Doymumlu doğrusal aktivasyon fonksiyonu, d) Eşik (Basamak) aktivasyon fonksiyonu.

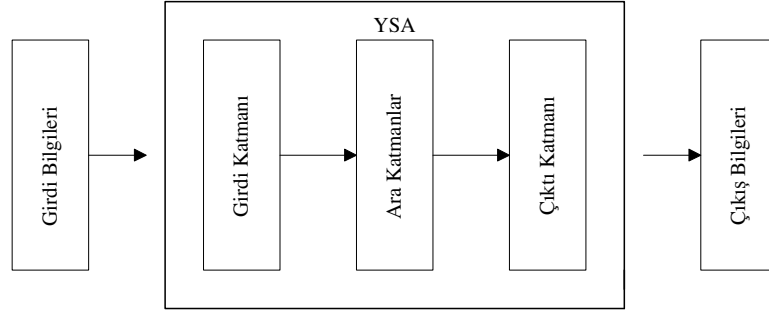
#### 5.4. Yapay Sinir Ağlarının Yapısı

Yapay sinir ağlarının görevlerini gerçekleştirmede, sahip oldukları fiziksel yapının da önemi vardır. Bugün 50'ye yakın farklı yapılanma görülmekte ve bu sayı her geçen gün artmaktadır [46, 52, 29]. Farklı yapılaşma, işlem elemanlarının birbirleri ile olan bağlantılarından ve uygulanan öğrenme kuralından kaynaklanmaktadır. İşlem elemanları ya tamamen birbirleri ile bağlantılı veya yerel olarak guruplar halinde bağlantılı olabildikleri gibi değişik şekilde de birbirleri ile bağlanabilmektedirler. Bilgi akışı bu bağlantılar üzerinden tek yönlü olduğu gibi, çift yönlü de olabilir. Bir gurup işlem elemanı bir araya gelerek bir katman oluştururlar. Genel olarak yapay sinir ağlarında 3 katman bulunur. Bu katmanlar;

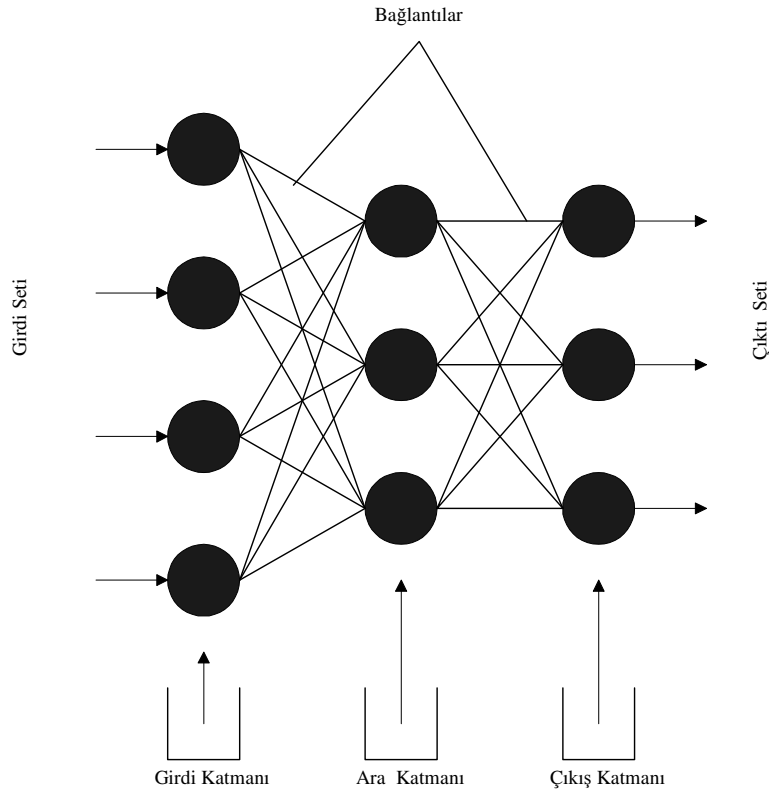
*Girdi katmanı:* Bu katmandaki proses elemanları dış dünyadan bilgileri alarak ara katmanlara transfer etmekle sorumludurlar. Bazı ağlarda girdi katmanında herhangi bir bilgi işleme olmaz.

*Ara katmanlar:* Girdi katmanından gelen bilgiler işlenerek çıktı katmanına gönderirler. Bu bilgilerin işlenmesi ara katmanlarda gerçekleştirilir. Bir ağ için birden fazla ara katmanı olabilir.

*Çıktı katmanı:* Bu katmandaki proses elemanları ara katmandan gelen bilgileri işleyerek ağı girdi katmanından sunulan girdi seti (örnek için üretmesi gereken çıktıyı) üretirler. Üretilen çıktı dış dünyaya gönderilir. Şekil 5.5 bu üç katmanın bir biri ile olan ilişkisini göstermektedir [53].



**Şekil 5.5.** Yapay Sinir Ağı katmanlarının birbiri ile ilişkisi.



**Şekil 5.6.** Bir yapay sinir örneği.

Bu üç katmanın her birinde bulunan proses elemanları ve katmanlar arası ilişkileri şematik olarak Şekil 5.6' da gösterilmektedir. Şekildeki yuvarlak şekiller proses elemanlarını



göstermektedir. Her katmanda birbirine paralel elemanlar söz konusudur. Proses elemanlarını birbirine bağlayan çizgiler ise ağıın bağlantılarını göstermektedir. Proses elemanları ve bağlantıları ve bir yapay sinir ağıını oluştururlar. Bu bağlantıların ağırlık değerleri öğrenme sırasında belirlenmektedir [53].

### 5.5. Yapay Sinir Ağlarında Öğrenme ve Öğrenme Algoritmaları

Daha öncede belirtildiği gibi bir yapay sinir ağıının sahip olduğu bilgi, işlem elemanları arasındaki bağlantı hatları üzerinde saklanır ve ağırlıklar vasıtası ile gösterilir. Ağ, olaylar hakkında giriş ve çıkışlar arasındaki ilişkiyi, elde bulunan mevcut örneklerden genellemeler yaparak öğrenir ve bu genelleme ile yeni oluşan ve ortaya çıkan daha önce hiç görülmemiş olaylar hakkında karar verir. Yani ağa, bir örnek olay gösterildiğinde, giriş katmanından alınıp ara katmanlarda işlenerek, ağıın o olay hakkında ürettiği sonuç, çıkış katmanına sunulur. Bu bilgiyi işleme, ağıın sahip olduğu tecrübeye göre, bilginin ara katmanlarda çağrıştırılması ile gerçekleştirilir. Bu çağrıştırma olayı modelden modele değişmektedir. Mesela, ara katmanlardaki işlem elemanları sahip oldukları bağlantılar ile kendi kararlarını üretir ve çıkış katmanındaki işlem elemanlarına gönderirler. Çıkış katmanındaki işlem elemanları da, yine ilgili ağırlıkları kullanarak ağıın en son kararını oluştururlar. Bu ağırlıklar, tıpkı ilgili olayın belirli özelliklerini hafızada saklayan elemanlar gibi düşünülebilirler. Bilgi işleme ise (örüntü tanıma gibi), bir olay gösterildiğinde hafızadan ilgili özellikleri çağırarak ve bunlar ile ilgili girişleri birlikte analiz ederek karar vermek şeklinde yorumlanabilir.

Yapay sinir ağıının öğrenme işlemini gerçekleştirebilmesi için, sahip olduğu bütün ağırlıkların, ilgili problemde öğrenilmesi istenen özellikleri genelleştirecek şekilde doğru değerlere sahip olması gerekir. Bu doğruluk ne kadar artarsa ağıın öğrenme işlemi o kadar iyi olur. Doğru ağırlık değerleri, bir öğrenme kuralına göre tespit edilir. Çoğunlukla bağlantılara başlangıç değerleri olarak rasgele ağırlıklar atanır ve bu ağırlıklar eldeki örnekler incelendikçe bir kurala göre değiştirilerek doğru ağırlık değerleri bulunmaya çalışılır. Kısaca belirtmek gerekirse öğrenme kuralları, bir işlem elemanının örnekleri gördükçe kazandığı tecrübeye göre, ilgili bağlantı ağırlıklarını nasıl değiştireceğini belirleyen algoritmalarıdır. Öğrenme yöntemleri temelde eğitici, eğitici ve takviyeli öğrenme olarak üç grupta toplanır [46, 48].

*Eğitici Öğrenme:* Bu yöntemde, dışardan bir eğiticinin sinir ağıına müdahalesi söz konusudur. Eğitici, sinir ağıının ilgili giriş için üretmesi gereken sonucu sinir ağı sistemine verir. Yani yapay sinir ağıına giriş/çıkış ikilisinden oluşan örnekler sunulur. Bu ikili, ağıın öğrenmesi gereken özellikleri temsil eder. Ağ giriş kısmını alır ve o anki bağlantı ağırlıklarının

temsil ettiği bilgi ile bir çıkış oluşturur. Bu çıkış, olması gereken çıktı ile mukayese edilir ve aradaki hata tekrar ağa aktarılarak ağırlıklar bu hatayı azaltacak şekilde değiştirilirler.

*Eğitici-siz Öğrenme:* Bu durumda hiç bir eğiticiye ihtiyaç yoktur. Bu nedenle çoğu zaman buna kendinden organizeli öğrenme (self-organized learning) denilmektedir. Ağ, kendine gösterilen örnekleri alır ve belli bir kritere göre sınıflandırır, bu kriter önceden bilinmeyebilir. Ağ, kendi öğrenme kriterlerini kendisi oluşturmaktadır.

*Takviyeli Öğrenme:* Bu yöntemde de yine eğiticiye ihtiyaç vardır. Yukarıdaki yöntemden farkı ise, bu durumda eğiticinin, ağın üretmesi gereken sonuç yerine, onun ürettiği sonucun sadece doğru veya yanlış olduğunu söylemesidir. Bu ise ağa bir takviye sinyalinin gönderilmesi ile gerçekleştirilir. Bu yöntem, ilgili örnek için beklenen çıktının oluşturulamadığı durumlarda çok faydalıdır.

Öğrenme işlemi, başlangıçtaki rasgele seçilmiş ağırlıkların, belirli bir kurala göre değiştirilmesi esasına dayanmaktadır. Bu öğrenme kurallarından ikisi aşağıda açıklanmaktadır. Bu algoritmalarda,  $w_j = [w_{j1} \ w_{j2} \ \dots \ w_{jp}]$  vektörü ağıdaki  $i$ . hücreye gelen  $n$  tane girişin ağırlık katsayılarını,  $x = [x_1 \ x_2 \ \dots \ x_n]$  vektörü ağa gelen  $n$  tane girişi,  $y_j$  ve  $d_j$ 'de sırasıyla  $i$ . hücrenin hesaplanan ve istenen çıkışını temsil etmektedirler.

*Delta Kuralı (Eğim düşme) Öğrenme Algoritması:* Eğim düşme (gradient descent) öğrenme algoritması veya “delta kuralı” öğrenme algoritması, sadece türetilebilir fonksiyonlara sahip olan ağlara uygulanabilmektedir. Eğitici bir öğrenme algoritmasıdır.  $w$  değişimi, hatanın eğiminin tersi yöndedir. Böylece, hata fonksiyonunun minimum olduğu yere doğru hareket edilmektedir.  $k$ . örnek için, ağ çıkışı ile arzu edilen çıkış arasındaki farka (hataya) göre yeni ağırlık değerleri,

$$w_j(k+1) = w_j(k) - \alpha \cdot \frac{\partial E(k)}{\partial w_j(k)} \quad (5.6)$$

olur.  $E(k)$ , hata fonksiyonunu temsil etmektedir ve aşağıdaki gibi tanımlanmıştır.

$$E(k) = \frac{1}{2} (d(k) - y(k))^2 \quad (5.7)$$

ağ çıkışı, hata fonksiyonunda yerine yazılırsa,

$$E(k) = \frac{1}{2} [d(k) - f(w(k).x(k))]^2 \quad (5.8)$$

olur. Buradan yeni ağırlıkları bulmak için, hata fonksiyonunun ağırlıklara göre kısmi türevleri aşağıdaki gibi hesaplanır.

$$\frac{\partial E(k)}{\partial w_i(k)} = -[d(k) - f(w(k).x(k))] \cdot \frac{\partial f(w(k).x(k))}{\partial (w(k).x(k))} \cdot x_i(k) \quad (5.9)$$

Bilinen geriye yayılma algoritmasının esası da, bu öğrenme kuralına dayanmaktadır.

*Geriye Yayılım Öğrenme Algoritması:* İleri beslemeli ağ yapılarında kullanılan bir algoritmadır. İleri beslemeli bir yapay sinir ağı için arzu edilen çıkış ile ağ çıkışı arasındaki fark (hata), çıkıştan girişe doğru yansıtılır. Bunun için, k anındaki hatanın ağın her bir ağırlığa göre eğimi hesaplanarak, ilgili ağırlığa uygulanacak değişim miktarı bulunur.

## 5.6. Yapay Sinir Ağlarının Temel Özellikleri

Yapay sinir ağlarını hem popüler yapan, hem de geleneksel bilgi işleme metotlarından ayıran özellikleri vardır. Bu özellikleri, her ne kadar ilgili problemin yapısına ve kullanılan sinir ağı modeline bağlı olsa da, genel olarak aşağıdaki gibidir [47].

*Öğrenme:* Yapay sinir ağlarının istenilen davranışı gösterebilmesi için hücreler arasındaki bağlantıların doğru yapılması gerekir. YSA problemden aldığı örnekleri inceleyerek aradaki ilişkiyi kavramaya çalışır yani problemi öğrenir.

*Genelleme:* Klasik sınıflandırma yöntemlerinde, istenilen çıkışı üretmek için girişlerin tamamına ihtiyaç duyulmaktadır. Fakat yapay sinir ağları, girişinde değişimler olsa bile doğru çıkışı üretebilirler [17]. YSA, eğitim aşamasında verilmeyen giriş sinyalleri için de sistemle aynı davranışı gösterebilir [37].

*Çıkarım Yapma:* Yapay sinir ağları tam doğru olmayan bir eğitime kümesinden, tam doğruyu çıkarabilirler. Ses tanımak için eğitilmiş bir yapay sinir ağına, gürültülü bir ses verildiğinde ağ çıkışta doğru sesi üretebilir. Yani, eksik veya bozuk girişlere uygun sonucu verebilmektedir.

*Hata toleransı:* İyi eğitilmiş ve genelleme kapasitesi yüksek bir sinir ağı, veriler eksik olsa da karar verme işlemine devam eder. Bunun dışında yapay sinir ağı üzerinde bir takım problemler ve bozukluklar olabilir. Geleneksel sistemlerin tersine yapay sinir ağları, bu durumda da çalışmasına devam eder. Verilerdeki eksiklik veya yapay sinir ağındaki yapısal bozukluk arttıkça yapay sinir ağının performansı yavaş yavaş azalmaya başlamaktadır. Fakat sistem fonksiyonunu tamamen durdurmaz ve mutlaka bir sonuç üretmektedir. Bu özellikler yapay sinir ağının yapısından kaynaklanmaktadır. Çünkü ağ paralel bir yapıya sahip olduğundan, bilgi tüm hücrelere dağılmış durumdadır. Bundan dolayı birkaç bağlantının etkisiz hale gelmesi, sonucu etkilemez [54].

*Hız:* Gerçek zaman uygulamalarında bilgi işleme hızı önemli bir yer teşkil eder. Sistemlerin her geçen gün biraz daha karmaşık olduğu, dolayısı ile daha fazla hacimde veriyi daha verimli bir şekilde işleme gerekliliği, yeni yazılım/donanım sistemlerinin zorunluluğunu ortaya çıkarmıştır. Yapay sinir ağlarının da, yine birbirlerine bağlı ve paralel işlem

elemanlarından oluřtuđundan byle hızlı iřleyebilmeleri, bu ađlara zellikle endstriyel hayatta ok nemli olan gerek zamanlı alıřma kabiliyeti kazandırır [17, 32].

## 6. GENETİK DALGACIK YAPAY SİNİR AĞI (GDYSA) YAKLAŞIMIYLA SAYISAL MODÜLASYON TANIMA UYGULAMALARI

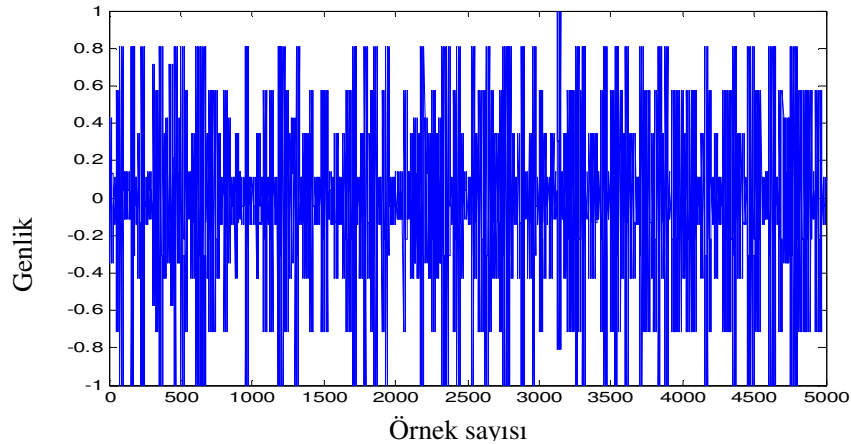
Bu tez çalışmasında, sayısal modülasyon tanıma için Genetik Dalgacık Yapay Sinir Ağları (GDYSA) tabanlı bir metod geliştirilmiştir. Burada GDYSA' nın kullanım amacı genetik algoritma ile özellik çıkarımında kullanılacak en uygun dalgacık tipini ve en iyi norm entropi  $p$  parametresi değerini seçerek, bu etkili özellikleri Yapay Sinir Ağları (YSA) sınıflandırıcısı ile sınıflandırmak ve böylelikle modülasyon tanımada optimum özellikleri elde ederek, en etkin modülasyon tanıma işlemini gerçekleştirmektir. Ayrıca GDYSA' nın özellik çıkarım aşamasında; fonksiyonları, operatörleri veya veriyi farklı frekanstaki bileşenlerine ayırıp, ayrı ayrı her bileşen üzerinde çalışmamıza izin veren dalgacık dönüşüm kullanılmıştır.

### 6.1. Sayısal Modüleli İşaretlerin Oluşturulması


Sayısal modüleli işaretler elde etmek için 0-60 dB SGO (İşaret Gürültü Oranı ) aralığında Gaussian Beyaz Gürültü (Additive White Gaussian Noise - AWGN) işaretlere ilave edilmiştir. Gürültü ilave edilerek her bir modülasyon çeşidinden 10 adet işaret oluşturulmuştur. Her modülasyon tipinden 15 adet, toplam 60 adet işaret elde edilmiştir. Bu işaretler YSA' nın eğitimi ve testi için kullanılmıştır.

- **ASK8 İşaretlerinin Oluşturulması**

Gürültü ilave edilerek oluşturulan 10 adet ASK8 işaretin taşıyıcı frekansı  $F_c=10$  Hz, örnekleme oranı  $F_s=25$  Hz, seviyesi  $M=8$  şeklinde değiştirilerek toplam 30 adet ASK8 modüleli işaret elde edilmiştir. Bir ASK8 modüleli işaret örneği Şekil 6.1' de gösterilmektedir.




Şekil 6.1. a)  $M=8$  ,  $F_c =10$  Hz için bir ASK8 modüleli işaret örneği.



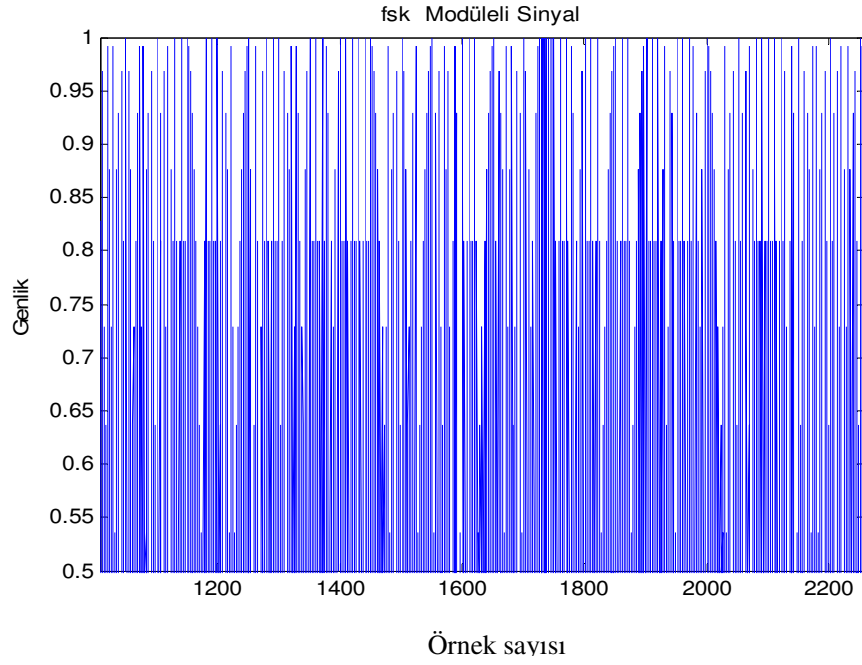
Şekil 6.1. b)  $M=8$  ,  $F_c = 10$  Hz için bir ASK8 modüledi işaretin zoomlu örneği.

- **FSK8 İşaretlerinin Oluşturulması**

Gürültü ilave edilerek oluşturulan 10 adet FSK8 işaretin taşıyıcı frekansı  $F_c=10$  Hz, örnekleme oranı  $F_s=25$  Hz, seviyesi  $M=8$  şeklinde değiştirilerek toplam 30 adet FSK8 modüledi işaret elde edilmiştir. Bir FSK8 modüledi işaret örneği Şekil 6.2' de gösterilmektedir.



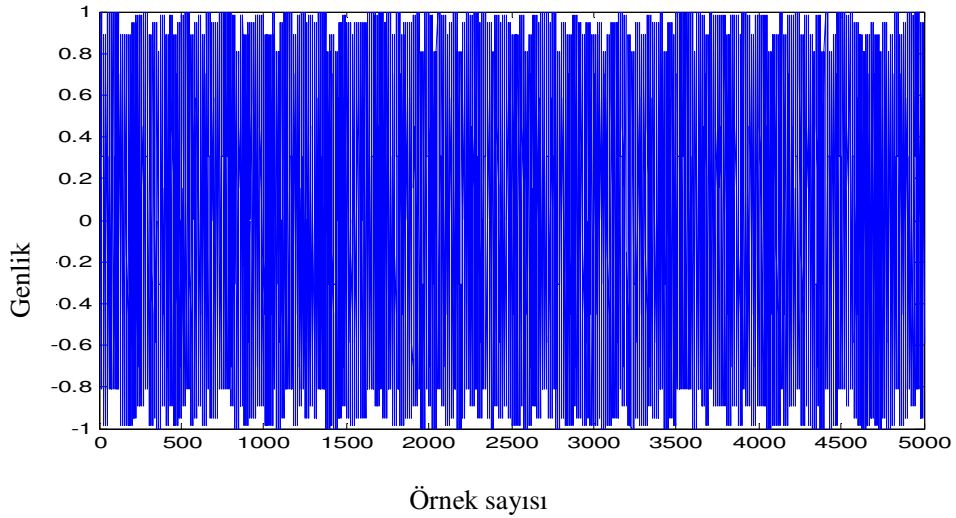
Şekil 6.2. a)  $M=8$  ,  $F_c = 10$  için bir FSK8 modüledi işaret örneği.



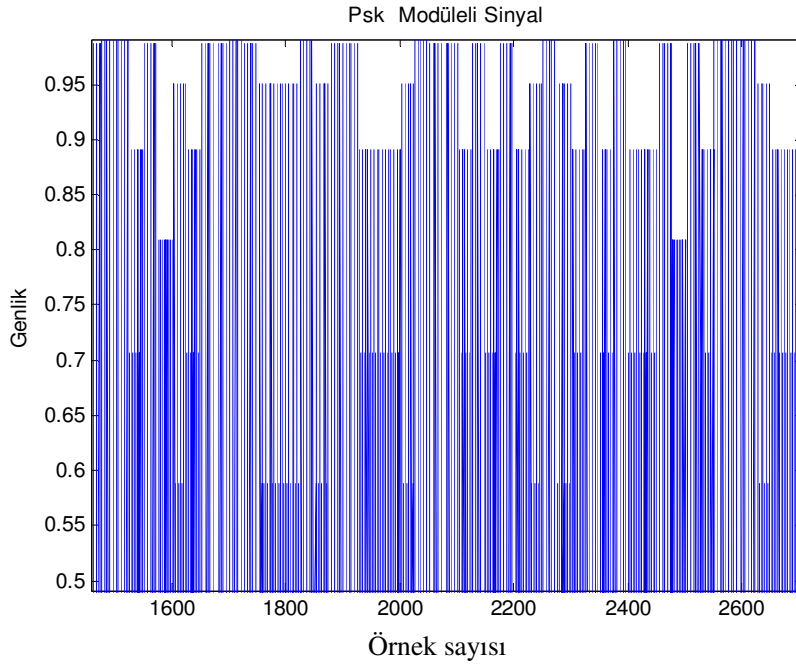
Şekil 6.2. b)  $M=8$  ,  $F_c =10$  Hz için bir FSK8 modüledi işaretin zoomlu örneği.

- **PSK8 İşaretlerinin Oluşturulması**

Gürültü ilave edilerek oluşturulan 10 adet PSK8 işaretin taşıyıcı frekansı  $F_c=10$  Hz, örnekleme oranı  $F_s=25$  Hz, seviyesi  $M=8$  şeklinde değiştirilerek toplam 30 adet PSK8 modüledi işaret elde edilmiştir. Bir PSK8 modüledi işaret örneği Şekil 6.3' de gösterilmektedir.




Şekil 6.3. a)  $M=8$  ,  $F_c =10$  için bir PSK8 modüledi işaret örneği.



Şekil 6.3. b)  $M=8$  ,  $F_c = 10$  Hz için bir PSK8 modüleli işaretin zoomlu örneği.


- **QASK8 İşaretlerinin Oluşturulması**

Gürültü ilave edilerek oluşturulan 10 adet QASK8 işaretin taşıyıcı frekansı  $F_c=10$  Hz, örnekleme oranı  $F_s=25$  Hz, seviyesi  $M=8$  şeklinde değiştirilerek toplam 30 adet QASK8 modüleli işaret elde edilmiştir. Bir QASK8 modüleli işaret örneği Şekil 6.4' te gösterilmektedir.



Şekil 6.4.a)  $M=8$  ,  $F_c = 10$  Hz için bir QASK8 modüleli işaret örneği.





Şekil 6.4.b)  $M=8$  ,  $F_c = 10$  Hz için bir QASK8 modüleli işaretin zoomlu örneği.

## 6.2. Özellik Çıkarımı

Bu tez çalışmasında sayısal modülasyonda özellik çıkarma için genetik algoritma ve ayrık dalgacık dönüşümü kullanılmıştır. Genetik algoritma, dalgacık dönüşümde kullanılacak en uygun dalgacık tipi ve en iyi norm entropi  $p$  parametre değerini seçmek için kullanılmıştır.

### 6.2.1. Genetik Algoritma

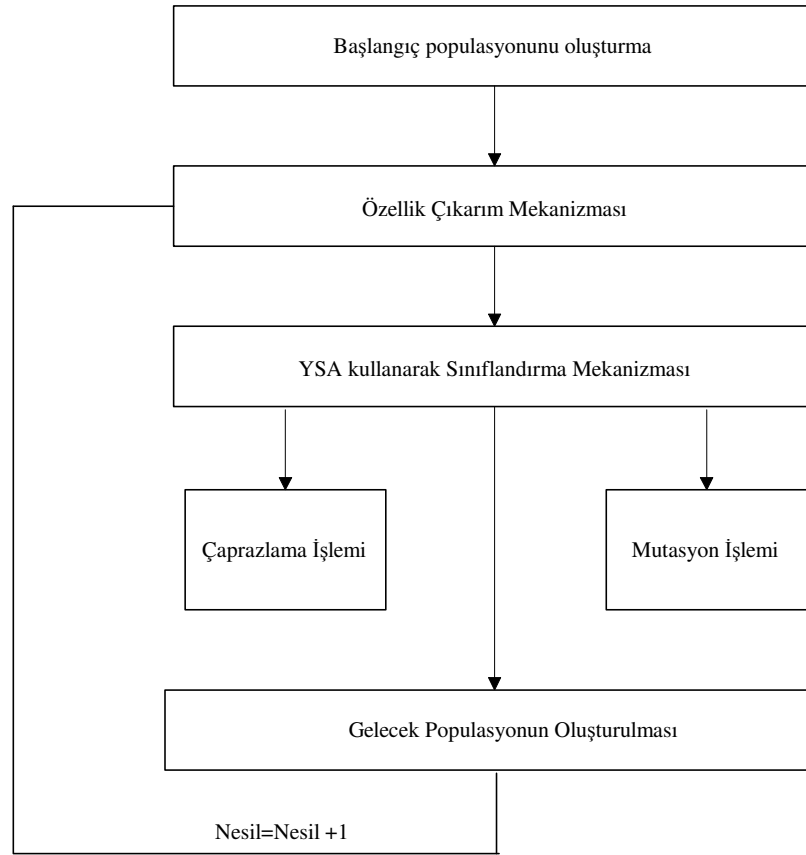
Bu çalışmada Genetik algoritma içerisinde gerçekleştirilen işlemler aşağıda sıralanmıştır.

- 1. Başlangıç Popülasyonunun Oluşturulması :** Genetik algoritmanın ilk aşaması popülasyonda kullanılacak birey sayısını belirlemektir. Bu tez çalışmasında rastgele 20 birey başlangıç popülasyonu için seçilmiştir. 16 çeşit dalgacık ailesi kullanıldığından norm entropi de kullanılan  $p$  parametresi popülasyonun her bir bireyi için 4 bit tarafından gösterilmektedir ve  $p$  parametresi için hassas değer  $1/16$  dır.  $P$  parametresinin değeri, 1.7320, 1.7990, 1.6660, 1.3320, 1.1990, 1.9320, 1.2660, 1.0660, 1.8650, 1.1330, 1.9980, 1.0000, 1.3990, 1.5330 ve 1.4650 olarak elde edilmiştir.
- 2. Özellik Çıkarma Mekanizması :** Rastgele bir birey ele alındığında ilgili bireyin temsil ettiği norm entropi, Shannon entropi, logaritmik enerji entropi, süre entropi ve eşik

entropi deęerleri hesaplanır. Buradan elde edilen entropi deęerleri özellik vektöründe özellik olarak kullanılır.

3. **Sınıflandırma Mekanizması :** Sınıflandırma mekanizmasında ise özellik çıkarım mekanizmasında elde edilen özellik vektörü çok katmanlı ileri beslemeli bir YSA sınıflandırıcının girişlerine verilerek bu özelliklerin sınıflandırılma işlemi gerçekleştirilmiştir.
4. **Çaprazlama Operatörü :** Elde edilen 10 adet iyi bireyin rastgele 6 tanesi kendi aralarında rastgele çaprazlama işlemine tabi tutulur. Kullanılan çaprazlama oranı %60' tır.
5. **Mutasyon Operatörü :** Bu uygulamada mutasyon operatörü olarak bit tersleme yöntemi kullanılmıştır. Geriye kalan 4 bireyin rastgele birer bitine bit tersleme işlemi uygulanarak buradan yeni 4 adet birey elde edilmiştir.

Aşağıda Şekil 6.5' de geliştirilen optimum entropi tabanlı özellik çıkarma yönteminin blok diyagramı verilmiştir.

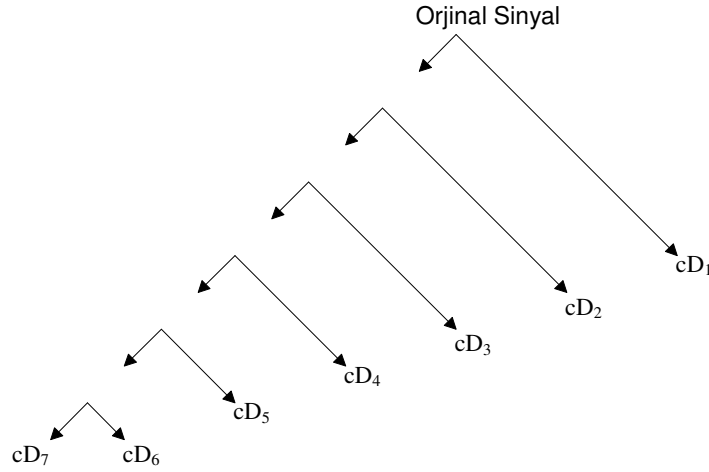


Şekil 6.5. Entropi tabanlı özellik çıkarma yönteminin blok diyagramı.

## 6.2.2. Dalgacık Dönüşüm

Bu çalışmada sayısal modülasyon işaretlerinde özellik çıkarmak için genetik algoritmayla birlikte ayrık dalgacık dönüşümü kullanılmıştır. Elde edilen her bir modüleli işaret dalgacık dönüşümünden geçirilerek özellikleri çıkarılmıştır.

Sayısal modülasyon işaretlerinin (ASK, FSK, PSK, QASK) dalgacık ayrışmaları için 7 seviyedeki ayrışım yapısı Şekil 6.6' da gösterilmiştir. Dalgacık dönüşümü ile işaretlerin diğer modülasyon tanıma yöntemlerinde ortaya çıkmayan en ince ayrıntılarına da ulaşılmıştır.

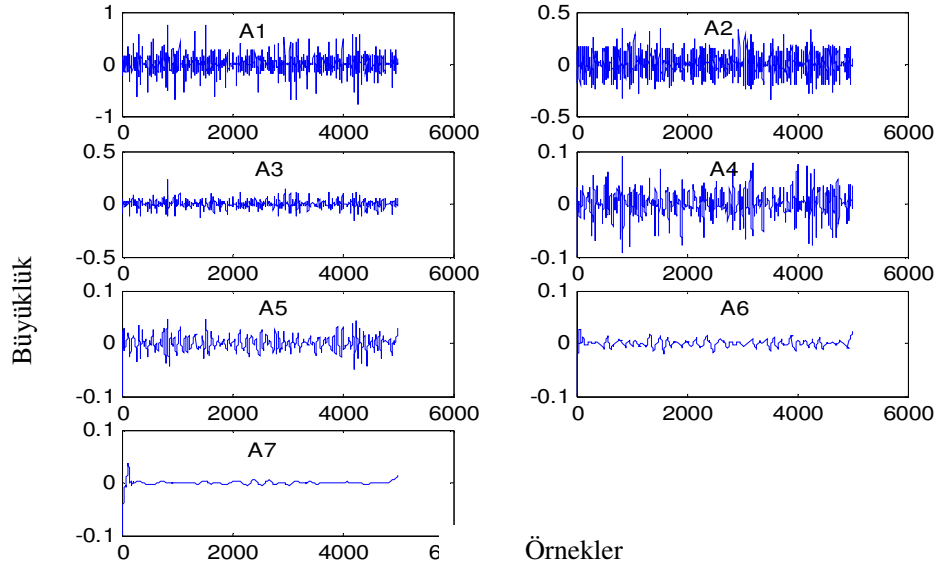


Şekil 6.6. 7 seviyede ayrışım yapısı.

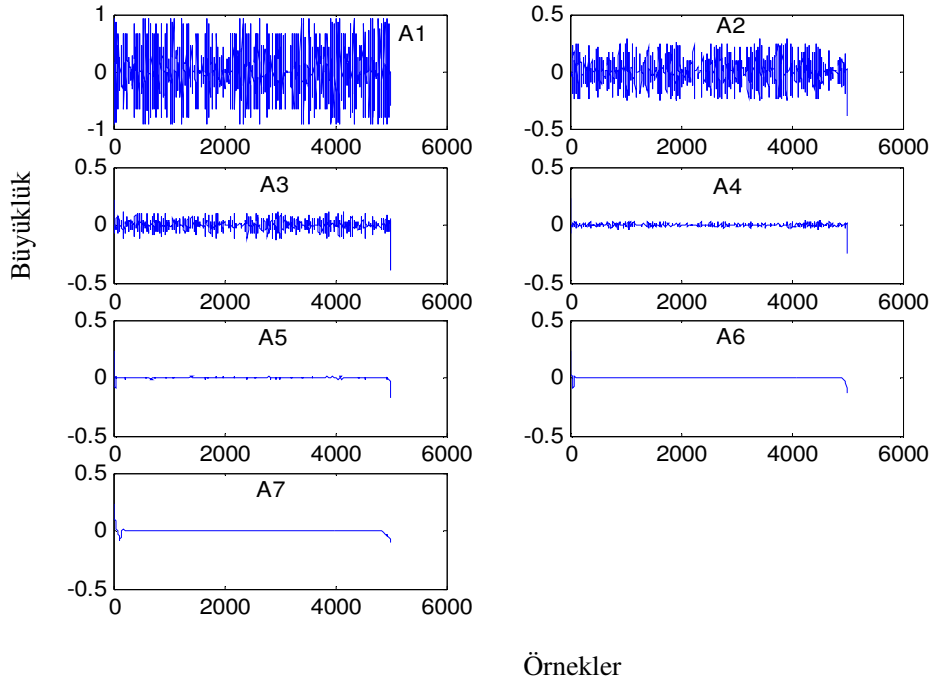
Dalgacık ayrışım db2, db4, db5, db10, sym2, sym3, sym5, sym8, bior1.3, bior2.2, bior3.5, bior6.8, coif1, coif2, coif3, coif5 dalgacık ayrışım filtreleri kullanılarak sayısal modülasyon işaretlerine uygulanmıştır. Böylece 7 -yaklaşım cA katsayısı elde edilmiştir.

Bu dalgacık katsayı işaretlerinin her birinin Norm entropi değerleri hesaplanıp 1/200 ile normalize edilmiştir.

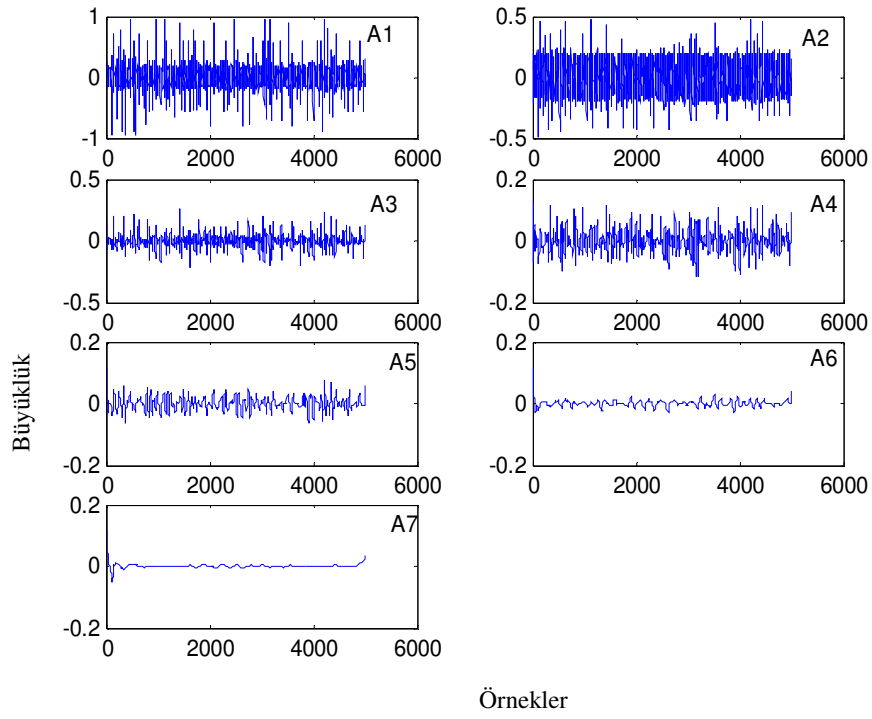
Şekil 6.7 (a-d)' de sırasıyla ASK, PSK, FSK ve QASK modülasyonlarının dalgacık dönüşümü uygulanarak elde edilen dalgacık dönüşümü katsayı örnek işaretleri görülmektedir.



Şekil 6.7(a). ASK8 işaretinin dalgacık dönüşüm ağacında bulunan işaretleri.

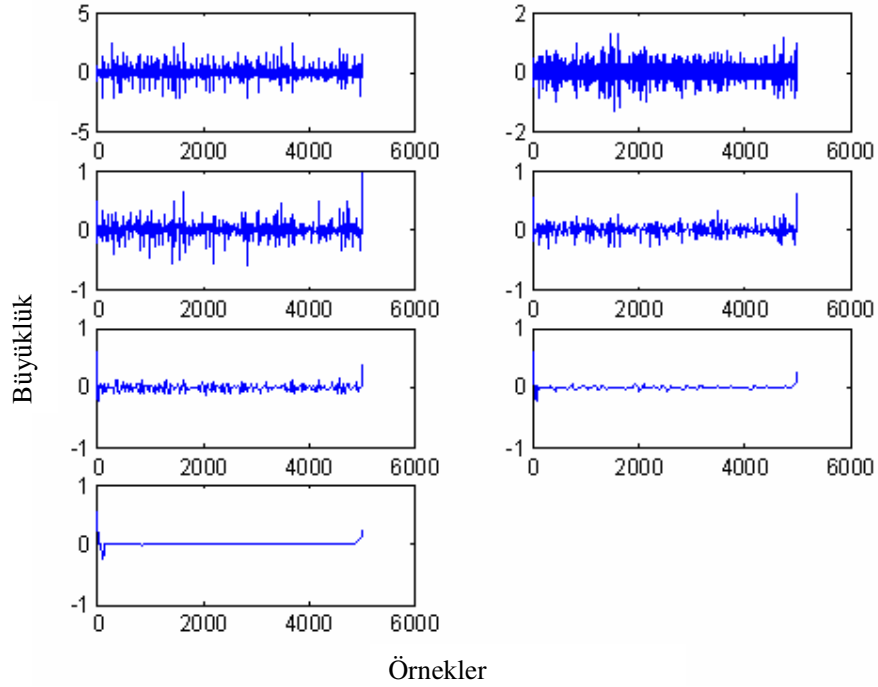


Şekil 6.7 (b). FSK8 işaretinin dalgacık dönüşüm ağacında bulunan işaretleri.



Örnekler

Şekil 6.7 (c). PSK8 işaretinin dalgacık dönüşüm ağacında bulunan



Örnekler

Şekil 6.7 (d). QASK8 işaretinin dalgacık dönüşüm ağacında bulunan

Dalgacık dönüşümünün sonucunda elde edilen işaretler entropi işleminden geçirilmiştir. Entropi, işaretteki düzensizliğin ölçütüdür. Kaynağı bilinmeyen modüleli işaretlerin özelliklerinin çıkarılması için bu metot kullanılmaktadır. Entropi birçok alanda uygulanmaktadır fakat en fazla işaret işlemede kullanılmaktadır.

Entropi için birçok kriter bulunmaktadır. Bunlar Shannon entropisi, Norm entropi, Log energy entropisi ve Threshold entropisidir.

GDYSA kullanarak sayısal modülasyon tanıma çalışmasında entropi olarak norm entropi kullanılmıştır. Elde edilen entropi değerleri  $N=200$  bölünele normalize edilmiştir. Böylece toplam normalize edilmiş 7 entropi değeri 60 işaretin her biri için bulunmuştur. Aynı zamanda bu entropi değerlerinin her biri dalgacık entropi olarak adlandırılmaktadır.

Entropi işlemi sonunda işaretlerin özellik vektörü çıkarılmıştır. Bu vektör her bir modülasyon tipi için (15X7) boyutundadır. Dalgacık dönüşümü 7 seviyede alındığından işaretlerin her birinin norm entropi değerleri hesaplanarak, her bir işaret için 7 özellik çıkarılmıştır. Toplam (60X7)' lık matris eğitim aşamasında, (60X7)' lık matris test aşamasında kullanılmıştır.

Dalgacık dönüşümü 7 seviyede alındığından 7 adet yaklaşık (A) işaret oluşturulmuş ve bu işaretlerin her birinin Norm entropi değerleri hesaplanarak, her bir işaret için özellik çıkarılmıştır. 4 (modülasyon çeşidi) x 15 ( her bir modülasyon çeşidi için kullanılan örnek sayısı) x 7 ( her bir modüleli işaretin özellik sayısı) matrisi eğitim aşamasında kullanılmıştır.

### 6.3. Sınıflandırma

Bu çalışmada, sınıflandırma için yapay sinir ağları sınıflandırıcısı kullanılmıştır. Bu mekanizma, özellik çıkarım mekanizmasından elde edilen özellikler kullanılarak uzman sınıflama için gerçekleştirilmiştir. Eğitim parametreleri ve bu çalışmada kullanılan YSA'nın yapısı Tablo1' de gösterilmiştir.


**Tablo1.** YSA yapısı ve eğitim parametreleri.

YAPILAR	
Katman sayısı	3
Katmanların nöron sayısı	Giriş:7 Gizli:15 Çıkış:1
Aktivasyon fonksiyonları	Log-sigmoid
Eğitim parametreleri öğrenme kuralları	Geriye yayılım
Momentum sabiti	0.95
Toplam Kare Hata	0.00001

Bunlar, bir kaç farklı deneme ile, yani gizli katman nöron sayısı, momentum ve öğrenme oranlarının değerleri ve etkinleştirme fonksiyonlarının türleri, en iyi başarımlar için seçildi. Şekil 6.8' de ise bu yöntem ile elde edilen özellikler ile kullanılan YSA' nın eğitim başarımı görülmektedir. Şöyle ki gizli katman sayısı, gizli katmanın boyutu, moment sabitinin değeri ve öğrenme oranı ve aktivasyonun tipi birkaç farklı deneyden sonra en iyi performans için seçilmiştir. YSA eğitiminde sayısal modüleli işaretlerden 60 tanesi kullanılmıştır. Modülasyon tiplerinden ASK8= 1, FSK8 = 2, PSK8= 3, ve QASK8= 4 olarak numaralandırılmıştır.

Bu çalışmanın adımları şunlardır:

- Özellik çıkarım mekanizmasından elde edilen (7X60) özellik vektörü YSA sınıflandırıcının girişine verilmiştir. YSA sınıflayıcının çıkışında karar alanı 4 sayısal modülasyondan oluşmuştur.
- Ortalama Karesele Hata (OKH ) YSA sınıflayıcının eğitim sonunda elde edilmiştir.
- YSA sınıflayıcının hedef hata değeri (HHD), OKH'ya eşit HHD ya da birey için daha az istenmiştir. Eğer bu durum fark edilirse, bu bireyin uygunluk fonksiyonu çok yüksek olacaktır. OKH-HHD' nin bu karşılaştırması popülasyonun bireylerinin uygunluk fonksiyonu gibi genetik algoritma için kullanılmıştır.



Şekil 6.8. YSA'nın eğitim başarımı.

#### 6.4. Deneysel Sonuçlar

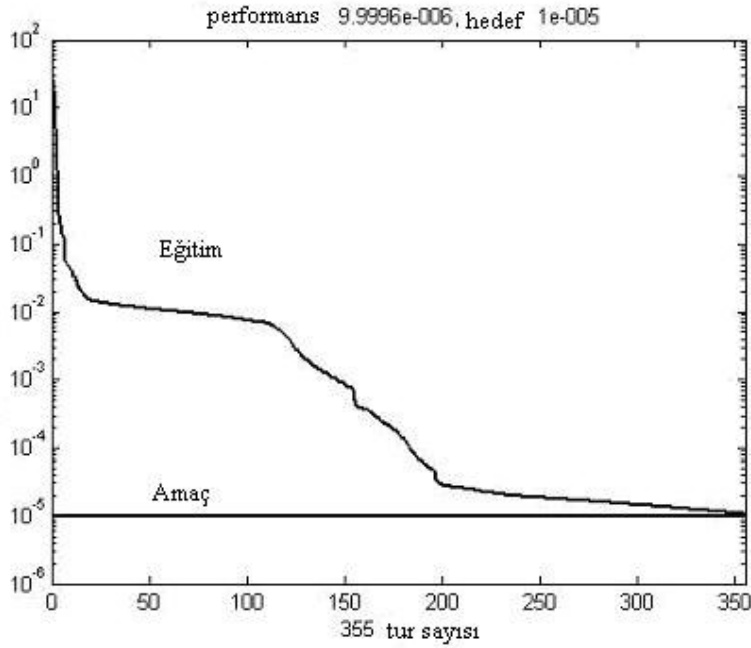
Sayısal modüleli işaretler ASK8, PSK8, FSK8 ve QASK8 olmak üzere 4 farklı işaret deneysel olarak incelenmiştir. Her bir işaretten 15 adet örnek alınmış ve toplam 60 işaret deneyde kullanılmıştır. Bu işaretler test ve eğitim aşamasında kullanılmıştır. Test aşamasında kullanılan bu işaretlerden %100 başarı oranı elde edilmiştir.

Bu işaretlerin her biri, farklı beyaz – gürültü genişliğine sahip gürültü işareti olarak kullanılmıştır. (İşaret/Gürültü Oranı(SNR)=0-60 dB). 60 tane işaret, en uygun özellik çıkarım ve GDYSA sınıflama mekanizması için kullanılmıştır. Ayrıca bu işaretler GDYSA performansını test etmek için de kullanılmıştır. Bu deneylerde, %95 doğru sınıflandırma 4 farklı sayısal işaret sınıflayıcı arasından GDYSA'nın eğitiminden elde edilmiştir. Sayısal modülasyon işaretlerinden en uygun özellik çıkarma için önerilen yaklaşımın güvenilirliği ve geçerliliği çok yüksektir. GDYSA algoritması kullanılarak elde edilen p parametre değeri, dalgacık ailesi parametre değeri ve hata değeri ve GDYSA algoritmasının performans sınıflayıcısı Tablo2' de verilmiştir



**Tablo2.** GDYSA algoritması kullanarak elde edilen optimum değerler ve GDYSA' nın sınıflama performansı

Elde edilen en uygun P parametresi	Wavtip	Hata Değeri	GDYSA'nın sınıflama performansı
1.732	coif5	0.000010	%98
1.799	coif1	0.000010	%97
1.000	db5	0.000008	%95
1.666	sym5	0.000010	%98
1.399	db2	0.000009	%96
1.266	db10	0.000010	%93
1.998	bior2.2	0.000009	%95
1.865	db4	0.000009	%96
1.465	sym8	0.000010	%98
1.998	coif3	0.000006	%98
1.533	sym2	0.000009	%95
1.535	bior1.3	0.000009	%96
1.666	db10	0.000009	%94



**Şekil 6.9.** GDYSA kullanarak sayısal modülasyon tanımının eğitim performansı.

## 7. SONUÇ

### 7.1. Sonuçlar ve Tartışma

Bu tez çalışmasının yapılmasındaki temel amaç, günümüzde askeri ve sivil haberleşme ortamlarında yaygın olarak kullanılan sayısal modülasyon tekniklerinin bilgisayar ortamında otomatik olarak tanınmasını sağlayan akıllı bir sayısal modülasyon tanıma uygulaması gerçekleştirmektir.

Bu amaçla tez çalışmasında, sayısal modüleli işaretlerden, bu işaretleri temsil edecek en iyi özelliklerin çıkarılması ve bu özelliklerin YSA sınıflandırıcısı kullanılarak sınıflandırılması için bir Genetik Dalgacık Yapay Sinir Ağları (GDYSA) uzman sistemi geliştirilmiştir.

Bu GDYSA yapısının özellik çıkarım mekanizmasında, optimum özellik çıkarımını sağlamak için sırasıyla değişik dalgacık ailelerinin kullanımı ile oluşturulmuş dalgacık dönüşümü ve dalgacık entropi hesaplama yöntemleri kullanılmıştır. Geliştirilen bu GDYSA yapısı öncelikle özellik çıkarım kısmında probleme en uygun dalgacık aile türünü seçer. İkinci aşamada ise bu seçilen dalgacık aile türü kullanılarak elde edilen dalgacık dönüşümü katsayılarını, en uygun parametre değerine sahip dalgacık entropi hesaplamasından geçirerek, en iyi özelliklerin bulunması ve daha sonrada bu özelliklerin YSA sınıflandırıcısına verilerek sınıflandırılması amaçlanmaktadır.

Bu tez çalışmasında GDYSA yapısı kullanılarak gerçekleştirilen sayısal modülasyon tanıma uygulamaları, farklı türdeki sayısal modüleli işaretler kullanılarak gerçekleştirilmiştir. Bu uygulamaların sonucunda elde edilen ve GDYSA uzman sisteminin sayısal modüleli işaretleri tanıma performansını gösteren sonuçlar, Tablo 2' de verilmiştir. Bu elde edilen sonuçlar, GDYSA' nın sayısal modüleli işaretleri tanımlamak için uygun bir yöntem olduğunu göstermektedir.

Burada GDYSA yapısının kullanılmasındaki temel amaçlardan biride ileride sayısal modüleli işaretlerin yorumlanması alanında yapılabilecek gerçek uygulamalara bir zemin oluşturmaktır. Böylece vericiden gelen henüz demodüle edilmemiş işaretin içinde ne tür sayısal modülasyon türünün olup olmadığını kestirerek, herhangi bir operatör kişiye ihtiyaç duyulmadan bu modülasyon türlerinin otomatik olarak tanınması sağlanabilecektir.

### 7.2. Öneriler

- Günümüz teknolojisinde sayısal modülasyonların otomatik olarak tanınmasının gerektiği her yerde GDYSA uzman sistemi tercih edilebilir.

- Bu çalışmada sınırlı sayıda sayısal modüleli işaret kullanılmıştır. Daha sonradan bu alanda yapılacak çalışmalarda ise daha geniş bir veri tabanı kullanılarak GDYSA'nın başarımı denenebilir.
- Bu çalışmada sayısal modüleli işaretlerin yorumlanması amaçlanmıştır. Aynı yöntemler analog modüleli işaretlerin yorumlanması içinde uygulanabilir.
- Ayrıca GDYSA uzman sistemi gerçek haberleşme sistemlerinde de sayısal ya da analog modülasyon tanıma amaçlı kullanılabilir.
- Askeri ve sivil haberleşme ortamlarında yaygın olarak kullanılan sayısal modülasyon tekniklerinin bilgisayar ortamında otomatik olarak tanınmasını sağlamak için Genetik Dalgacık Yapay Sinir Ağları kullanılabilir.

### **7.3. Yayınlar**

Bu tez çalışmasında gerçekleştirilen uygulamalar bir adet uluslar arası konferans yayını [33] ve bir adet dergi yayını ile sonuçlandırılmıştır.

## KAYNAKLAR

1. Tomasi,W., 1994, Elektronik İletişim Teknikleri. MEB, Ankara.
2. Derin, H., Aşkar, M., 1987, İletişim Kuramı Modülasyon Yöntemleri. ODTÜ Mühendislik Fakültesi, Ankara.
3. Türkoğlu, İ., 2002, Haberleşme Tekniği-I Ders Notları. Fırat Üniversitesi, Elazığ.
4. Azzouz, E. E., Nandi, A. K., 1997, Automatic Modulation Recognition-I, Journal of Franklin Inst., 334B, No.2, 241-273.
5. Azzouz, E. E., Nandi, A. K., 1997, Automatic Modulation Recognition-II, Journal of Franklin Inst., 334B, No.2, 275-305.
6. Dominguez, L. V., Borello, J. M. P., Garcia, J. P., &Mezaua, B. P., 1991, A general approach to the automatic classification of radio communication signals, Signal Processing, 22, 239–250.
7. Jondral, F., 1985, Automatic classification of high frequency signals,Signal Processing, 9, 177–190.
8. Azzouz, E.E., Nandi, A.K., 1996, Automatic modulation recognition of communication signals, Kluwer Academic Publishers.
9. Ghani, N., Lamontagne, R., 1993, Neural networks applied to the classification of spectral features for automatic modulation recognition, Military Communication Conference, 93, 111-115.
10. Fabrizi, P. M., Lopes L. B., Lockhart, G. B., 1986, Receiver recognition of analogue modulation types, in IERE Conference on Radio Receiver and Associated Systems, Bangor Wales, 135-140.
11. Guldemir, H, Sengür, A.,2006, Comparison of Clustering Algorithms for Analog Modulation Classification, Expert Systems with Applications, 30, No.4, 642-649.

12. Avcı, E., 2007, Performance comparison of wavelet families for analog modulation classification using expert discrete wavelet neural network system, Elsevier Expert Systems with Applications, 33, No.1, (in Press).
13. Aisbett, J., 1997, Automatic modulation recognition using the time domain parameters, Signal Processing, 13, 323–328.
14. Nandi, A. K., Azzouz, E. E., 1997, Modulation recognition using artificial neural networks, Signal Processing, 56, 165-175.
15. Yarcı, K., Öztürk, O., 1999, Elektronik Ders Kitabı. Beta Yayınevi, İstanbul.
16. Rajan, J.J., 1994, Time series classification, Doktora Tezi, Cambridge Üniversitesi, 191s.
17. Türkoğlu, İ., 2003, Örüntü Tanıma Ders Notları. Fırat Üniversitesi, Elazığ.
18. Rothe, H., 1998, Approaches to pattern recognition, advanced pattern recognition techniques, NATO-RTO Lecture Series 214, Lisbon Portugal, 1.1 – 1.29.
19. Duda, R.O. and Hart, P.E., 1989, Pattern Classification and Scene Analysis. Stanford Research Institute, 483s.
20. Phan, F., Tzanakou, E.M. and Sideman, S., 2000, “Speaker identification using neural networks and wavelets”, IEEE Engineering in Medicine and Biology, Ocak/Şubat, 92-101.
21. Türkoğlu, İ. ve Hanbay, D., 2001, “Yapay sinir ağı ve HFD kullanarak DTMF sinyal örüntülerini tanıma sistemi”, Elektrik-Elektronik-Bilgisayar Mühendisliği 9.Ulusal Kongresi, 19-23 Eylül 2001, Kocaeli, 431-434.
22. Chau, T., 1994, “Pattern recognition of processed EMG signals for two-site Myoelectric control”, Uygulamalı Master Lisans Tezi, Toronto Üniversitesi, 96s.

23. Kil, D.H. ve Shin, F.B., 1996, Pattern Recognition and Prediction with Applications to Signal Characterization. AIP Press, USA, 417s.
24. Rutledge, G.A., 2000, "Dictionary Projection Pursuit: A wavelet packet technique for acoustic spectral feature extraction", Doktora Tezi, Victoria Üniversitesi, 193s.
25. Englehart, K., 1998, Signal Representation for Classification of the Transient Myoelectric Signal. Doktora Tezi, New Brunswick Üniversitesi, Kanada, 319s.
26. Young, T.Y. and Fu, K.S., 1986, Handbook of pattern recognition and image processing. Academic Press, Inc, 159s.
27. Bishop, C.M., 1996, Neural networks for pattern recognition. Clarendon Press, Oxford, 482s.
28. Banks, S.P., 1990, Signal Processing, Image Processing and Pattern Recognition, Prentice-Hall, New York, 409s.
29. Türkoğlu, İ., 1996, Yapay sinir ağları ile nesne tanıma, Yüksek Lisans Tezi, Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Elazığ, 112 s.
30. Ward, M., 1998, Detection and classification of transient underwater sounds by a finite impuls response neural network, Yüksek Lisans Tezi, New Brunswick Üniversitesi, Fredericton, Kanada.
31. Kaita, T., Tomita, S. ve Yamanaka, J., 2002, On a higher-order neural network for distortion invariant pattern recognition, Pattern Recognition Letters, 23,8,977-984.
32. Türkoğlu, İ., ve Arslan, A., 1996, Yapay sinir ağları ile bozuk örüntü tanıma, Fırat Üniversitesi Fen ve Mühendislik Bilimleri Dergisi, 8, 147-158.

33. Avcı, E., Bicer, Z. Erdem Yakut, S., 2006, An Adaptive Wavelet Entropy Method for Intelligent Digital Modulation Classification, Fifteenth Turkish Symposium on Artificial Intelligence and Neural Networks (TAINN 2006), MUĞLA,117-124, No.2.
34. Avcı, E., Türkoğlu, İ., ve Poyraz, M., 2005, Intelligent Target Recognition Based on Wavelet Packet Neural Network, Expert Systems with Applications, 29, No.1, 175-182.
35. Matlab 6.5 Wavelet Toolbox Help , 2006.
36. Avcı, E., Avcı, D., A novel approach for digital radio signal classification: Wavelet packet energy–multiclass support vector machine (WPE–MSVM) ARTICLE Expert Systems with Applications, In Press, Uncorrected Proof, Available online 1 Mart 2007.
37. Avcı, E., 2007, Performance comparison of wavelet families for analog modulation classification using expert discrete wavelet neural network system, Elsevier Expert Systems with Applications, 33, No.1, (in Press).
38. Hanbay, D., Türkoğlu, İ., ve Demir, Y., 2008, Prediction of Wastewater Treatment Plant Performance Based on Wavelet Packet Decomposition and Neural Networks, Expert systems with applications, 34, No.4.
39. Shannon, C.E., 1948, A mathematical theory of communication, Bell System Technology Journal, 27, 379-423.
40. Tonga, S., Bezerianosa, A., Paula, J., Zhub, Y. ve Thakora, N., 2002, Nonextensive entropy measure of EEG following brainin jury from cardiac arrest, Elsevier Physica A, 305, 619 – 628.
41. Principe, J.C., Euliano, N.R. ve Lefebvre, W.C., 2000, Neural and Adaptive Systems. John Wiley & Sons, 1. Baskı, New York, 656s.
42. KURT M., SEMETAY C., M.Ü.Teknik Eğitim Fakültesi Makina Bölümü.

43. Avcı, E., Türkođlu, İ., ve Poyraz, M., An Expert Target Recognition System Using Genetic Wavelet Neural Network.
44. Avcı E., 2005, Akıllı Radar ile Hedef Tanıma Sistemi, Fırat Üniversitesi, Doktora.
45. EMEL G.G., TAŞKIN Ç., 2002, Genetik Algoritmalar ve Uygulama, Uludağ Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi Cilt XXI, Sayı 1, s. 129-152.
46. Zurada, M.J., 1992, Introduction to Artificial Neural Systems, West Publishing Company, Inc. New York.
47. Bal C., 2002, Doğru Akım Motorlarının Hız Denetiminde Yapay Sinir Ağlarının Performans Analizi, F.Ü. Fen Bilm. Enst. Yüksek Lisans Tezi.
48. Hanbay D. 2005, Akıllı Donanım ve uygulamaları, F.Ü. Fen Bilm. Enst. Doktora Semineri.
49. Haykin, S., 1994, Neural Networks, A Comprehensive Foundation, Macmillan College Publishing Comp. Inc.
50. Narendra, K.S., ve Parthasarathy, K., 1990, Identification and Control of Dynamical Systems Using Neural Networks, IEEE Transactions on Neural Networks, Vol.1, No:1, 4-27.
51. Hunt, K.J., Sbarbaro, D., Zbikowski R., and et all, 1992, Neural Networks for Control Systems – A Survey, Automatica, Vol.28, No:6, 1083-1112.
52. Karlık, B., 1995, Yapay Sinir Ağları, Yüksek lisans ders notları.
53. Öztemel, E., 2003, Yapay Sinir Ağları, Papatya Yayıncılık, İstanbul.



54. BALOĐLU, Ő., 2003, Modül Yapay Sinir AĐları İle DoĐrusal Olmayan Sistemlerin Denetimi, Yüksek Lisans, F.Ü. Fen Bilimleri Enstitüsü.

## ÖZGEÇMİŞ

Zeynep BİÇER

zeynepbicer@hotmail.com.tr

Fırat Üniversitesi Teknik Eğitim Fakültesi

Elektronik Bilgisayar Eğitimi Bölümü

ELAZIĞ

1982 yılında Malatya’da doğdu. İlk, orta ve lise öğrenimini Malatya’da tamamladıktan sonra 2001 yılında Fırat Üniversitesi Teknik Eğitim Fakültesi Elektronik Bilgisayar Eğitimi Bilgisayar Öğretmenliği Bölümü’nü kazandı. 2005 yılında bu bölümden mezun oldu.. Aynı yıl Fırat Üniversitesi Fen Bilimleri Enstitüsü Elektronik Bilgisayar Eğitimi Ana Bilim Dalı Telekomünikasyon Bilim Dalı’nda yüksek lisans eğitimine başladı. 2005 yılı eylül ayında Malatya Kemal Özalper İlköğretim Okulu’nda Bilgisayar Öğretmeni olarak göreve başladı. Halen bu görevi sürdürmektedir. Yabancı dili İngilizce’dir.