

**T.C.  
SAKARYA ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ**

**EMG İŞARETLERİNİN İŞLENMESİ  
VE SINIFLANDIRILMASI**

**YÜKSEK LİSANS TEZİ**

**Elektrik-Elektronik Mühendisi İsmail YAZICI**

**Enstitü Anabilim Dalı : ELEKTRİK-ELEKTRONİK MÜH.  
Enstitü Bilim Dalı : ELEKTRONİK  
Tez Danışmanı : Prof. Dr. Etem KÖKLÜKAYA**

**Nisan 2008**

T.C.  
SAKARYA ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ

## EMG İŞARETLERİNİN İŞLENMESİ VE SINIFLANDIRILMASI

YÜKSEK LİSANS TEZİ


Elektrik-Elektronik Mühendisi İsmail YAZICI

Enstitü Anabilim Dalı : ELEKTRİK-ELEKTRONİK MÜH.

Enstitü Bilim Dalı : ELEKTRONİK

Bu tez 29 / 04 /2008 tarihinde aşağıdaki jüri tarafından Oybirliği ile kabul edilmiştir.

  
Prof. Dr. Etem KÖKLÜKAYA  
Jüri Başkanı

  
Yrd. Doç. Dr. Cabir VURAL  
Üye

  
Doç. Dr. M. Barış BASLO  
Üye

## ÖNSÖZ

Tez çalışmam sırasında bilgi ve birikimiyle her an yanımda olan tez danışmanım Sayın Prof. Dr. Etem KÖKLÜKAYA'ya, bu çalışmada emeği olan İstanbul Üniversitesi Tıp Fakültesi Nöroloji Anabilim dalı öğretim üyesi Sayın Doç. Dr. M. Barış Baslo'ya, Elk-Elktr. Yük. mühendisi Mustafa ÖZSERT'e, desteğini her an yanımda hissettiğim eşime ve saygıdeğer aileme teşekkür eder şükranlarımı sunarım.

## İÇİNDEKİLER

ÖNSÖZ.....	ii
İÇİNDEKİLER .....	iii
SİMGELER VE KISALTMALAR LİSTESİ.....	vi
ŞEKİLLER LİSTESİ .....	viii
TABLolar LİSTESİ .....	xi
ÖZET.....	xv
SUMMARY.....	xvi
BÖLÜM 1.	
GİRİŞ.....	1
1.1. İlk Yapılan Çalışmalar.....	2
1.2. Son Yapılan Çalışmalar.....	3
BÖLÜM 2.	
ELEKTROMİYOGRM İŞARETİ VE ÖLÇÜLMESİ.....	5
2.1. Kasların Yapısı.....	8
2.1.1.Kas kasılması.....	10
2.1.2.Motor ünite ve motor hareketi.....	11
2.1.3.Kaslarda servomekanizma.....	12
2.1.3.1. Refleks cevap.....	13
2.1.3.2. Kas hareketi sırasında üretilen gerilim.....	13
2.1.3.3. Kas kasılmasının regülasyonu.....	14
2.1.4. Kas kasılması sırasında oluşan gerilim.....	15
2.1.4. Kas yorulması ile EMG’de görülen değişim.....	18
2.2.EMG İşaretlerini İnceleme Yöntemleri.....	18
2.2.1. EMG işaretlerinin zaman domeninde incelenmesi.....	19

2.2.1. EMG işaretlerinin frekans domeninde incelenmesi.....	22
2.3.EMG Ölçüm Düzeni.....	24
2.4.Elektrotlar.....	25
2.4.1.Elektrotun devre modeli.....	27
2.4.2.Elektrot çeşitleri.....	28
2.4.2.1. Yüzey elektrotları.....	29
2.4.2.2. Dahili elektrotlar.....	31
2.4.2.3. Mikroelektrotlar.....	32
2.4.3.Hücre uyarmada kullanılan elektrotlar.....	34
<b>BÖLÜM 3.</b>	
<b>BİYOMEDİKAL İŞARET İŞLEME.....</b>	<b>35</b>
3.1. Rasgele İşaretlerin İşlenmesi.....	37
3.1.1.Fourier dönüşüm.....	38
3.1.2.Kısa dönem fourier dönüşüm ve spektrogram.....	38
3.1.3.Durağan süreçler ve modeller.....	41
3.1.3.1.Ayrık–Zaman durağan süreçlerin kısmi karakterizasyonu.....	42
3.1.3.2.Korelasyon matrisi.....	44
3.1.3.3.Durağan modeller.....	47
3.1.4.Dalgacıklar ve dalgacık dönüşümü.....	57
3.1.4.1. Dalgacık açılımı ve dalgacık dönüşümü.....	57
3.1.4.2. Dalgacık sistemi.....	58
3.1.4.3. Dalgacık sisteminin özel karakteristikleri.....	59
3.1.4.4. Haar ölçekleme fonksiyonu ve dalgacıklar.....	59
3.1.4.5. Dalgacık analizi niçin etkilidir.....	60
3.1.4.6. Dalgacıklar ve fourier dönüşümü.....	60
3.1.4.7. Sürekli dalgacık dönüşümü.....	62
3.1.4.8. Ayrık dalgacık dönüşümü.....	63
<b>BÖLÜM 4.</b>	
<b>YAPAY SİNİR AĞLARI.....</b>	<b>66</b>
4.1. Yapay Sinir Ağlarının Genel Özellikleri.....	68

4.1.1. Yapay sinir ağlarının dezavantajları.....	69
4.2. Çok Katmanlı Algılayıcı Ağlar.....	70
4.2.1. Çok katmanlı algılayıcı ağların yapısı.....	71
4.2.1. Çok katmanlı algılayıcı ağlarda öğrenme.....	72
4.3. Radyal Temelli Ağlar.....	76
4.3.1. Ağ topolojisi.....	77
4.3.2. Radyal temelli ağların eğitilmesi.....	79
4.3.2. Radyal temelli ağların öğrenme algoritmaları.....	80
4.4. LVQ Ağı.....	81
4.4.1. LVQ ağının özellikleri.....	81
4.4.2. LVQ ağının yapısı.....	82
4.4.3. LVQ ağının çalışma prosedürü.....	83
4.4.4. LVQ ağının öğrenme kuralı.....	84
4.4.5. LVQ ağının eğitilmesi.....	88
<b>BÖLÜM 5.</b>	
<b>MALZEME VE YÖNTEM</b> .....	89
5.1. EMG Kaydı Yapılan El Hareketleri.....	89
5.2. Seçilen Kas Grupları.....	92
5.3. EMG Kayıtlama Şekli.....	93
<b>BÖLÜM 6.</b>	
<b>SONUÇLAR VE ÖNERİLER</b> .....	97
6.1. Sonuçlar.....	97
6.2. Öneriler.....	106
<b>KAYNAKLAR</b> .....	108
<b>EK (Matlab yazılımı)</b> .....	111
<b>ÖZGEÇMİŞ</b> .....	112

## SİMGELER VE KISALTMALAR LİSTESİ

MES	: Miyoelektrik sinyal
EMG	: Elektromiyogram
YSA	: Yapay sinir ağları
DD	: Dalgacık dönüşümü
TBA	: Temel bileşenler analizi
BBA	: Bağımsız bileşenler analizi
MÜAP	: Motor ünite aksiyon potansiyeli
ISEK	: The International Society of Electromyography and Kinesiology
SENIAM	: Surface EMG for Noninvasive Assesment of Muscles
ATP	: Adenazin trifosfat
HZ	: Hertz
Ms	: Milisaniye
mo(t)	: Hareket eden ortalama
RMS	: Root mean square
t	: Zaman
f	: Frekans
Zf	: Sıfır geçiş hızı
C <sup>+</sup>	: Katyon
A <sup>-</sup>	: Anyon
E <sub>o</sub>	: Yarı hücre çekirdek potansiyeli
EKG	: Elektrokardiyogram
kohm	: Kilo ohm
T	: Periyod
FD	: Fourier dönüşüm
HFD	: Hızlı fourier dönüşüm

X	: Raslantı deęiřkeni
$x(t)$	: İřaret
KZFD	: Kısa zaman fourier dđnüşüm
$h(t)$	: Normalize edilmiş perncere fonksiyonu
SP	: Spektrogram
WAR	: Wavelet tabanlı AR(Dalgacık tabanlı öz baęlanım)
DD	: Dalgacık dđnüşümü
$\psi(t)$	: Ana dalgacık
ADD	: Ayrık dalgacık dđnüşümü
SDD	: Sürekli dalgacık dđnüşümü
db	: Daubechies
ÖB	: Öz baęlanımlı modeller
$r(k)$	: Otokorelasyon fonksiyonu
$r(k)$	: Otokorelasyon fonksiyonu
$c(k)$	: Otokovaryans fonksiyonu
R	: Korelasyon matrisi
$u(n)$	: Gözlem vektörü
$\sigma^2$	: Gürültü varyansı
$h(n)$	: Darbe cevabı
$a(k)$	: Öz baęlanımlı model katsayıları
YSA	: Yapay sinir aęları
w	: Yapay sinir aęı aęırlık katsayısı
ÇKA	: Çok katmanlı aę
$\beta_j$	: Ara katman j. elemana baęlanan eřik deęer elemanın aęırlıęı
E	: m. eleman için hata
TH	: Toplam hata
$\Delta w_a$	: Deęişim miktarı
RTA	: Radyal temelli aęlar
RTF	: Radyal temelli fonksiyon
LVQ	: Liner vector kuantalama
d	: Girdi vektörü X ile referans vektörü A arasındaki mesafe



## ŞEKİLLER LİSTESİ

Şekil 2.1.	Elektromiyogram (EMG) işareti.....	2
Şekil 2.2.	Çizgili kaslarda A, H, Z ve I bandları.....	5
Şekil 2.3.	Sinir-Kas.....	7
Şekil 2.4.	Kaslarda Servomekanizma.....	8
Şekil 2.5.	Kasın iç yapısı.....	10
Şekil 2.6.	Normal bir dorsal interossus kasının çok azdan çok kuvvetliye kadar kasılması anlarında üretilen potansiyeller .....	11
Şekil 2.7.	Bir motor ünitesinin aktive edilip EMG işaretini.....	12
Şekil 2.8.	EMG işaretlerinin oluşumu ve yüzey elektrotlara ulaşımı.....	13
Şekil 2.9.	Kasa uyarı gelişi ve kasın kasılması.....	13
Şekil 2.10.	EMG İşaretlerinin monopolar ve bipolar deteksiyonu.....	18
Şekil 2.11.	EMG İşaretlerinin elektrotlara ulaşımına kadar ki işlemler a)EMG işaretlerinin işlendiği integratör diyagramı, b)İntegratörün çeşitli noktalarındaki işaretlerin zamana göre değişimi .....	19
Şekil 2.12	İdealize edilmiş EMG işareti güç spektrum yoğunluğu.....	22
Şekil 2.13.	Klinik EMG düzeni basitleştirilmiş modeli.....	24
Şekil 2.14.	Elektrot-elektrolit arayüzü ve akım.....	25
Şekil 2.15.	Elektrotun eşdeğer devre modeli.....	27
Şekil 2.16.	Bir elektrotun Ag-AgCl referans elektrotu ile arasındaki empedansın genliğinin (modülünün) frekansla değişimi.....	27
Şekil 2.17.	Elektrot-elektrolit ve kuvvetlendiriciden oluşan sistem 2.17b. Sistemin basitleştirilmiş elektriksel eşdeğer modeli.....	28
Şekil 2.18.	Yüzey elektrotları a) Metal plaka b) Vakum pompalı c) Gezici tipten d) Tümüyle atılabilir e) Bükülebilir f) Kuru elektrotlar....	29

Şekil 2.19.	Dahili elektrotlar a) İğne elektrot b) Tel elektrot c) Tel halka elektrot.....	32
Şekil 2.20.	Mikroelektrotlar a) Cam muhafazalı b) Cam göbekli.....	32
Şekil 2.21.	Mikropipet elektrot.....	33
Şekil 2.22.	Mikroelektrot ile gerçekleştirilen ölçüm düzeninin basitleştirilmiş modeli.....	33
Şekil 3.1.	İşaretlerin sınıflandırılması .....	36
Şekil 3.2.	Rasgele süreç tarafından oluşturulan ayrık zaman Durağan süreç blok diyagramı .....	48
Şekil 3.3.	Lineer filtre yapısı.....	49
Şekil 3.4.	Süreç analizörü.....	50
Şekil 3.5.	Süreç üretici.....	52
Şekil 3.6.	Genel doğrusal süreç oluşturulması için tüm sıfır filtreye dayanan model .....	53
Şekil 3.7.	Genel doğrusal süreç oluşturulması için tüm kutup filtreye dayanan model.....	54
Şekil 3.8.	a) Sinüs dalgası b) Daubechies dalgacığı.....	56
Şekil 3.9.	ADD katsayıları ilişkisinin mozaığı.....	62
Şekil 3.10.	Fourier dönüşümü yapılmış bir işaretin farklı frekanslarda sinüs dalgaları.....	62
Şekil 3.11.	İşaretin yaklaşım ve ayrıştırma katsayılarına ayrılması.....	63
Şekil 3.12.	Yaklaşım ve ayrıştırma katsayılarının seyrekleştirilmesi.....	64
Şekil 3.13.	Gürültü eklenmiş sinüs dalgasının filtrelenmesi ve seyreltilmesi..	64
Şekil 3.14.	Dalgacık ayrıştırma ağacı.....	65
Şekil 3.15.	İşaretin çoklu seviye ayrıştırılması.....	65
Şekil 4.1.	Bir yapay sinir ağı örneği.....	67
Şekil 4.2.	Çok katmanlı ağ yapısı .....	71
Şekil 4.3.	Çok katmanlı ağlarda öğrenme .....	72
Şekil 4.4.	LVQ ağının topolojik yapısı .....	82
Şekil 4.5.	Girdi vektörüne en yakın ağırlık .....	85
Şekil 4.6.	Ağırlık vektörünü girdi vektörüne yaklaşması .....	85
Şekil 4.7.	Referans vektörü örneği .....	87
Şekil 4.8.	LVQ öğrenme prosedürünün geometrik gösterimi.....	88

Şekil 4.9.	LVQ öğrenmede ağırlıkların değişim yönü.....	88
Şekil 5.1.	Baş parmak fleksiyon hareketi.....	89
Şekil 5.2.	Başparmağın fleksiyon hareketine karşılık gelen EMG işaretleri..	90
Şekil 5.3.	Baş parmak addüksiyon hareketi.....	90
Şekil 5.4.	Başparmağın addüksiyon hareketine karşılık gelen EMG işaretleri .....	91
Şekil 5.5.	Parmakların abdüksiyonu hareketi.....	91
Şekil 5.6.	Parmakların abdüksiyonu hareketine karşılık gelen EMG işaretleri.....	92
Şekil 5.7.	Medtronic marka EMG kayıt cihazı.....	94
Şekil 5.8.	Ön kolda yerleşmiş yüzeysel flexorler kaslarına elektrotların bağlantısı.....	95
Şekil 5.9.	Hipotenar kaslarına elektrotların bağlantısı.....	95
Şekil 5.10.	1. Dorsal İnterosseus kasına elektrotların bağlantısı.....	96
Şekil 5.11.	Tenar kaslarına elektrotların bağlantısı.....	96

## TABLolar LİSTESİ

Tablo 4.1.	XOR Problemi.....	70
Tablo 4.2.	Çeşitli radyal temelli fonksiyonlar .....	79
Tablo 6.1.	5,10 ve 20. dereceden öz bağımlı model katsayıların öznelik vektörü olarak kullanıldığı 5,10 ve 20 giriş elemanı 2 çıkış elemanına sahip ileri beslemeli geri yayımlı yapay sinir ağı test sonuçları. Parametreler epoch=2000, lr=0.9, tf=logsig, btf=trainlm.....	98
Tablo 6.2.	5,10 ve 20. dereceden öz bağımlı model katsayıların öznelik vektörü olarak kullanıldığı 5,10 ve 20 giriş elemanı 2 çıkış elemanına sahip ileri beslemeli geri yayımlı yapay sinir ağı test sonuçları. Parametreler epoch=2000, lr=0.7, tf=logsig, btf=trainlm.....	98
Tablo 6.3.	5,10 ve 20. dereceden öz bağımlı model katsayıların öznelik vektörü olarak kullanıldığı 5,10 ve 20 giriş elemanı 2 çıkış elemanına sahip ileri beslemeli geri yayımlı yapay sinir ağı test sonuçları. Parametreler epoch=2000, lr=0.8, tf=tansig, btf=trainlm.....	98
Tablo 6.4.	Dalgacık tabanlı 5. dereceden öz bağımlı model katsayıların öznelik vektörü olarak kullanıldığı 5 giriş elemanı 2 çıkış elemanına sahip ileri beslemeli geri yayımlı yapay sinir ağı test sonuçları. Parametreler epoch=2000, lr=0.9, tf=logsig, btf=trainlm.....	99
Tablo 6.5.	Dalgacık tabanlı 5. dereceden öz bağımlı model katsayıların öznelik vektörü olarak kullanıldığı 5 giriş elemanı 2 çıkış elemanına sahip ileri beslemeli geri yayımlı yapay sinir ağı test sonuçları. Parametreler epoch=2000, lr=0.7, tf=logsig,	

	btf=trainlm.....	99
Tablo 6.6.	Dalgacık tabanlı 5. dereceden öz bağımlı model katsayıların öznitelik vektörü olarak kullanıldığı 5 giriş elemanı 2 çıkış elemanına sahip ileri beslemeli geri yayımlı yapay sinir ağı test sonuçları. Parametreler epoch=2000, lr=0.8, tf=tansig, btf=trainlm.....	99
Tablo 6.7.	Dalgacık tabanlı 10. dereceden öz bağımlı model katsayıların öznitelik vektörü olarak kullanıldığı 5 giriş elemanı 2 çıkış elemanına sahip ileri beslemeli geri yayımlı yapay sinir ağı test sonuçları. Parametreler epoch=2000, lr=0.9, tf=logsig, btf=trainlm.....	100
Tablo 6.8.	Dalgacık tabanlı 10. dereceden öz bağımlı model katsayıların öznitelik vektörü olarak kullanıldığı 5 giriş elemanı 2 çıkış elemanına sahip ileri beslemeli geri yayımlı yapay sinir ağı test sonuçları. Parametreler epoch=2000, lr=0.7, tf=logsig, btf=trainlm.....	100
Tablo 6.9.	Dalgacık tabanlı 10. dereceden öz bağımlı model katsayıların öznitelik vektörü olarak kullanıldığı 5 giriş elemanı 2 çıkış elemanına sahip ileri beslemeli geri yayımlı yapay sinir ağı test sonuçları. Parametreler epoch=2000, lr=0.8, tf=tansig, btf=trainlm.....	100
Tablo 6.10	Dalgacık tabanlı 20. dereceden öz bağımlı model katsayıların öznitelik vektörü olarak kullanıldığı 5 giriş elemanı 2 çıkış elemanına sahip ileri beslemeli geri yayımlı yapay sinir ağı test sonuçları. Parametreler epoch=2000, lr=0.9, tf=logsig, btf=trainlm.....	101
Tablo 6.11	Dalgacık tabanlı 20. dereceden öz bağımlı model katsayıların öznitelik vektörü olarak kullanıldığı 5 giriş elemanı 2 çıkış elemanına sahip ileri beslemeli geri yayımlı yapay sinir ağı test sonuçları. Parametreler epoch=2000, lr=0.7, tf=logsig, btf=trainlm.....	101
Tablo 6.12	Dalgacık tabanlı 20. dereceden öz bağımlı model katsayıların öznitelik vektörü olarak kullanıldığı 5 giriş elemanı 2 çıkış	

	elemanına sahip ileri beslemeli geri yayımlı yapay sinir ağı test sonuçları. Parametreler epoch=2000, lr=0.8, tf=tansig, btf=trainlm.....	101
Tablo 6.13	5,10 ve 20. dereceden öz bağımlı model katsayıların öznelik vektörü olarak kullanıldığı sp= 70 için radyal temelli yapay sinir ağı test sonuçları.....	102
Tablo 6.14	5,10 ve 20. dereceden öz bağımlı model katsayıların öznelik vektörü olarak kullanıldığı sp= 70 için radyal temelli yapay sinir ağı test sonuçları.....8.....	102
Tablo 6.15	5,10 ve 20. dereceden öz bağımlı model katsayıların öznelik vektörü olarak kullanıldığı sp= 90 için radyal temelli yapay sinir ağı test sonuçları.....	102
Tablo 6.16	Dalgacık tabanlı 5. dereceden öz bağımlı model katsayıların öznelik vektörü olarak kullanıldığı sp= 70 için radyal temelli yapay sinir ağı test sonuçları.....	102
Tablo 6.17	Dalgacık tabanlı 5. dereceden öz bağımlı model katsayıların öznelik vektörü olarak kullanıldığı sp= 80 için radyal temelli yapay sinir ağı test sonuçları.....	103
Tablo 6.18	Dalgacık tabanlı 5. dereceden öz bağımlı model katsayıların öznelik vektörü olarak kullanıldığı sp= 90 için radyal temelli yapay sinir ağı test sonuçları.....	103
Tablo 6.19	Dalgacık tabanlı 10. dereceden öz bağımlı model katsayıların öznelik vektörü olarak kullanıldığı sp= 70 için radyal temelli yapay sinir ağı test sonuçları.....	103
Tablo 6.20	Dalgacık tabanlı 10. dereceden öz bağımlı model katsayıların öznelik vektörü olarak kullanıldığı sp= 80 için radyal temelli yapay sinir ağı test sonuçları.....	104
Tablo 6.21	Dalgacık tabanlı 10. dereceden öz bağımlı model katsayıların öznelik vektörü olarak kullanıldığı sp= 90 için radyal temelli yapay sinir ağı test sonuçları.....	104
Tablo 6.22	Dalgacık tabanlı 20. dereceden öz bağımlı model katsayıların öznelik vektörü olarak kullanıldığı sp= 70 için radyal temelli yapay sinir ağı test sonuçları.....	104

Tablo 6.23	Dalgacık tabanlı 20. dereceden öz bağımlı model katsayıların öznitelik vektörü olarak kullanıldığı $sp=80$ için radyal temelli yapay sinir ağı test sonuçları.....	104
Tablo 6.24	Dalgacık tabanlı 20. dereceden öz bağımlı model katsayıların öznitelik vektörü olarak kullanıldığı $sp=90$ için radyal temelli yapay sinir ağı test sonuçları.....	104
Tablo 6.25	db3-7 tabanlı 20. dereceden öz bağımlı model katsayıların öznitelik vektörü olarak kullanıldığı $sp=112$ ve $sp=120$ için radyal temelli yapay sinir ağı test sonuçları.....	105
Tablo 6.26	5,10 ve 20. dereceden öz bağımlı model katsayıların öznitelik vektörü olarak kullanıldığı 9 gizli düğüme sahip LVQ yapay sinir ağının test sonuçları. Parametreler $lr=0,01$ , $lf=leranlv2$ .....	105
Tablo 6.27	Dalgacık tabanlı 5. dereceden öz bağımlı model katsayıların öznitelik vektörü olarak kullanıldığı 9 gizli düğüme sahip LVQ yapay sinir ağının test sonuçları. Parametreler $lr=0,01$ , $lf=leranlv2$ .....	105
Tablo 6.28	Dalgacık tabanlı 10. dereceden öz bağımlı model katsayıların öznitelik vektörü olarak kullanıldığı 9 gizli düğüme sahip LVQ yapay sinir ağının test sonuçları. Parametreler $lr=0,01$ , $lf=leranlv2$ .....	106
Tablo 6.29	Dalgacık tabanlı 20. dereceden öz bağımlı model katsayıların öznitelik vektörü olarak kullanıldığı 9 gizli düğüme sahip LVQ yapay sinir ağının test sonuçları. Parametreler $lr=0,01$ , $lf=leranlv2$ .....	106

## ÖZET

Anahtar kelimeler: Protez-yapay el, EMG, Öz bağımlı modeller, Dalgacık Dönüşümü, Yapay sinir ağları

Elektrokimyasal kökenli biyolojik işaretlerin varlığının fark edilmesinden bu yana birçok bilim adamı insana haiz mükemmel olan vücut hareketlerini inceleyip modellemeye çalışmışlardır. Yapılan çalışmalarda geliştirilen yeni teknikleri ve yöntemleri kullanarak kasların aktivasyonu sonucu ortaya çıkan ham miyoelektrik işaretleri(MES) faydalı hale getirmişler ve protez-biyonik uzuvların mekanik kısımlarını süren elektronik kontrolörlerde kaynak işareti olarak kullanmışlardır. Ayrıca teknolojinin gelişimiyle günlük hayatımızda çokça yer alan, başta otomotiv olmak üzere birçok endüstri alanında kullanılan ve yakın gelecekte hastanelerde evlerimizde de kullanılması beklenen robotlara da insana yakın el becerileri kazandırılmaya çalışılmaktadır.

Günümüzde kullanılan protez eller sınırlı hareket kabiliyetine sahiptirler. Gerçeğe yakın daha hünerli protez-yapay ellerin yapılabilmesi için şu üç konu üzerindeki çalışmalar sürecektir. Birincisi elin yeterli serbestlik derecesinde çalışabilmesini sağlayacak mekanik çözümler, ikincisi mekanik kısmın istenen kabiliyette ve hızda hareket etmesini sağlayacak elektronik devreler ve üçüncüsü bu kontrolör devreyi sürmesi için kullanılacak kaynak işaretin üretilmesi ve amaca uygun olarak kullanılmasıdır. Üçüncüsü, ham EMG işaretinden faydalı kaynak işaretin elde edilmesi ve amaca uygun kullanılmasıdır ki buda işaret işleme ve yapay zeka tekniklerinin gelişimine paralel olarak daha da iyileşecektir. Önem derecesine göre sıralamak gerekirse öncelikle 3. ve 2. problemler çözülmeyen daha gelişmiş protez – yapay uzuvlardan bahsedilemeyecektir.

Bu çalışmada yukarıda belirtilen problemlerden üçüncüsüne, yeni çözümler getirilmek istenmiştir. Bu amaçla protez-biyonik el çalışmalarında önem arz eden el hareketlerinden; nesnelere bilinçli kontrol altında amaca uygun kullanılmasını sağlayan bazı hareketler seçilerek bu hareketlerin konumlarına karşılık gelen elektromiyogram işaretleri kayıtlanmıştır. Daha sonra kayıtlanan bu ham elektromiyogram işaretleri, elektromiyogram işaretinin tabiatına uygun dalgacık dönüşümü tabanlı öz bağımlı modeller kullanılarak yapay sinir ağları ile sınıflandırılmıştır .



# **PROCESSING AND CLASSIFICATION OF EMG SIGNALS**

## **SUMMARY**

Key Words: Prosthesis–bionic hand motion control, EMG, Wavelet Transform, Autoregressive, Neural networks

Lots of researchers try to modelling perfect body motions since electrochemical basis biologic signals have been discovered. In many studies, raw Mioelectrical Signals (MES) which are consequent of muscle contraction become meaningful and useful via new technics and methods. This signals used for source signals for electronic devices drive mechanical parts of prosthesis-bionic limb. Also the development of technology in robotics field; researchers wants to bring robots in hand proficiency which are rarely used in automotive, surgery etc. areas.

Nowadays prosthesis hands used has limited activity ability. To compose more proficient prosthesis-artificial hands the studies must keep going on this three topics. The first one is mechanical solutions which supply the ability of freenes scale, second one is electronic circuits which are responsible for obtaning motion speed at desirable ability and the third one is to generate source signals which are used to drive this electronic circuits. The third one become better which is paralel with the improvement and development of signal processing and artificial intelligence technics. We couldn't talk about more developed prosthesis-artificial limbs unless third and second problems solved.

In this work, the aim is to make better and newer solutions for third problem. For this reason, motions which are used for controlling objects consciously are identified and Electromyogram signals which are used for talented some hand motions was recorded according to this consciously motions. After this recording stage; Wavelet Transform based autoregressive models that is suitable for signal nature and known as a good signal processing technic for Electromyogram used for analysis of signal. After that these signals are classified by neural networks.

## BÖLÜM 1. GİRİŞ

İnsanoğlunu diğer sıcakkanlı memelilerden ayıran en önemli farklardan birisi hünerli el hareketleridir. El ve parmakların amaca uygun kullanılması ile birçok ince ölçekli hareket başarı ile gerçekleştirebilmektedir. Bu hareketler arasında; yazı yazmak ve obje kullanmak gibi kendini ifade edici eylemler ile öz bakımını sağlamak ve üretken olmak gibi fonksiyonları sağlayan işlevler de bulunmaktadır. Günlük hayatımız boyunca ellerimizi ve parmaklarımızı ne kadar çok kullandığımız düşünülürken, çeşitli nedenler ile eli amputé olmuş (kesilmiş) insanların; insanı insan yapan el becerilerini kısmi de olsa yeniden kullanabilmelerine imkan verecek olan gelişmiş protez el tasarımlarına duydukları ihtiyaç daha iyi anlaşılacaktır.

Elektrokimyasal kökenli biyolojik işaretlerin varlığının fark edilmesinden bu yana birçok bilim adamı insana haiz olan son derece mükemmel olan vücut hareketlerini inceleyip modellemeye çalışmışlardır. Yapılan çalışmalarda zaman içinde geliştirilen yeni teknikleri ve yöntemleri kullanarak kasların aktivasyonu sonucu ortaya çıkan ham miyoelektrik işaretleri(MES) faydalı hale getirmişler ve bu işaretleri, protez-biyonik uzuvların mekanik kısımlarını süren elektronik kısımlarda kaynak işareti olarak kullanmışlardır. Ayrıca teknolojinin gelişimiyle günlük hayatımızda çokça yer alan, özellikle başta otomotiv olmak üzere birçok endüstri alanında kullanılan ve yakın gelecekte hastanelerde ve hatta evlerimizde de kullanılması beklenen robotlara da insana yakın el becerileri kazandırılmaya çalışılmaktadır.

Bu tasarımların, gerçek fizyolojideki işlevselliği ne kadar doğru modeller iseler; fonksiyonel geri kazanım da o kadar etkin olacaktır. Buradan hareket ile; el parmaklarının obje kullanmak sırasında aldıkları pozisyonlar ile bu pozisyonları sağlayan kasların aktivitelerinin protez – yapay el tasarımında dikkate alınması, normal fizyolojinin modellenmesi aşamasında en büyük katkıyı sağlayacaktır.

Günümüzde kullanılan protez uzuvlar, özellikle protez eller sınırlı hareket kabiliyetine sahiptirler. Gerçeğe yakın daha hünerli protez-yapay ellerin yapılabilmesi için şu üç konu üzerindeki çalışmalar soluksuz sürecektir. Birincisi elin yeterli serbestlik seviyesinde çalışabilmesini sağlayacak mekanik çözümler, ikincisi mekanik kısmın istenen kabiliyette ve hızda hareket etmesini sağlayacak elektronik devreler ve üçüncüsü bu kontrolör devreyi sürmesi için kullanılacak kaynak işaretin üretilmesi ve amaca uygun olarak kullanılmasıdır. Üçüncüsü, ham EMG işaretinden faydalı kaynak işaretin elde edilmesi ve amaca uygun olarak kullanılmasıdır ki buda işaret işleme tekniklerinin ve yapay zeka tekniklerinin gelişimine paralel olarak daha da iyileşecektir. Önem derecesine göre sıralamak gerekirse 3. ve 2. problemler çözülmeyen daha gelişmiş protez – yapay uzuvlardan bahsedilemeyecektir.

Bu çalışmada yukarıda belirtilen problemlerden üçüncüsüne, yeni ve daha iyi çözümler getirilmesi amaçlanmıştır. Bu amaçla protez-biyonik el çalışmalarında önem arz eden nesnelere bilinçli kontrol altında amaca uygun kullanılmasını sağlayan hareketlerden bazıları seçilerek bu hareketlerin konumlarına karşılık gelen elektromiyogram işaretleri kayıtlanmıştır. Daha sonra kayıtlanan bu ham elektromiyogram işaretleri, elektromiyogram işaretinin tabiatına uygun dalgacık tabanlı öz bağımlı modeller kullanılarak yapay sinir ağları ile sınıflandırılmıştır. Yapılan bu çalışma ile insan el hareketlerini, protez-yapay el tasarımlarına kazandırma çalışmalarına katkı sağlamak istenmiştir.

### **1.1. İlk Yapılan Çalışmalar**

Miyoelektrik kontrol çalışmaları ilk olarak Münih Üniversitesi fizik bölümü öğrencisi Reinhold Reiter tarafından yürütülmüştür. Reiter'in araştırmalarının ilk bulguları 1945 yılında belgelendi [1]. Reiter'in tek yayını "Ampüte olmuş(uzvu kesilmiş) fabrika çalışanları için protez kol tasarımı" ismi ile Alman tıp gazetesinde yayınlanmıştır [2]. Bu prototip aynı yıl Hannover Export fuarında gösterildi. Aygıtın baş araştırmacısı Bavarian Kızılhaçı tarafından özel finansla desteklendi [2]. Reiter'in proje işletmecisi Pudluský, 1948 yılında Alman para birimindeki reform sonrası fonların kesilmesiyle projenin geliştirme faaliyetlerinin sonlandırıldığını not etmiştir [1]. Bu ilk protez katlanabilir değildi. Protezin kontrol ünitesi vakum tüp

kullandığından çok fazla elektrik enerjisi gerekiyordu ve elektrikli el kısmı oldukça yeteneksizdi. Bu yüzden protez kablolu olarak imal edilmişti. Bu haliyle belki fabrikanın iş istasyonlarında kullanılabilirdi fakat bu günlük yaşamın genel aktivitelerini çok azı yerine getirilebilirdi. Reiter'in kontrol sisteminin arkasındaki fikir, selenoid ile harekete geçirilecek tahta elin kontrolünü, kasların kasılmasından elde edilen kuvvetlendirilmiş miyoelektrik sinyaller ile yapmaktı. Reiter bu çalışmada kolun kalan kısmındaki tek kas bölgesini kullandı. İki farklı kasılma ritmi kullanarak, açma-kapama hareketlerinin kontrolünü sağladı [3]. Reiter'in çalışmaları denetlenebilir değildi. 1947'lerde miyoelektrik işaretler monitörlerde uyarıcı olarak görüntüleniyordu. 1957'e kadar çocuk felci için kullanılan bir cihazın kontrolünde kullanıldı [4] [5]. Reiter'in fikirleri, yapılan ilk ulusal çalışmalarda birbirinden bağımsız ve lüzumsuz bir şekilde çokça yeniden türetiliyordu. 1970'li yıllara kadar İngiltere'de Bottomley, Amerika'da; Kaliforniya üniversitesinde Weltman ve Lyman, bir grup araştırmacı Massachusetts enstitüsünde, Yugoslavya'da; Vodovnik, Tomovic ve Rakic, Gavrilovic ve Maric, Kanada'da; Gustav'ın liderliğinde bir araştırma grubu, Yine Rusya'da bir grup araştırmacı Reiter'in protez kol çalışmasının eksik taraflarını gidermek için değerli çalışmalar yaptılar. Bu grupların bir kısmı zaman zaman işbirliğine gittiler [6].

## 1.2. Son Yapılan Çalışmalar

Son zamanlarda işaret işleme teknikleri ve yapay zeka tekniklerinin gelişimine paralel olarak yapılan çalışmalar ile ilk yapılanlardaki eksiklikler giderilip yetenekli sayılabilecek protez uzuvlar geliştirilmiştir. Ama yine de çok karmaşık bir yapıya sahip olan insan hareketlerini tam olarak modelleyebilmenin mümküniyetinin ne olduğu aşikârdır. Modellenecek uzuv fonksiyonlarının kaynağı insanoğlu olduğundan, çalışmaların başarısı öncelikle insan vücudununun fizyolojisini çok iyi tanımlamaktan geçmektedir. Yapılan tüm çalışmalarda mevcut bilgi ve imkanlar dahilinde kısıtlar konularak protez uzuva kazandırılmaya çalışılacak olan hüner belirlenmektedir. Yukarıda bahsettiğimiz protez uzuv probleminin üçüncüsün çözümüne yönelik son yıllarda yapılan çalışmalardan bazıları şunlardır. Syhu ve ark.'ları 9 erkek ve 2 kadından yüzey elektrotlarla 11 el hareketine karşılık alınan EMG işaretlerini DD(Dalgacık dönüşümü) ile işleyerek YSA(Yapay sinir ağları) ile

sınıflandırmada kullanmışlardır. Ayrıca çalışmalarında TBA(Temel bileşenler analizi) ve BBA(Bağımsız bileşenler analizi)'yı kullanarak kullanılan kanal sayısını 7'den 4'e düşürmüşlerdir [7]. Mahdi ve ark.'ları yüzey elektrotlarla alınan EMG işaretlerini TBA'da boyut azaltarak Bulanık sınıflayıcı ile sınıflandırma işlemi yapmışlardır [8]. Ziheng ve ark.'ları yüzey elektrotlarla ön koldan alınan EMG işaretlerinin güç spektrumu katsayılarını ve Bayes istatistiksel algoritmasını kullanarak sınıflandırma işlemi yapmışlardır. Çalışma sonucu % 84 oranında doğrulukla sınıflama yapmışlardır [9]. Wang ve ark.'ları 2 serbestlik dereceli, duyu sensörüne sahip biyonik yapay el tasarlamışlardır. Bu çalışmada Yapay elin parmaklarına tutturulmuş cisme duyarlı, duyu sensörü iyi derecede dinamik cevap yeteneğine sahiptir. Geliştirilmiş güç spektrumu algoritması ve istatistiksel bayes tabanlı data birleştirme kullanılarak el hareketleri tanınmaya çalışılmıştır [10]. Sharif teknoloji üniversitesinden Khezri ve ark.'ları yüzey elektrotlarla 6 el hareketine karşılık aldıkları toplam 600 adet EMG işaretini DD(Dalgacık dönüşümü) ile işleyerek YSA(Yapay sinir ağları) ve Bulanık Mantık algoritmalarından oluşturdukları hibrid bir sınıflandırıcı ile sınıflandırmışlardır [11]. Harbin enstitüsünden Zhao ve ark.'ları 3 kanallı EMG cihazı ile 3 kas grubundan yüzey elektrotlarla aldıkları EMG işaretlerini kullanarak 6 el hareketini dalgacık dönüşümü ve öz bağımlı modelleri kullanarak çeşitli öğrenme değerleri için LM öğrenme algoritmalı yapay sinir ağları ile sınıflandırmaya çalışmışlardır. Sınıflandırma sonucunda bazı hareketler için Öz bağımlı modelli yapay sinir ağları bazı hareketler için dalgacık dönüşümlü yapay sinir ağlarının başarılı olduğunu görmüşlerdir [27].

## **BÖLÜM 2. ELEKTROMİYOGRAM İŞARETİ VE ÖLÇÜLMESİ**

Elektromiyogram (EMG), kasın kasılması sonucu ortaya çıkan biyopotansiyel işaretlerdir. Elektromiyogram işaretlerin kaynağı vücutta meydana gelen çeşitli elektrokimyasal olaylardır. İstemli kas hareketleri, beyinde oluşan aksiyon potansiyellerinin sinirler yoluyla kasa iletilmesi sonucu ortaya çıkar.

İskelet kaslarının fonksiyonel olarak temel birimi, motor ünitelerdir. Gevşek demetlerde motor ünitesinin bileşenleri boyunca uzanır. Çeşitli motor ünitelerinin lifleri iç içe durumda bulunmaktadır. Tek bir motor ünitesinden uyarılma sonucu, iğne elektrotlarla elde edilen hücre dışı potansiyel değişimleri 3–15 ms arasında sürer ve motor ünitesinin büyüklüğüne bağlı olarak genliği 20–2000 mV'dur. Deşarj frekansı genellikle saniyede 6–30 darbe arasındadır.


EMG kayıtlamada yüzey elektrotlar kullanılmakla birlikte kas içine doğrudan girilmesi gereken uygulamalarda iğne elektrotlar kullanılır. İşaretlerin kuvvetlendirilmesinde fark kuvvetlendiriciler kullanılır.

EMG işaretinin bilgisi kaslarda harcanan güce, elektrotların yerleşimi gibi faktörlere bağlıdır. Tek fibere batırılan iğne elektrot ile sadece o fibere ait potansiyel ve gürültü ölçülür iken, yüzey elektrotlarla yapılan ölçümlerde elektrotların yerleştirildiği bölgedeki örtüşmüş kasların gürültüsü ve potansiyellerinin ortalaması ölçülecektir. Bununla birlikte yüzeydeki kasların faaliyeti alttan gelen bilgiyi maskelediğinden yüzey elektrotların sadece yüzeydeki kasların incelenmesinde kullanılması uygundur. Tek kutuplu(monopolar), çift kutuplu(bipolar) ve çok kutuplu(multipolar) şekillerde geliştirilmiş batırma(iğne) tipi elektrotlar genellikle derinlerdeki kasların ve ya tek bir motor ünitesinin elektromiyogramının ölçülmesinde kullanılırlar.

Elektromiyografi ise kaslardaki kasılıp gevşemeleri saptamak için kasların elektriksel aktivitelerini yani EMG'yi kayıtlamak, kas içinde kendiliğinden var olan aksiyon potansiyellerinin veya motor ünite tahribatlarının sezildiği yerlerde gönüllü katılımlar ile ateşlenen kasların potansiyellerini hoparlör ve osiloskop vasıtasıyla göstermek veya sinir uyarısı ile kasların kasılması sırasında sinirlerde ki elektriksel aktiviteleri kayıtlamak için kullanılan bir enstrümandır [12].

Elektromiyografi sinir-kas işlevi, sinir-kas durumu, sinir tahriplerinin büyüklüğü, refleks cevapları ve benzeri konularla ilgili çalışmalarda kolaylık sağlayan bir enstrümandır.

EMG işaretleri günümüzde kas-sinir hastalıkları teşhisi gibi klinik uygulamalarda, uzuv kesilmelerinde kesik yere takılan protez uzuvların miyoelektriksel kontrollerinde kaynak işaret olarak kullanılmaktadır. Protez uzuv uygulamalarında, kesilmiş ya da tahrip olmuş kasların EMG işaretleri ile kişiye özel tasarlanmış mekanik uzuv uyarılarak hareket sağlanır. Tipik bir EMG işareti Şekil 2.1'de gösterilmektedir.



Şekil 2.1. Elektromiyogram (EMG) işareti

Kelime anlamı itibariyle, elektriksel aktivite ile ilgili olarak “electro”, Yunanca “muscle” kökünden gelen “myo” ve kayıt miktarı anlamına gelen “gram” terimlerinden oluşan Elektromiyogramın tarihsel gelişimine bakıldığında 1666 yılında İtalyan hekim Francesco Redi’nin kaslarda elektrik üretimini ilk olarak fark eden bilim adamı olduğu kayıtlarda yer almaktadır. Galvani 1791’de kurbağının gastrocnemius kası üzerinde çalışarak kas kasılmasıyla elektrik üretimi arasında bir ilişki olduğunu gözlemlemiştir. Alman bilim adamı Alexander von Humboldt(1769-1859) ilk elektrotları tasarladı ve birçok deneyde uyarıcı olarak denedi. Johannes S.C. Sweigger 1820’de Oersted manyetizması temelli ilk pratik galvanometreyi yaptı. 1900’lü yıllara kadar teknolojinin gelişimine paralel olarak bu alanda çalışmalar yapıldı [13]. H.Piper 1912 yılında Almanya da tel galvanometre ile çalışma yapan EMG araştırmacılarından. 1924 yılında Gasser ve Erlanger benzer çalışmaları osiloskop kullanarak yapmışlardır. 4 yıl sonra Proebster bu işaretlerin denervated kaslar tarafından üretildiğini gözlemlemiş ve klinik EMG’nin alanını açmıştır. 1929 yılında Adrian ve Bronk’un geliştirdiği ortak merkezli iğne elektrotu hala EMG çalışmalarında geniş bir kullanım alanı olan güçlü bir araçtır. Motor ünite aksiyon potansiyeli nicel analiz ve metotlarının (MÜAP) geliştiricileri olarak anılan Kugelberg, Petersen, Buchtal, Guld, Gydikov, Kosarov, Pinelli, Rosenfalck ve Stalberg vakum tüpü yükselticileri ve daha sonra katı hal devrelerini on yıllarca kullandılar. Devrin birçok çalışması arasında Denny-Brown’un 1949 yılındaki “EMG işaretlerinin yorumu” çalışması sözü edilen çalışmalardandır. Uchizono 1953 yılında kara kurbağasının sartorius kasındaki işaretlerin yayılımını tanımlamıştır. Willison 1964 yılında EMG işaretlerinin genlik analizini yapmıştır. Şu an 5. baskısı yayında olan ve kilometre taşı sayılan J.V. Basmajian tarafından yazılan “Muscles alive ” adlı kitabın ilk baskısı 1962 yılında yayınlanmıştır. 1979 yılında EMG işaretlerinin fizyolojisi ve matematiğini birleştiren De Luca tarafından yayımlanan makale bu konuda bir ilk olup EMG içerik bilgisi ve çıkarımı ile ilgili temel bir yaklaşım oluşturmuştur.

EMG çalışmalarında bilgisayarların kullanımı modellerin gelişimi ve simülasyon yöntemlerinin kullanımını kolaylaştırmıştır. 1970’ler ve 1980’lerde birçok grup ve araştırmacı bu konuyla ilgilenmiş, yayınlar yayınlamış ve bu alanda oldukça gelişme kaydedilmiştir. Dimitrova ve Lindstrom modelleme alanının öncülerindedir.



Bu modeller EMG işaretinin biyofiziğinin anlaşılmasına oldukça katkı sağlamış ve böylece işaretin içerdiği bilgilerin çıkarımını kolaylaştırmıştır. Ayrıca bu modeller iyi bir eğitim aracı olmakla birlikte mevcut uygulamalar ile yeni uygulamaların geliştirilmesiyle uğraşan uzmanlar için temel çalışma kaynağıdır. EMG işaretlerinin ilk ve doğal alanlarından biride protez kontrolüdür. Miyoelektrik kontrol olarak da bilinen ve ilk olarak 1940'larda açılan bu alan 1960, 1970 ve 1980'lerde hızla gelişmiştir. Potansiyel ile eşzamanlı çalışan çok fonksiyonlu EMG örüntüsü temelli protezler güncel ve gelişen bir alandır.

J.V. Basmajian, S. Carlsöö, B. Johnson, M. MacConaill, J. Pauly ve L. Scheving 1965 yılında yaptıkları toplantıda uluslararası Elektromiyografi ve Kas bilimi topluluğunu (The International Society of Electromyography and Kinesiology) kurmayı kararlaştırdılar ve 1966 yılında ISEK'i resmileştirdiler. Bu topluluk EMG ilgili toplantılar, konferanslar ve sempozyumlar organize etmektedir. 1988 yılında EMG araştırma sonuçlarının bir dergide yayınlanması önerisi ISEK konseyi tarafından kabul edilmiştir. Electromyography and Kinesiology dergisinin ilk sayısı 1991 yılında yayınlanmıştır.


1995 yılında bir grup araştırmacının önderliğinde ve Avrupa Birliğinin katkılarıyla Kasların Noninvasive Değerlendirilmeleri için Yüzeysel EMG (Surface EMG for Noninvasive Assesment of Muscles) projesi hazırlanmış ve 1996 yılında finanse edilmiştir. SENIAM'ın amacı; bu konularda çalışan laboratuvarların kabul edilebilir bir seviyeye getirilmesidir. Bilgisayar girdili aygıtların kullanımı ile sinir-kas bozulmalarını önleme(Prevention of Neuromuscular Disorders in the Use of Computer Input Devices) isimli çalışma ise Avrupa Birliği tarafından finanse edilen ikinci anlaşmadır [14].

## **2.1. Kasların Yapısı**

İskelet kasları fiber denilen ince uzun hücrelerden meydana gelmiştir. Uzunlukları 1–50 mm ve çapları 10–100 µm arasındadır. Dış yüzeyleri sakrotenma denilen bir kılıf ile örtülmüştür. Bu lifler, bağlayıcı(kıkırdak) dokuya bağlıdırlar. Kasın kasılması, liflerin kısalıp şişmesi ile olur. Kaslara besin, kan damarları ile uyarı ise sinirlerle

götürülür. Kasın kasılması anında bir seri kimyasal reaksiyon olur. Bu reaksiyonlar için gerekli aktomyosin proteini, kandaki hemoglobine benzer biçimde oksijen depolayan myoglobin, enerji tasarrufu için gerekli fosfatlar ve yakıt olarak gylcogen şeklinde kasta bulunur. Kaslar çizgili(striated), düz(smooth) ve kalp kasları olmak üzere 3 tiptir.

Çizgili Kaslar; İstemli hareketi sağlayan iskelet kaslarıdır. Mikroskop altında yapılan incelemelerde açık renkli ve koyu renkli bandlar gözlenmiştir. Koyu banda A, açık banda I bandı denir. A bandının ortasında açık H bandı ve I bandının ortasında koyu Z bandı vardır. Z bandları arasındaki bölge kasılma anında daralır. A bandı sabit kalır, H ve I bandları ise daralır. Kasın proteinin actomyosinin myosin bileşeni A'da bulunur. Actin ise Z bandında başlayıp H bandında biter.



Şekil 2.2. Çizgili kaslarda A, H, Z ve I bandları (Yazgan, Korürek 1996)

Düz Kaslar; Bu kaslar, istemsiz hareket kasları olup sindirim sistemi, idrar yolları ve kan damarları etrafında bulunurlar. Lifleri kısadır. Otonom sinir sisteminin sempatik ve parasempatik kontrolleri altındadır.

Kalp Kasları; Bu kaslar çok gelişmiş istemsiz kaslardır. Kalın ve kısa liflerden meydana gelen çok yoğun bir ağ gibidir. Sinirsel uyarı olmadan kasılabilirler. Sinirsel uyarı, kasılma zamanını etkiler.

### 2.1.1 Kas kasılması

Kas lifi uyarıldığında kasılır. Gerekli uyarı motor siniri ile gelir. Kas, elektrik akımı gibi bir uyarıya da cevap verir. Kasın kasılması, boyunun sabit kalıp, sadece şişmesi şeklinde statik(izometrik) veya hem boyunun kısalması hem de şişmesi şeklinde dinamik(izotonik) olabilir. Kısa bir uyarı uygulandıktan sonra bir zaman gecikmesi ile önce kasılma ve bundan sonra bir gevşeme oluşur.

Kimyasal olarak kasın kasılması kısaca şöyle özetlenebilir: Kas aktif duruma geçtiğinde glikojen depoları boşaltılır, oksijen kullanımı ile karbondioksit meydana çıkar. Kas glikojeni pruvik aside parçalanırken yüksek enerjili ATP (Adenazin trifosfat) moleküllerinde depolu enerji açığa çıkar. Pruvik asidin tekrar oksitlenmesi ile sitrik asit çevriminde CO<sub>2</sub> ve H<sub>2</sub>O ile yeni ATP molekülleri oluşur. Oksijen yetersizliği durumunda ise pruvik asitten anaerobik reaksiyonla laktik asit üretilir ve yeni enerji açığa çıkar.

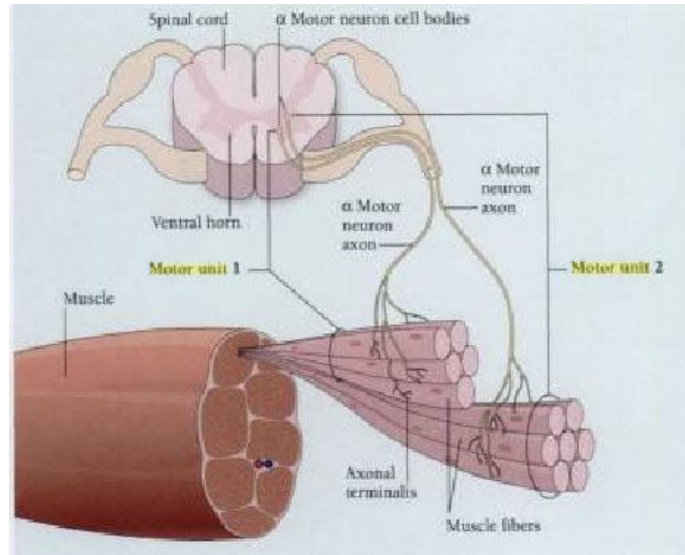
Egzersizden sonra artmış olarak devam eden solunum ile sağlanan fazla oksijen alımı, oksijen açığını kapatır. Laktik asidin beşte biri oksitlenerek CO<sub>2</sub> ve su ile enerji açığa çıkar ve bu enerji ile laktik asidin geri kalan kısmı glikojene dönüşür. Kasın aktif olduğu zaman üretilen enerjinin bir kısmı mekanik enerjiye, bir kısmı da ısı enerjisine dönüşür. Kasın enerji verimi en fazla % 25'dir. Yani enerjinin en az dörtte üçü ısı enerjisi olarak kaybolur. Motor sinirlerin kas lifine ulaştığı noktaya motor uç plakları adı verilir. Motor sinirinden motor uç plakalarına bilgi geldiğinde acetylcholine salgılanarak kas uyarılır. Bazı düzgün kaslar ise kimyasal haber ileticisi olarak noradrenaline kullanırlar.

Kalp kasları, enerjilerini glikozdan değil yağdan sağlar. Böylece kandaki glikoz oranından etkilenmezler. Düz kaslar kontrol ettikleri organı bir ağ gibi sarar. Onların daralıp kasılmaları ile organda hareket meydana gelir. Buna peristaltik hareket denir. Vücudun hareketsiz olduğu anlarda bazı kaslar, izometrik olarak gergin olup, yerçekimine karşı koyarlar.

### 2.1.2. Motor ünite ve motor hareketi

Motor ünite kas fonksiyonunun biyolojik ünitesidir. Bir motor ünitesi, merkezi sinir sisteminden gelip motor uç plakalarına dağıtılan bir motor sinirine sahiptir. Uç plakaların her biri bir kas lifine bağlanmıştır ve onların uyarılması ile bağlı buldukları kas lifleri de uyarılır.

Motor ünitelerin adedi vücudun muhtelif bölgelerindeki kaslar için birbirinden farklıdır. Genellikle kas büyüdükçe motor ünitelerin sayısı artar. Motor ünitesinin büyüklüğü, yani aynı sinir lifi tarafından uyarılan kas liflerinin adedi, çeşitli kaslar için birbirinden çok farklıdır. İnsanda bir motor ünitesinde 25 ile 2000 kas lifi bulunabilir. Bir motor ünitesi tarafından üretilen kuvvete karşılık gelen ağırlık 0,1 – 250 gram arasında değişebilir. Aynı üniteyi oluşturan lifler bir araya toplanmış olmayıp çeşitli ünitelerin lifleri içe içe girmiş haldedirler.



Şekil 2.3. Sinir-Kas (neuromuscular) fizyolojisi (Stanley 2006)


Motor sinirleri yapı itibariyle sinir hücrelerinden meydana gelir. Böylece her bir motor siniri polarize yada depolarize durumda olabilir ve motor uç plakalarına iki seviyeli var yada yok bilgisi gönderir. Böylece her bir kas lifi de ya dinlenme durumunda yada uyarılmış durumda bulunur. Normal kas hareketinin özelliği, hareketinin yumuşaklığı, devamlılığı ve hassasiyetidir. Bu özellikler herhangi bir

kasın birçok motor ünitesinden meydana gelmesindedir. Kas hareketinin büyüklüğü ile orantılı sayıda motor ünitesi faaliyete geçer.

Kas hareketinin büyümesi ile birçok motor ünitesi faaliyete geçer ve hepsinin faal olduğu zaman kas hareketi en üst düzeydedir. Böylece harekette bir miktar düzgünlük sağlanmış olur. İlave hareket düzgünlüğü de birim zamanda uyarılan kas liflerinin adedi modüle edilerek sağlanır. Her bir motor ünitesi sadece bir kasılma seviyesi verebilse de birim zamandaki kasılma sayısı yani motor uç plakalarınca birim zamanda yapılan depolarizasyon ve repolarizasyonun sayısı kas liflerinin gücünü artıracaktır. Böylece bir kasın hareketinin düzgünlüğü, hem uyarılan motor ünitelerinin sayısı hem de bu motor ünitelerin uyarılma hızı ile kontrol edilir.

### 2.1.3. Kaslarda servomekanizma

Kas hareketini kontrol eden sinir sisteminin basitleştirilmiş blok şeması Şekil 2.4.'de gösterilmiştir.



Şekil 2.4. Kaslarda Servomekanizma (Yazgan, Korürek 1996)

Sistem, bir servomekanizma kontrol sistemidir. Bir duyu alıcısı, bir hız veya konum işareti üretir. Bu işaret duyu siniri ile beyne iletilir. Beyin hafızadaki bilgi ile gelen bilgiyi karşılaştırarak bir hata (kontrol) işareti üretir. Bu işaret motor siniri ile kasa gönderilerek onun hareketi kontrol edilir.

Bu servo sistemin çalışması basit bir örnekle açıklanabilir. Bir insan parmağını soğuk bir cisme değdirdiği zaman, parmaktaki duyu alıcıları sıcaklığı algılar ve beyne gönderir. Beyin bu işaretin soğuktan geldiğini anlar ve motor siniri ile kası harekete

geçirmesi gerekmez. Şayet parmak sıcak bir cismin üzerine konmuşsa, beyin duyu sinirleri ile gelen bilgiden parmağın sıcak bir cisim üzerinde olduğunu anlar. Eğer cisim çok sıcak ise motor sinirleri ile kol kaslarına gerekli bilgiyi gönderip parmağın sıcak cismin üzerinden çekilmesini sağlar. Duyu alıcılarının sıcak cisimi hissetmeleri ile parmağın kaldırılması arasında birkaç yüz ms'lik bir zaman gecikmesi vardır. Bu gecikme daha ziyade şahsın o sıcak cisme gösterdiği ilgi ile de ilgilidir. Şimdi, parmağın çok sıcak bir cisim üzerine değdirildiğini düşünelim. Bir refleks cevap ile parmak, 150 ms civarında bir sürede cismin üzerinden kaldırılır.

### **2.1.3.1. Refleks cevap**

Acil çıkış kapısı (Bkz. Şekil 2.4.) normal durumda olaya karışmaz. Acil kapısı genellikle omurilikte bulunur. Duyu alıcılarından kuvvetli bir işaret algılandığında refleks cevap ortaya çıkar. Bu durumda acil kapısı beyin yolunu köprülüyerek kasın hızlı hareket etmesini sağlar. Refleks cevap sayesinde vücut tehlikelere karşı korunmuş olur.

### **2.1.3.2. Kas hareketi sırasında üretilen gerilim**


Bir duyu alıcısı uyarıldığında, duyu sinir lifi boyunca yürüyen bir depolarizasyon dalgasını (aksiyon potansiyelini) oluşturur. Bu darbe dizisi beyine ulaşır. Buna cevap olarak beyin de, motor uç plakalarının depolarizasyonuna neden olan uyarıyı, motor sinirleri boyunca propagasyon yapan aksiyon potansiyelleri şeklinde kasa gönderir. Motor uç plakalarının depolarizasyonu kas lifi içindeki hücreleri depolarize eder ve lifler kasılır.

Kaslarla ve sinirlerle uğraşırken, mikro elektrotlarla hücre potansiyellerinin ölçümü pek nadir yapılır. Genel olarak bir motor ünitesi gibi az sayıdaki hücrelerin net potansiyel değişiminin ölçümü iğne elektrotlarla, birçok motor ünitesinin oluşturduğu toplam potansiyelinin ölçümü ise yüzey elektrotları ile yapılır. Eğer bir mikro elektrot hücrenin içine batırılarak ölçme yapılırsa hücrenin tüm faaliyetinin 1 ms'den daha az olduğu görülür. Eğer, iğne elektrotlar bir hücrenin yakınına yerleştirilirse çevredeki hücrelerden gelen değişimleri de algırlar. Aynı motor

ünitesine bağlı kas lifleri, motor uç plakalarına gelen sinir dalları ile hemen hemen aynı zamanda uyarıldığı halde, hücrelerin depolarize durumda kalış sürelerindeki farklılıklar ve ayrıca kas liflerine gelen sinir dallarının uzunluk farklılıklarından dolayı (bazı kas liflerine uyarı diğerlerinden biraz daha önce ulaşmış olur) bir motor ünitesindeki değişim süreci 2 ila 5 ms arasındadır. Bu asenkron durum, kas hareketinin düzgünlüğüne katkıda bulunur.

### 2.1.3.3. Kas kasılmasının regülasyonu

Motor ünitenin her bir kasılması sabit bir kuvvet oluşturur. Bütün kasın hareketi, kasılma frekansındaki bir değişme ve motor ünitelerinin ilavesiyle sağlanır. Kasın hareket ettirdiği organın hassas hareketi, kastan, merkezi sinir sistemine ulaştırılan bir geri besleme işareti yardımıyla sağlanır. Kaslardaki duyu algılayıcı(reseptör) elemanlar kas mekiği(muscle spindles) adını alır. Bunların bünyesinde kendilerine ait kas fiberleri vardır. Şekil 2.5.'de kas iğinin yapısı görülmektedir.



Şekil 2.5. Kas iğinin yapısı (William 2006)


Merkezi sinir sistemine bağlı efferent gamma sinir fiberleri olarak isimlendirilen motor sinirleri yardımıyla, istenilen kasılma derecesi sağlanacak şekilde iğın uzunluğu ayarlanır. Kas iğini merkezi sinir sistemine bağlayan efferet sinir fiberleri, arzu edilen ve gerçek değerler arasındaki fark değeri merkezi sinir sistemine ulaştırırlar. Bu geri besleme ile kasın kasılması regüle edilir. Ayrıca eklem yerlerinde, eklem durumunu ve hareketinin hızını merkezi sinir sistemine

ulaştırarak kasın kontrolünü sağlayan reseptörler vardır. Bu reseptörler yardımıyla uç organların büyük bir hassasiyetle hareket ettirilmeleri sağlanır.

#### 2.1.4. Kas kasılmasının sırasında oluşan gerilim

Tek bir motor ünitesinden elde edilen EMG işaretinin şekli, hastalık yada yorulmanın etkisiyle oldukça değişir. Periferik(çevre) nöropatilerinde(sinir bozulması), kasın kısmen sinirsel uyarıyı alamaması söz konusu olabilir. Sinirler kendilerini yenileyebilen dokular olup bu durumdan sonra düzelme mümkündür. Kendini yenileyen sinir liflerindeki iletim, sağlıklı sinir liflerinden daha yavaştır. Ayrıca, çoğu periferik nöropatilerde nöronların uyarılabilirliği de değişebileceğinden sinirsel iletim hızında genel bir yavaşlama görülür. Bunun bir sonucu olarak, EMG şeklinde bir dağılıma ve senkronluğun bozulması ortaya çıkar.

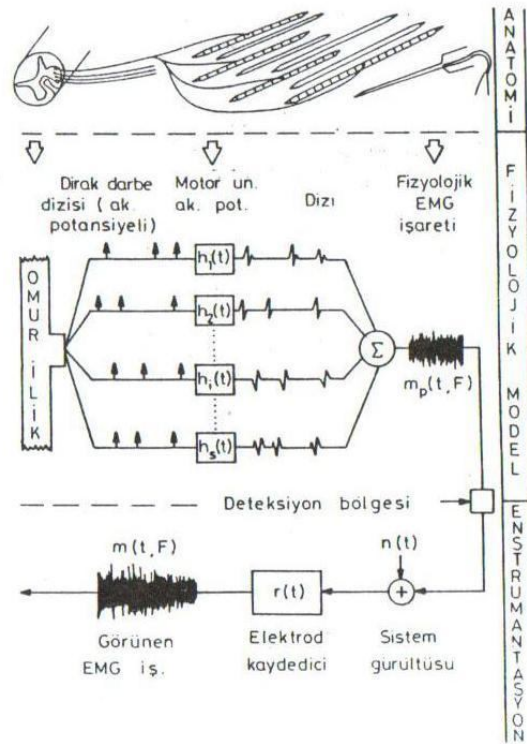
Şekil 2.6.'da normal bir interosseus dorsalis kasının çeşitli kasılmalarında ürettiği motor ünite potansiyelleri görülmektedir. Hafif kasılma durumunda tek bir motor ünitesinin faaliyeti ayırt edilebilirken kuvvetli kasılmalarda bu mümkün değildir. Çünkü birçok motor ünitesinin faaliyeti üst üste binmiştir. Kasın kasılması kademeli olarak artarken aktif motor ünitelerinin uyarma frekansları da artar ve yeni motor üniteleri devreye girer.



Şekil 2.6. Normal bir dorsal interossus kasının çok azdan çok kuvvetliye kadar kasılması anlarında üretilen potansiyeller (Yazgan, Korürek 1996)








Şekil 2.8. EMG işaretlerinin oluşumu ve yüzey elektrotlara ulaşımı (Yazgan, Korürek 1996)

Kasa uyarının gelmesiyle kasın kasılmaya başlaması arasında gecikme süresi olarak isimlendirilen bir süre Şekil 2.9.'da gösterilmektedir. Burada  $T$ , mekanik gerilmeyi gösterir. Her kasılma fazını bir gevşeme fazı takip eder. Kasın uyarma sonucu kasılması olayına "kas seğirmesi" denir. Seğirme süresi kasın tipine göre değişir. Örneğin hızlı ve hassas hareketleri sağlayan hızlı kaslarda bu süre 7.5 ms kadar küçük bir değere inebildiği halde kaba ve kuvvetli hareketlerin yapılmasını sağlayan kaslarda 100 ms kadar olabilir.



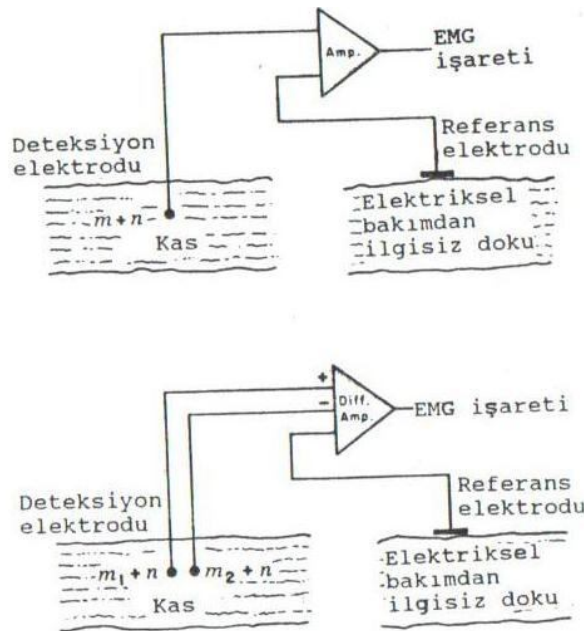
Şekil 2.9 Kasa uyarı gelişi ve kasın kasılması (Yazgan, Korürek 1996)

### 2.1.5. Kas yorulması ile EMG'de görülen değişim

Yorulma sonucu EMG işaretlerinin frekans spektrumu, alçak frekanslara doğru genliği artarak kaymaktadır. Frekans bandındaki kaymayı alçak frekanslarda 20-40 Hz ve yüksek frekanslarda 130-238 Hz bandları içerisindeki bileşenler nazara alınarak yapılmaktadır.

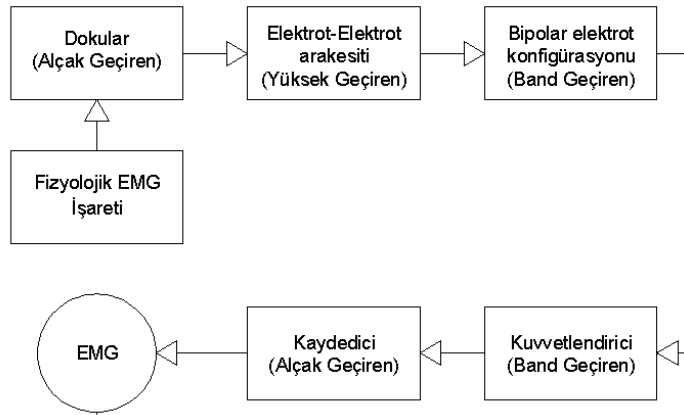
### 2.2. EMG İşaretlerini İnceleme Yöntemleri

Şekil 2.9.'da, EMG işaretlerinin monopolar ve bipolar modda algılama yöntemi gösterilmiştir. Ortak moddaki işareti düşük tutmak mümkün olduğundan bipolar mod daha fazla kullanılmaktadır.



Şekil 2.10. EMG İşaretlerinin monopolar ve bipolar deteksiyonu (Yazgan, Korürek 1996)

Şekil 2.10'da EMG işaretlerinin oluşumu ve görüntülenmesi sürecinde çeşitli dokuların işaret üzerindeki filtreleme işlemleri gösterilmiştir. Kuvvetlendirici bandı, yüzey elektrotların kullanılması durumunda 20-500 Hz, iğne ve tel elektrotlar kullanılması durumunda 20-1000 Hz olmalıdır. Tek bir fiberde oluşan işareti algılamak için kullanılan iğne ve tel elektrot durumunda ise 20-10000 Hz olmalıdır.



Şekil 2.11. EMG İşaretlerinin elektrotlara ulaşmaya kadar ki işlemler(Yazgan, Korürek 1996)

EMG işaretlerini, zaman domeni ve frekans domeni olmak üzere iki ayrı domende incelemek mümkündür.

### 2.2.1. EMG işaretlerinin zaman domeninde incelenmesi

EMG işaretlerinin zaman domeninde incelenmesi 5 basamakta yapılmaktadır. Bunlar;

**Doğrultma (Rectification);** EMG işaretlerinin doğrultulması işleminde doğrultma genellikle, enerjinin tümünü kullanabilmek için tam dalga doğrultması şeklinde yapılır. Böylece doğrultulan işaret, orijinal işaretin mutlak değerini gösterir. Doğrultmadan sonraki aşamada üç farklı yol takip edilmektedir.

**Alçak Geçiren Filtrelme;** Doğrultulmuş işaretteki random flüktuansları yok etmek için doğrultulmuş işaret, analog veya sayısal bir alçak geçiren filtreden geçirilir. Yani işaret üzerinde yumuşatma (smoothing) işlemi yapılır.

**Ortalama Alma (Averaging);** Ortalama alma yumuşatma işleminin sayısal yapılışıdır. Bu işaretin random olarak değişen değerlerinin ortalaması alınarak, büyük flüktüasyonlar yok edebilir. Tamamlanmış bir olayı karakterize eden bir kaydın zamanla değişen ortalamasını elde etmek için zaman penceresinin kayıt boyunca

hareket ettirilmesi gereklidir. Bu işlem “hareket eden ortalama” olarak isimlendirilir. Hareket eden ortalama veya doğrultulmuş işaretin ortalaması,

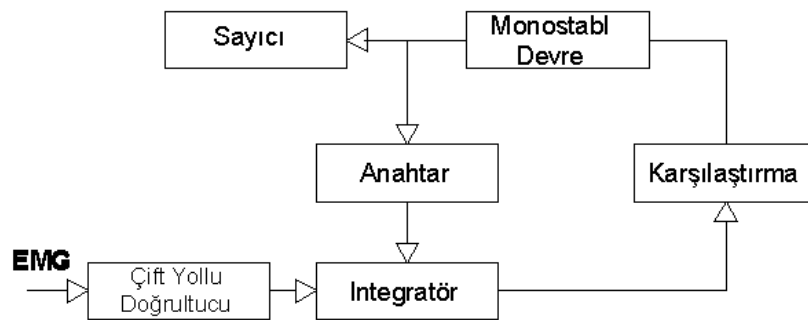
$$m_0(t) = \frac{1}{T} \int_{t-\frac{T}{2}}^{t+\frac{T}{2}} |m(t)| dt \quad (2.1)$$

bağıntısıyla hesaplanabilir. Burada, T pencereleme süresidir. T'nin küçük olması, doğrultulmuş işaretin zamana bağlı ortalamasının az yumuşatılması sonucunun oluşturur. T'nin büyük değerlerinde ise işaret durağan olmayabilir. T için tavsiye edilen değerler 100-200 ms arasındadır.


İntegrasyon; Data azaltmakta en çok kullanılan yöntem doğrultulmuş EMG işaretlerinin integralinin alınmasıdır. İntegral alma işlemi, alçak frekansları filtreleme işleminin özel bir şekil olması nedeniyle bir önceki işlemin benzeridir. Bu işlem,

$$I[|m(t)|] = \int_0^t |m(t)| dt \quad (2.2)$$

bağıntısıyla hesaplanır. Şekil 2.11a.'da bir EMG integratörünün blok diyagramı ve Şekil 2.12'de ise integratörün çeşitli noktalarındaki dalga şekilleri görülmektedir.



Şekil 2.11a. EMG işaretlerinin işlendiği integratör diyagramı (Yazgan, Korürek 1996)



Şekil 2.11b. İntegratörün çeşitli noktalarındaki işaretlerin zamana göre değişimi  
(Yazgan, Korürek 1996)

Doğrultulmuş EMG işaretlerinin integratör yardımıyla alınan integralin değeri, sürekli değişir ve karşılaştırıcıya uygulanmış olan değere ulaşınca karşılaştırıcı çıkışında oluşan işaret tek atımlı devreyi tetikler. Tek atımlı devrenin çıkışındaki darbe C, integratör kapasitesinin kısa devre edilmesini sağlar ve sayıcıda kaydedilmiş değeri bir artırır. İntegratör çıkışındaki bilgi iki farklı şekilde değerlendirilebilir.

a. İntegratör çıkışındaki analog gerilim bir kaydedici yardımıyla zamanın fonksiyonu olarak kaydedilir. Böylece herhangi bir anda gerçek integral değer görülebilir. İntegratörün sıfırlanması için gerekli integral değerinin bilinmiş olması nedeniyle, herhangi bir andaki integral değeri integratörün sıfırlanma sayısı ile kalibrasyon sabitinin çarpımına, o andaki integratörde kaydedilmiş olan değerin ilave edilmesiyle bulunabilir.

b. Sayıcı yardımıyla sıfırlama darbeleri sayılır. Böylece yaklaşık integral hesaplanır. İntegratördeki değerin ilavesiyle gerçek değer elde edilir.

RMS Değerin Ölçülmesi; Sinüs, kare darbe gibi dalga şekli olan deterministik işaretlerin genlikleriyle RMS değerleri arasındaki bağıntı bilinmektedir. Bu nedenle bu özelliğe sahip işaretlerle ilgili güç hesaplarında, bu işaretlerin genlikleri kullanılabilir. EMG'nin rasgele özelliğe sahip bir işaret olması nedeniyle, genliğiyle

RMS değeri arasında bir bağıntı yoktur. Bu nedenle, bu tip işaretlerin kapsadığı gücün belirlenebilmesi için RMS değer hesaplanmak zorundadır. RMS değer:


$$\text{RMS}[m(t)] = \frac{1}{T} \int_t^{t+T} m^2(t) dt \quad (2.3)$$

bağıntısı yardımıyla hesaplanır.

Sıfır Geçiş ve Dönüşlerin Sayılması; Bu yöntemde, işaret genliğinin bir t anındaki değeri işaretin sıfır değerinden geçiş sayısı veya genliklerin sayısının ölçülmesiyle belirlenir. Düşük düzeylerdeki kasılmalarda sıfır geçiş sayısı ile motor ünitesi aksiyon potansiyeli arasında lineer bir bağıntı vardır.

### 2.2.1. EMG işaretlerinin frekans domeninde incelenmesi

EMG işaretlerinin frekans domenindeki analizi bu işaretlerin frekans spektrumundaki özelliklerini belirleyen parametrelerinin ölçülmesi ve hesaplanması ile yapılır. Bu işaretlerin Güç Spektrum Yoğunluklarının belirlenmesinde genellikle Hızlı Fourier Dönüşümleri kullanılır. Şekil 2.12’de idealize edilmiş EMG işaretinin güç spektrum yoğunluğu, median frekansı, ortalama frekans ve spektrumun band genişliği gibi önemli parametreleriyle birlikte gösterilmiştir.



Şekil 2.12. İdealize edilmiş EMG işareti güç spektrum yoğunluğu (Yazgan, Korürek 1996)

Median ve ortalama frekans arasındaki bağıntı:

$$\int_0^{f_{med}} Sm(f)df = \int_{f_{med}}^{\infty} Sm(f)df = \frac{1}{2} \int_0^{\infty} Sm(f)df \quad (2.4)$$

$$f_{ort} = \frac{\int_0^{\infty} f \cdot Sm(f)df}{\int_0^{\infty} Sm(f)df} \quad (2.5)$$

bağıntılarıyla verilmiştir. Burada  $Sm(f)$ , EMG işaretinin güç spektrum yoğunluğunu göstermektedir. Median ve ortalama frekansın EMG'nin analizinde en çok güvenilebilecek parametreler olduğu gösterilmiştir. Median frekansı, gürültüye diğerine nazaran daha az duyarlıdır. Bu durum, özellikle işaret/gürültü oranının düşük olduğu düşük seviyeli kasılmalarda önemli olmaktadır.

Band genişliği spektrumu karakterize eder ve zaman ve kuvvetle değişimi belirtir. Aynı zamanda, EMG üzerinde gerçekleştirilmiş olan filtreleme işlemleriyle ilgili faydalı bilgiler verir. Sadece güç spektrumu yardımıyla hesaplanabilmesi nedeniyle gerçek zaman çalışmaları için faydalı değildir.

Mod frekansı, spektrumun tepe noktasıdır. Median ve ortalama frekans değişimlerine benzer değişimler gösterir. Yüksek doğrulukta belirlenebilecek bir parametre değildir.

Zaman domeni analizlerinde kullanılan sıfır geçiş tekniği, frekans domeni analizinde de kullanılabilir.  $Zf$ , sıfır geçiş hızı(zero crossing rate);

$$Zf = 2|\sigma^2 - (f_{ort})^2|^{1/2} = 2|\sigma^2 - (k \cdot f_m)^2|^{1/2} \quad (2.6)$$

bağıntısıyla ortalama frekansa ve EMG'nin varyansına bağlı olduğu gösterilebilir. Burada  $f_m$ , median frekansı ve  $k$  ise bir sabittir. Kasın yorgunluk dışında çalışması durumunda yüzey EMG'sinin 500 ms'ye kadar durağan olduğu ve gauss dağılımıyla



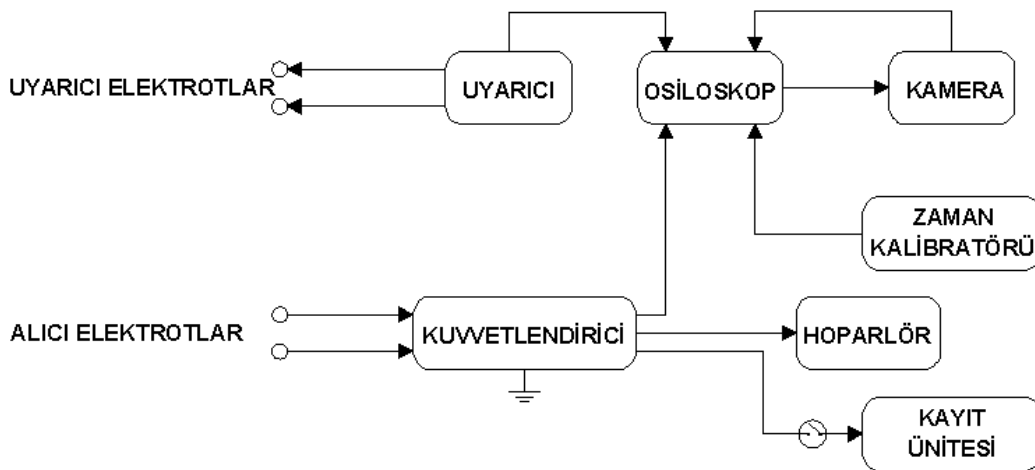
karakterize edilebileceği gösterilmiştir. O halde Zf, kas yorulması sonucu spektral karakteristikteki kaymayı belirtmek amacıyla kullanılabilir.

### 2.3. EMG Ölçüm Düzeni

EMG ölçüm düzenleri, genel olarak EMG işaretlerini algılamaya yarayan elektrotlar, uyarıcı, kuvvetlendirici, osiloskop, magnetik kaydedici ve hoparlörden oluşur. Araştırmaya yönelik çalışmalarda bu elemanlara ilaveten çeşitli işaret işleme blokları, spektrum analizörleri ve bilgisayarlar da bulunabilir.

Uyarıcı ile incelenecek kasın motor siniri uyarılarak kas liflerindeki EMG işaretleri, alıcı elektrotlar yardımıyla biyopotansiyel kuvvetlendiriciye ve kuvvetlendirici çıkışında da görüntüleme birimine aktarılır.

EMG düzenleri pratikte ayrı ayrı bloklar halinde olmayıp uygulamada ve taşımada kolaylık açısından tek bir kompakt ünite olarak ve bazen de kas işaretleri dışındaki biyopotansiyel işaretleri de ölçebilecek nitelikte gerçekleştirilirler. Uygulamada ölçüm yapılacak kasın motor ünitesi uyarılarak kas lifinde meydana gelen EMG işareti elektrotlar yardımıyla alınarak biyopotansiyel kuvvetlendiriciye oradan da görüntüleme ünitesine verilir. Şekil 2.13'de EMG ölçüm düzeneğinin blok bir şeması verilmiştir.




Şekil 2.13. Klinik EMG düzeni basitleştirilmiş modeli (Yazgan, Korürek 1996)

## 2.4. Elektrotlar


Biyolojik işaretlerin, özellikle tıpta teşhise yönelik algılanabilmesi için vücut ile ölçme düzeni arasındaki iletişimi sağlayan ve çeşitli amaçlar ve özellikle tedavi amacı için akım gönderilmesini sağlayan elemanlara elektrot adı verilir. Elektrotlar işlevlerini iyon akımını elektron akımına veya elektron akımını iyon akımına dönüştürerek gerçekleştirirler.

Elektrotların iyon akımını elektron akımına dönüştürme işlemi, elektrotların içinde buldukları sıvı ortamda (elektrolit içinde) ve elektrota yakın olan yüzeyde (arayüzde) gerçekleşir. Şekil 2.14'de bu dönüşüm işleminin gerçekleştiği arayüz görülmektedir. Bu arayüzün elektrot tarafında akım taşıyıcı olarak elektronlar ve elektrolit tarafında ise katyon( $C^+$ ) ve anyonlar( $A^-$ ) bulunur.



Şekil 2.14. Elektrot-elektrolit arayüzü ve akım (Yazgan, Korürek 1996)

Elektrolit içinde kullanılan elektrot malzemesinden katyonların bulunduğu durum da göz önüne alınarak, elektrot atomlarının elektronlarını kaybederek elektrolit içinde katyon durumuna gelmesi veya tersine elektrolit içindeki elektrot malzemesinden olan katyonların, elektrotdan elektron çalarak elektrot yüzeyinde birikmesi işlemleri ile karşılaşır. Elektrotdan akım çekilmediği sürece, kimyasal birer reaksiyon durumunda olan bu iki işlem, birbirini dengeleyecek biçimde (2.7) eşitliğinde gösterildiği gibi sürüp gider (termodinamik denge). (2.7) eşitliğinde, n ve m sırasıyla katyon ve anyonların valanslarını(değerliklerini) göstermektedir.




Termodinamik dengede, elektrot-elektrolit arayüzünde pozitif yüklü  $C^+$  iyonları ile, elektrotun arayüze yakın olan bölgelerinde elektronlar birikir. Bu şekilde arayüzdeki yük birikimi (iyon birikimi), elektrotu çevreleyen elektrolit bölgesinin elektriksel potansiyelini, elektrolitin diğer bölgelerine göre farklı bir potansiyele getirir. Kullanılan elektrotun yapıldığı malzemeye ve kullanılan elektrolitteki iyon aktivitesine göre değişen bu potansiyel farkına “Yarı hücre potansiyeli” adı verilir. Elektrotların yarı hücre potansiyellerini( $E_o$ ) ölçmek kolay değildir. Çünkü elektrolitin elektrottan uzaktaki referans potansiyelde olan noktasına batırılacak referans elektrotunun da bir yarı hücre potansiyeli olacaktır ve yarı hücre potansiyeli ölçülecek elektrot ile referans elektrot arasına bağlanacak büyük iç dirençli bir voltmetre ancak bu iki elektrotun yarı hücre potansiyellerinin farkını gösterecektir. Bu soruna bir çözüm getirmek amacıyla, yarı hücre potansiyeli sıfır varsayılan hidrojen elektrotu(asit içine daldırılarak etrafında hidrojen kabarcıkları oluşturulmuş platin elektrot), referans elektrot olarak ele alınmıştır.

Yarı hücre potansiyelinin ölçülebilmesi için elektrottan hiç akım çekilmemesi gerekir. Akım çekilince reaksiyon dengesi bozulur ve ölçülen yarı hücre potansiyeli, akımın sıfır olduğu değerinden farklı olur. Bu iki potansiyel arasındaki farka “gerilim aşımı” denir.

Teorik olarak elektrotlar, polarize olan ve polarize olmayan elektrotlar olarak ikiye ayrılabilirler. Polarize olan elektrotlarda, elektrot-elektrolit arayüzünde akım geçişi sınırlıdır ve elektrot bir kapasite gibi davranır. Polarize olmayan elektrotlarda akım arayüzü serbestçe geçer ve bu elektrotlarda gerilim aşımı yoktur. Ag-AgCl elektrotu pratik olarak polarize olmayan elektrot sınıfına girer ve bu yüzden, bu elektrotların yarı hücre potansiyelleri oldukça kararlıdır, yani gürültüleri çok azdır. Ayrıca bu elektrotların yapımı kolay ve ucuzdur.


### 2.4.1. Elektrotun devre modeli

Elektrotun elektriksel devre modeli Şekil 2.4'te görülmektedir. Bu modelde,  $C_d$  elektrot-elektrolit arayüzündeki yük birikiminin neden olduğu kapasiteyi,  $R_d$  ise bu kapasitenin kaçak direncini temsil etmektedir.  $E_d$ , elektrotun yarı hücre potansiyeline karşılık olan gerilim kaynağıdır.  $R_s$  ise elektrolitin direncine karşı gelir. Kullanılan elektrot Ag-AgCl elektrotu ise  $C_d$  kapasitesi oldukça küçüktür ve bu yüzden kapasitif etki oldukça azdır.



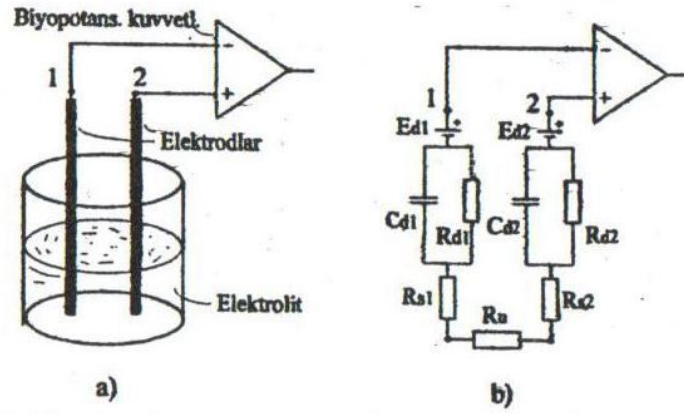
Şekil 2.15. Elektrotun eşdeğer devre modeli (Yazgan, Korürek 1996)

Ag-AgCl referans elektrotu ile birlikte kullanılan ve devre modeli çıkarılan elektrotun, empedansının genliğinin frekansla değişimi Şekil 2.16'da gösterilmiştir. Bu değişimde, empedansın modülünün alçak frekanslardaki değeri, eşdeğer devredeki ( $R_d + R_s$ ) direncinin değerine ve yüksek frekanslardaki değeri ise  $R_s$  direncinin değerine karşılık gelmektedir.



Şekil 2.16. Bir elektrotun Ag-AgCl referans elektrotu ile arasındaki empedansın genliğinin (modülünün) frekansla değişimi (Yazgan, Korürek 1996)

Elektrotların doku ile olan bağlantı durumunun elektriksel eşdeğer modelinin çıkarılmasında yardımcı olabilecek şekil olarak, elektrolit içine daldırılmış olan elektrotların kuvvetlendirici ile olan bağlantısı Şekil 2.17a.'da ve bu bağlantının elektriksel eşdeğer modeli 2.17b.'de görülmektedir. Şekil 2.17b.'de görülen modelde elektrotlar, Şekil 2.15.'deki elektrot eşdeğer devresi ile ve elektrolit ise daha çok rezistif karakter göstermesi nedeniyle  $R_u$  direnci ile gösterilmiştir.



Şekil 2.17a. Elektrot-elektrolit ve kuvvetlendiriciden oluşan sistem 2.17b. Sistemin basitleştirilmiş elektriksel eşdeğer modeli (Yazgan, Korürek 1996)

Elektrotların deri üzerinden test edilecek veya ölçme yapılacak organa olan bağlantısında deri, paralel R-C elemanları ile biyopotansiyel kaynak, bir gerilim kaynağı ( $e_{mp}$ ) ve ona seri olan paralel R-C devresi ile ve elektrot-biyopotansiyel kaynak arasındaki daha çok sıvımsı olan ortam olan iletken hacim(volume conductor) ise bir direnç elemanı  $R_u$  ile modellenilebilecektir.

#### 2.4.2. Elektrot çeşitleri

Değişik amaçlara göre kullanılan elektrot çeşitleri aşağıdaki şekilde gruplandırılabilir;


- Yüzey Elektrotları

- a) Metal Plaka Elektrotları
- b) Emici Düzenli (Vakum Pompalı) Elektrotlar
- c) Gezici Tipten Elektrotlar

- d) Tümüyle Atılabilir Elektrotlar
- e) Bükülebilir Elektrotlar
- f) Kuru Elektrotlar
- Dâhili Elektrotlar
- Mikroelektrotlar
- Hücre Uyarmada Kullanılan Elektrotlar

#### 2.4.2.1. Yüzey elektrotları

Çeşitli yüzey elektrotları Şekil 2.18’de görülmektedir. Bu elektrotlar, biyolojik işaretlerin deri üzerinden algılanmasında kullanılırlar.



Şekil 2.18. Yüzey elektrotları a) Metal plaka b) Vakum pompalı c) Gezici tipten d) Tümüyle atılabilir e) Bükülebilir f) Kuru elektrotlar (Yazgan, Korürek 1996)

a) Metal plaka elektrotlar; çok sık kullanılan bir elektrot türüdür ve özellikle EMG, ve EKG işaretlerini algılamakta kullanılır. Deri ile temas eden metalik bir yüzeyi bulunur. Gerçekte, deri ile temas eden bir elektrolit pasta aracılığı ile olur. Metal plaka, düz veya uygulanacak yüzeyin şeklini alacak şekilde bir silindir yüzey parçası biçimindedir ve genellikle Nikel-Gümüş alaşımından yapılmaktadır (Şekil 2.18a.). Genelde bu sınıfa giren elektrotların yüzeyleri büyük olduğundan empedansları küçük olup 2-10 Kohm arasındadır.

b) Emici düzenli elektrotlar; metal plaka elektrotunun geliştirilmiş bir şekli olup herhangi bir şekilde yapışkan veya bağlama kayışı gerektirmez ve genelde göğüs üzerinden EKG işaretlerinin algılanmasında kullanılır. Bu elektrot türünde, metal elektrot bir boru şeklindedir. Bu borunun halka şeklindeki yüzlerinden biri deriye değerken diğer yüzü, deriye elektrotun tutturulmasını sağlayan ve vakum pompası görevi gören elastik bir hazne içinde kalır. Bu tür bir elektrotun deri ile temas eden yüzeyi halka şeklinde olduğundan elektrot oldukça büyük hacimli olsa bile empedansı büyüktür ve bu yüzden küçük giriş empedanslı kuvvetlendiricilerle kullanılması elverişli olmaz (Şekil 2.18b.)

c) Gezici tipten elektrotlarda; elektrolit, metal elektrot ile birlikte hareket ettiğinden, elektrot ya da deri yani elektrolit hareketinden ileri gelen bozucu işaretler pek oluşmamaktadır. Şekil 2.18c.'de gezici tipten bir elektrot görülmektedir. Elektrot şapka biçimindedir ve metal dik şapkanın en üst iç yüzeyine yapışık durumdadır. Elektrot kullanılacağı zaman, yalıtkan şapkanın içi elektrolit ile doldurulur ve şapka, her iki yüzü yapışkan olan elastik bir halka vasıtası ile deriye yapıştırılır. Şapka hareketli olsa bile metal elektrolite göre hareket edemeyeceğinden aralarındaki yük dağılımı bozulmaz ve daha kararlı işaretler elde edilir. Ayrıca metal, disk gümüşten(Ag) yapıp AgCl ile kaplanırsa kararlılık daha da artırılmış olur. Her iki tarafı yapışkan olan elastik halka, her hasta için yenilenir.

d) Tümüyle atılabilir elektrolar; EKG ölçümlerinde çok kullanılan ve bir kere kullanıldıktan sonra atılan elektrotlardır (Şekil 2.18d.). Elektrolit, Ag-AgCl elektrot tabanının hemen altında elektrota yapışık durumda jel ve emdirilmiş süngerden oluşur.

e) Bükülebilir elektrotlar; düz olmayan vücut yüzeyinin şeklini alacak şekilde bükülebilmektedir. En çok kullanılanları, bir yüzü kısmen Ag telleri ile örülmüş, yapışabilir özelliğe sahip olup band şeklindedir (Şekil 2.18e.). Bükülebilir elektrotlar genellikle küçük çocukların EKG işaretlerini algılamada kullanılırlar.

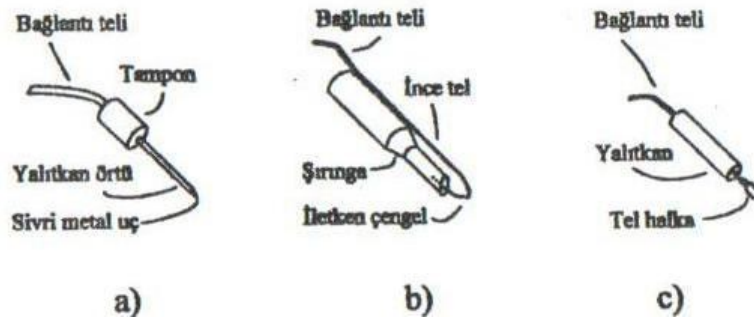
f ) Kuru Elektrotlar; yüzey elektrotlarının bu gruba girenleri, ara pasta malzemesi gerektirmeden, deri üzerine direkt olarak uygulanabilirler ve aradaki kuplaj

kapasitiftir. Şekil 2.15'deki eşdeğer devre geçerlidir ancak, elektrot-elektrolit ilişkisi bulunmadığından, eşdeğer devrede kaynak gerilimi yoktur. Dış deri, elektrot yüzeyi ile daha iyi iletken durumunda olan dermis arasında bir yalıtkan durumundadır ve bu yüzden bir kapasite oluşur ki dermis ile elektrot bu kapasitenin plakaları, dış deri ise dielektrik malzeme durumundadır. Üst deri iyice temizlenmeden kuru elektrot deri yüzeyine, eşdeğer devredeki kapasiteye paralel gelen direnç ( $R_d$ ) de oldukça büyüktür. Bu yüzden bu tür elektrotların bağlandığı kuvvetlendiricilerin giriş dirençleri de aynı oran da büyük ve 1 G $\Omega$  mertebelerinde olmalıdır. Büyük empedanslı devrelerle çalışıldığı içindir ki gürültü problemini en aza indirmek amacıyla daha ziyade, empedans dönüştürme işi yapan kuvvetlendiricinin ön katı, elektrotun hemen yanına monte edilir (Şekil 2.18f.). Kuru elektrotların, bazen dielektrik malzemesi de metal üzerinde oksit film oluşturularak gerçekleştirilir ki bu durumda artık hiç elektrolite gerek yoktur. Yarı iletken yapım teknolojisi ile silisyum kristal yüzeyler üzerinde çok ince ve düzgün SiO<sub>2</sub> yalıtkan tabakaları oluşturularak yapılan kuru elektrotlarda, kapasite 1nF civarında olup, kuvvetlendiriciler de aynı silisyum taban üzerinde gerçekleştirilebilmektedir.

#### 2.4.2.2. Dahili elektrotlar

Dahili elektrotlar, biyopotansiyel işaretleri vücut içinden algılamakta kullanılırlar. Deri altına batırılan iğne şeklinde olanları bulunduğu gibi, tümüyle vücut içine gömülüp harici kuvvetlendiriciye telemetri verici düzeni ile bağlı olanları da vardır. Bu tür elektrotlarda pasta kullanılmaz, elektrolit olarak hücre sıvısı mevcuttur. Şekil 2.19'da dahili elektrotlardan, iğne, tel ve tel halka elektrotları görülmektedir. İğne elektrotlar, paslanmaz çelikten yapılmış olup, EMG ve ameliyat gereken hastalarda EKG işaretlerinin algılanmasında kullanılırlar (Şekil 2.19.). Bu elektrotlarda, yüzey elektrotlara göre daha kararlı işaretler elde edilebilmektedir. Ancak bunların kullanılışı her zaman hastayı rahatsız etmektedir. Çünkü iğne çapları 0,1 mm ile 1 mm arasında değişmektedir. Tel elektrotların metal uçları kanca şeklindedir ve bu kanca sayesinde bir şırıngaya tutturularak deri altına sokulurlar ve şırınga geri çekildiğinde ise yine bu kanca yardımıyla buldukları yere tutunurlar (Şekil 2.19b.).






Şekil 2.19. Dahili elektrotlar a) İğne elektrot b) Tel elektrot c) Tel halka elektrot (Yazgan, Korürek 1996)

Vücut içine yerleştirilen elektrotlardan biri Şekil 2.19c.'de gösterilmiştir. Bu elektrotun ucu, vücut içinde ölçme yapılacak noktaya dikilebilmesi için halka şekline getirilmiştir.

#### 2.4.2.3. Mikroelektrotlar


Uyarılabilen hücrelerin elektriksel davranışlarını inceleyebilmek için, hücre zarı ile bölünen hücre içi ve hücre dışı arasındaki potansiyel farkını ölçmek için hücreyi tahrip etmeyecek ve elektriksel davranışını bozmayacak bir elektrotun hücre içine daldırılması gerekmektedir. Bu amaç için kullanılan ve uç çapları 0,05–10  $\mu\text{m}$  arasında değişen ve hücre zarını delerek, mekanik olarak kararlı kalabilecek durumda olan elektrotlara mikroelektrotlar adı verilir.



Şekil 2.20. Mikroelektrotlar a) Cam muhafazalı b) Cam göbekli (Yazgan, Korürek 1996)

Mekanik sağlamlık, metal cam içinde muhafaza edilerek veya bir cam silindir yüzeyini kaplayacak biçime getirilerek sağlanır.(Şekil 2.20a. ve 2.20b.). Elektrotu, içine konan elektrolit içinde muhafaza eden, camdan yapılmış mikropipetler de


mikroelektrot sınıfına girerler (Şekil 2.21.). Mikropipet elektrotlarda, cam muhafaza şeklindeki tübün içi KCl ihtiva eden bir sıvı ile doldurulduktan sonra tübün geniş olan ağzının ortasında metal (Ag) elektrot tel bulunan yalıtkan bir tıpa ile kapatılır. Cam tübün ince ve açık olan ucunun çapı 1  $\mu\text{m}$  kadardır.



Şekil (10.8) Mikropipet elektrod

Şekil 2.21. Mikropipet elektrot (Yazgan Korürek 1996)

Mikroelektrot ile yapılan hücre içi biyopotansiyel ölçüm düzeninin basitleştirilmiş elektriksel modeli Şekil 2.22'de gösterilmiştir. Bu şekilde, A ucu mikroelektrotun bağlantı ucuna ve B ucu ise referans elektrotunun bağlantı ucuna karşı gelmektedir. Bu modelde, yüzeyi mikroelektrot yüzeyine göre oldukça geniş olan referans pasif model elemanları mikroelektrotun model elemanları yanında ihmal edilmiştir. Şekil 2.15'deki modelde gözükken seri dirençler de bu modelde ihmal edilmiştir. Sonuçta, basitleştirilmiş modelde mikroelektrotun paralel R-C elemanları ile kablo ve elektrot kaçak kapasiteleri kalmaktadır. Modeldeki  $(E_{ma}-E_{mb})$  potansiyel kaynağı, mikroelektrot ile referans elektrot eşdeğer yarı hücre potansiyel farklarını temsil etmektedir.



Şekil 2.22. Mikroelektrot ile gerçekleştirilen ölçüm düzeninin basitleştirilmiş modeli (Yazgan, Korürek 1996)

### 2.4.3. Hücre uyarda kullanılan elektrotlar

Hücre uyarda kullanılan elektrotlar genelde, biyoelektrik potansiyellerin algılanmasında kullanılan elektrotlara benzerler. Ancak bu elektrotlardan mili amper mertebesinde uyarı akımları akıtılmaktadır. Kalbin hızlı ve zayıf çalışmasını önleyici cihazlarda(defibrilatör) ve kalbin atış hızını ayarlayan cihazlarda hücre uyarda için özel elektrotlar kullanılır. Elektriksel uyarı için, dikdörtgen dalga, sinüzoidal veya dönüşü eksponansiyel olarak azalan darbeler kullanılmaktadır. Uyarı, akım veya gerilim değişimi biçiminde yapılabilir. Elektrot eşdeğer devresi Şekil 2.15'deki gibidir. Uyarı elektrotlarında kullanılan malzeme önemlidir, çünkü uyarı akımı elektrotun okside olmasına ve elektrot yakınında elektrot malzemesinden iyonların konsantrasyonunun artmasına ve dolayısıyla hücre zehirlenmesine yol açabilir. Elektrot açısından bakıldığında ise bu oksidasyon, elektrotun ömrünü azaltıcı bir etkidir. Bu yüzden uyarı elektrotu olarak soy metaller kullanmak uygun olur.

### **BÖLÜM 3. BIYOMEDİKAL İŞARET İŞLEME**

İnsan vücudunda üretilen elektrokimyasal kökenli işaretlere biyolojik işaret adı verilir. İşaret, genel anlamı ile bilgi taşıyan, zamana göre değişen veya değişmeyen büyüklüklerdir. İşaret, bazen, direkt olarak, orijinal bilgi kaynağından üretilir ve bu durumda işarete bakarak kaynağın yapısı veya işleyişi hakkında bilgi elde edilebilir. Bazı durumlarda ise, elde edilen işaret, direkt olarak istenilen bilgiyi vermeyebilir ve bu durumda da işaret üzerinde istenileni elde etmek için çeşitli işlemler uygulamak gerekir.


Bazen biyolojik işaretin bilgisayar ortamı gibi bir görüntüleme ortamına taşınması yada işaretin bilgisayar belleği gibi bir ortamda tutulması gerekebilir. Bazen de biyolojik işaretin hekimin yapacağı teşhise yardım amacıyla işlenmesi söz konusu olabilir. Bütün bu istenenleri gerçekleştirebilmek için ham işaretin, amaca en uygun hale getirilmesi yani işaretin işlenmesi gerekmektedir. Bu sebeplerden biyomedikal işaret işleme, tıp elektroniğinde ve biyoelektrik işaretlerin kullanıldığı tüm uygulamalarda büyük önem kazanmıştır.

Bu amaçlarla algılanan ham işaretin değerlendirilebilir ve yorumlanabilir şekle getirilmesi için bir takım işlemler gerekmektedir. İşaretten gerekli bilgiyi çıkarmak için çeşitli işaret işleme metotları vardır. İşaret, toplam veya çarpım şeklinde gürültü ile karışık şekildedir. Veya amaca uygun anlamlı bilgi, işaretin bir parçasını oluşturur, geri kalan işe yaramaz kısımlar da gürültü olarak ele alınır. İşaretlerin analizinde her türlü bilgi bozucu ve esas işaret dışında kalan işaretler gürültü olarak ele alınır ve esas işaretin bu gürültüden ayrıştırılması istenir.

Biyomedikal işaret işlemede, uygun işaret işleme metotlarının seçilebilmesi için işlenecek olan işaretin karakteristiğinin bilinmesi önemlidir. İşaretler deterministik ve rasgele işaretler olmak üzere iki ana başlık altında ele alınabilir. Deterministik

bağıntılar aynı girişler için her zaman aynı çıkışları veren açık ve belirgin matematiksel bağıntılardır. Deterministik bağıntılar, zaman yada frekansın birer fonksiyonu şeklinde olup sonlu sayıda terim bulundurlar. Rasgele işaretler ise, tam olarak matematiksel bağıntılarla ifade edilemeyen ancak olasılıkları ve istatistiksel ortalamaları ile belirlenebilen işaretlerdir. Gerçekte ise tam olarak deterministik ve rasgele işaret bulmak mümkün değildir. İncelenen işaret zaman zaman deterministik zaman zaman da rasgele olabilir. Ama yine de işareti bu iki grupta tanımlamak mümkündür.

Deterministik işaretler; periyodik ve periyodik olmayan işaretler olarak sınıflandırılabilir. Periyodik işaretler, her  $t$  için  $x(t)=x(t+T)$  bağıntısı sağlayan işaretlerdir ki burada  $T$ , işaretin periyodudur. Periyodik işaretler, bir periyotluk kısımlarının tüm işareti temsil etmesi nedeniyle işaret işleme ve işareti tanımlama yönlerinden kolaylık arz ederler. Frekans domeninde ise periyodik işaretler Fourier serileri ile temsil edilirler ki, bu domende temel frekans ve harmonik bileşenler söz konusu olur. Periyodik olmayan işaretler de, hemen hemen periyodik ve süreksiz işaretler olmak üzere iki kısma ayrılır.



Şekil 3.1. İşaretlerin sınıflandırılması

Rasgele (random) işaretler; işlenmesi daha zor olan işaretlerdir. Bir rastgele işaret, bir rastgele sürecin bir örnek fonksiyonudur. Bu örnek fonksiyonların oluşturduğu işaret, topluluk (ensamble) adını alır. Rasgele işaret, birleşik olasılık yoğunluk fonksiyonu ile belirlenir.

Rasgele işaretler, durağan (stationary) ve durağan olmayan(nonstationary) işaretler olmak üzere iki alt gruba ayrılır. Durağan süreçlerde istatistiksel özellikler zamanla değişmez. Durağan olmayan süreç işlenmesi en zor işlenen süreçtir ve bu yüzden hatalı olduğu bilindiği halde ergodik süreç gibi kabul edilerek çözüme gidilir.

İşaretler ayrıca sürekli ve ayrık işaretler olarak iki gruba ayrılırlar. Genel olarak, sürekli işaretler, zaman içinde herhangi bir anda tanımlanabilirler. Bu işaretlere uygun işaret işleme metotları; Fourier ve Laplace dönüşümleri ve diğer analog metotlardır.

Ayrık işaretler ise, sürekli işaretlerin zaman içinde örneklenmiş ve genlik olarak kuantalanmış halleridirler. Tabiatı itibariyle ayrık olan işaretlere Z dönüşümü, ayrık Fourier dönüşümü (FD), hızlı Fourier dönüşümü (HFD) gibi ayrık işaret işleme metotları uygulanır.

### **3.1. Rasgele İşaretlerin İşlenmesi**

EMG işaretleri tabiatı itibariyle; diğer elektriksel kökenli biyolojik işaretler gibi rasgele işaretler olduğundan, bu işaretlerin işlenmesinde rasgele işaret işleme teknikleri kullanılmaktadır. Rasgele işaretler durağan ve durağan olmayan işaretler sınıflaması altında değerlendirilerek çözüme gidilmektedir.

Durağan işaretlerin analizinde, Birçok çalışmada şu iki bakış açısıyla çözüme gidilmiştir. Birincisi; kullanılan parametrelerin istatistiksel dağılıma sahip olduğu varsayılmıştır. Bu model optimizasyon temelli her sınıflamanın(ölçümler ve eğitim seti) koşullu olasılığını hesaplamak için kullanılır. Birinci modelin kullanımında Monte Carlo metodu ve Markov serileri gibi ağır sayısal yöntemlerin kullanılmasına ihtiyaç duyulmuştur.

İkinci bakış açısı ise; modellemenin çok zor olduğu durumlarda parametrik olmayan kaynakların tanımlanmasının ad hoc karar algoritmalarından türetilmesidir.

Durağan olmayan işaretler için doğru olan modelin seçimi çok zordur ve bu durum istatistiksel işaret işleme, zaman-frekans veya zaman-ölçek temelli gibi yeni yaklaşımların geliştirilmesine sebep olmuştur.

### 3.1.1. Fourier dönüşüm

Klasik olarak  $x(t)$  durağan işaretinin frekans içeriği 3.1. bağıntısında da gösterilen Fourier dönüşümden çıkarılır.

$$FT_x(f) = \int x(t) \exp(-j2\pi ft) dt \quad (3.1.)$$

Temel bir kural olan bu integralde,  $x(t)$  sinyalinin skaler bileşeni ve  $f$  frekansının monodromatik dalga takımı görülmektedir.  $FT_x(f)$  sonucunda  $\exp(-j2\pi ft)$  vektör temelli  $x(t)$  işaretinin frekans bileşenleri hesaplanabilir. Ayrıca Fourier integrali,  $x(t)$  işareti ve  $f$  frekansında ortalanmış monokromatik band geçiren filtrenin darbe cevabının konvolüsyonu olarak hesap edilebilir.  $FT_x(f)$  ise filtre çıkışı olarak adledilebilir. Burada bilinmesi gereken husus incelenen dalgaların sonsuz uzunlukta ve filtrelerin ise sonsuz uzunlukta darbe cevabı olduğudur. Parseval teoremi olarak da adlandırılan 3.2. bağıntısında en önemli sonuç, işaretin enerji/güç spektrumu olduğu gibi formülize edilebilmektedir.

$$E_x = \int |x(t)|^2 dt = \int |FT_x(f)|^2 df \quad (3.2.)$$

3.2. bağıntısında görülen  $|x(t)|^2$  zaman domeninde enerji dağılımı olup  $|FT_x(f)|^2$  frekans domeninde enerji dağılımıdır.

Fourier dönüşüm durağan olmayan işaretler için uygulanabilir. Örnek olarak dikdörtgen pencere ile kırılmış sonsuz uzunlukta monokromatik bir dalga ele alalım. Fourier dönüşüm sonucu, ele alınan dalganın Fourier dönüşümü (Dirac darbesi) ve ötelenmiş sinc fonksiyonunun penceresinin konvülasyonudur. Orijinal kesikli dalga, sinc fonksiyonu ve genlikleri frekanslar boyunca dağılmış sonsuz sayıda monokromatik dalgaların katılımıyla oluşmuş durağan içerik ile tanımlanabilir. Bu çözüm kuşkusuz makul bir yorum olmamakla birlikte kullanılan

pencerenin başından sonuna kadar monokromatik dalgayı tanımlama için iyi bir yoldur. Bahsedilen tüm bu durumlar, durağan olmayan işaretlerin analizinde zaman-frekans gösterimleri olarak adlandırılan kesin yöntemlerin kullanımına ihtiyaç olduğunu göstermektedir. Her ne kadar durağan olmayan işaretler için Fourier dönüşümünün kullanımı yanlış olmasa da, gözlem zamanında süreksiz durumları tespit etmek kolay değildir.

### 3.1.2. Kısa zaman fourier dönüşümü (KZFD) ve spektrogram

$x(t)$  işaretinin Kısa zaman Fourier Dönüşümü olan 3.3. nolu bağıntıdaki  $STFT_{hx}(t, f)$ ,  $t$  zaman ve  $f$  frekansın bir fonksiyonu olup  $\int |h(t)|^2 dt = 1$  (normalize edilmiş pencere) olarak tanımlanan  $h(t)$  penceresine bağlıdır.

$$STFT_{hx}(t, f) = \int x(u)h^*(u-t)\exp(-j2\pi fu)du \quad (3.3.)$$

Bu tanımın aşağıdaki maddeleri içerdiği görülebilir. Bunlar;

- 1- Pencere içinde durağan kabul edilen  $x(u)$  işaretinin standart Fourier dönüşümü,  $h(u)$  penceresi tarafından kırılmıştır.
- 2-  $f$  frekanslı,  $h$  penceresi tarafından kırılmış monokromatik dalga temelinde bir ayrıştırma (skaler çarpım),  $t$  zaman etrafında ortalanmıştır. (burada pencere frekanstan bağımsızdır.)
- 3- Sonlu uzunlukta darbe cevaplı filtre bankası (darbant filtre) tarafından filtrelenmiş işaret (konvülyasyon çarpımı) mevcut zaman ve frekans çözümleri üzerine ortalanmıştır.

Sonlu enerji sinyali için (ve normalize edilmiş pencere) Parseval'in teoremi 3.4. bağıntısındaki gibi kolayca STFT'e genişletilebilir.

$$E_x = \iint |STFT_{hx}(t, f)|^2 dt df \quad (3.4.)$$

Spektrogram 3.5. bağıntısındaki gibi tanımlanabilir. Buna göre SP,

$$SP_{hx}(t, f) = |STFT_{hx}(t, f)|^2 \quad (3.5.)$$



Spektrogram zaman-frekans düzleminde işaretin enerji dağılımını göstermekte olup bilinear gösterimlerin özel bir halidir. 3.6. bağıntısındaki yazılabilir.

$$SP_{hx}(t, f) = \iint h\left(t - u + \frac{\tau}{2}\right) * h\left(t - u - \frac{\tau}{2}\right) x\left(u + \frac{\tau}{2}\right) x^*\left(u - \frac{\tau}{2}\right) \exp(-j2\pi f\tau) du d\tau \quad (3.6.)$$

Ani bileşenleri 3.7. bağıntısındaki gibi tanımlayabiliriz.

$$p(t, \tau) = x\left(t + \frac{\tau}{2}\right) x^*\left(t - \frac{\tau}{2}\right) \quad (3.7.)$$

3.8. bağıntısında  $t$  analiz edilen andaki zamanı yani anlık değeri,  $\tau$ 'da gecikmeyi (ötelemeyi) göstermektedir. Zaman-gecikme düzgünleştirme operatörünü 3.8. bağıntısındaki gibi tanımlayabiliriz.

$$\Phi_{t\tau}(t, \tau) = h\left(t + \frac{\tau}{2}\right) h^*\left(t - \frac{\tau}{2}\right) \quad (3.8.)$$

Böylece spektrogramın  $\Phi_{t\tau}(t, \tau)$  operatörü tarafından düzgünleştirilmiş ani bileşen  $p(t, \tau)$ 'nin Fourier dönüşümü olduğunu görebiliriz. Artık  $\Phi_{t\tau}(t, \tau)$ 'nin fourier dönüşümü ile düzgünleştirme operatörünün zaman-frekans deyimlerini hesaplamaya devam edebiliriz.

$$\Phi_{tf}(t, f) = \int \Phi_{t\tau}(t, \tau) \exp(-j2\pi f\tau) d\tau \quad (3.9.)$$

Fourier dönüşüm ile ani bileşen  $p(t, \tau)$ 'nin frekansı için zaman gecikmesi yani  $x(t)$ 'nin Wigner-Ville dönüşümü 3.10.'deki bağıntıdaki gibi gösterilebilir.

$$WVx(t, f) = \int x\left(t + \frac{\tau}{2}\right) x^*\left(t - \frac{\tau}{2}\right) \exp(-j2\pi f\tau) d\tau \quad (3.10.)$$

Wigner-ville dönüşümü ile spektrogram 3.11. eşitliğindeki gibi düzenlenebilir.

$$SPhx(t, f) = \int \Phi_{tf}(u - t, v - f) WVx(u, v) du dv \quad (3.11.)$$

Spektrogram  $x(t)$ 'nin Wigner-ville dönüşümünün ikili(zaman ve frekans düzleminde) düzgünleştirme sonucu olarak gösterilebilir.

$$\Phi_{ff}(t, f) = \int h\left(t + \frac{\tau}{2}\right) h^*\left(t - \frac{\tau}{2}\right) \exp(-j2\pi f\tau) d\tau \quad (3.12.)$$

Rasgele işaretler için matematiksel olarak beklenen sonuçlar, istatistiksel dağılımların integrali olarak ele alınmaktadır. Çünkü durağan olmayan durumlarda, zamansal integraller istatistiksel yorumlara imkan vermemektedir. Ama yinede ani bileşenin beklenen değeri otokorelasyon fonksiyonu ve onun fourier dönüşümü olarak adlandırılan Wigner-ville dönüşümü ile tanımlanır.

### 3.1.3. Durağan süreçler ve modeller

Durağan süreç veya rasgele süreç terimleri, olasılık kurallarına bağlı olan istatistiksel olayların zamanla değişiminin tanımlanması için kullanılır. Zaman değişiminden kastedilen, durağan sürecin belirli bir gözlem aralığında değişen zamanın bir fonksiyonu olmasıdır. Olayın istatistiksel doğası ile zaman içindeki değişimin tam manası ile tarif edilememesi kastedilmektedir. Durağan süreç örnekleri konuşma işaretleri, televizyon işaretleri, radar işaretleri, sayısal bilgisayar verileri, iletişim kanal çıkışları, sismik veriler ve gürültü gösterilebilir. İlgilenilen durağan süreçlerden biri, anlık zaman içerisinde ayırık ve düzenli olarak belirtilen süreçlerdir. Bilgisayar verileri ve radar işaretleri gibi uygulama alanlarında yukarıdaki gibi sınırlamalar görülmektedir. Buna ilaveten durağan süreçler zamanın gerçek değerleri içinde tanımlanabilir. Bu tanımlamayı yaparken zamanda düzenli örnekleme yapılmalı ve örnekleme oranının en yüksek frekans elemanının 2 katı seçilmiş olması gerekmektedir [28].

Durağan süreçler sadece zamanın tekil bir fonksiyonu değildir, aynı zamanda teoride sürecin sonsuz sayıda gerçekleşmesidir. Ayırık-Zaman Durağan Süreçlerin bir özel gerçekleştirilmesi Ayırık-Zaman serileri veya basitçe zaman serileri olarak isimlendirilir. Notasyonun uygunluğu için örnekleme periyoduna uygun olarak zaman normalize edilmiştir. Örneğin,  $u(n)$ ,  $u(n-1)$ , ... ,  $u(n-M)$  dizisi  $u(n)$ 'nin “n” anındaki şimdiki değeri ve “n-1”, ... , “n-M” anlarındaki M adet geçmiş değerinin oluşturduğu bir

zaman serisidir. Bir zaman ötelemesi sonucu sürecin istatistiksel özellikleri değişmez ise sürecin “katı bir biçimde durağan” olduğu tanımlaması yapılabilir.

### 3.1.3.1 Ayırık – zaman durağan süreçlerin kısmi karakterizasyonu

Pratikte, Durağan süreç üzerinde yapılan ardışık incelemelere ait birleşik olasılık yoğunluk fonksiyonlarının belirlenmesi mümkün değildir. Bu bağlamda, sürecin 1. ve 2. hareketlerini belirten kısmi bir karakterizasyon yapılmalıdır.

$u(n)$ ,  $u(n-1)$ , ... ,  $u(n-M)$  ile gösterilen bir ayırık – zaman durağan süreç ele alalım. Sürecin ortalama değerini (mean – value ) şu şekilde tanımlayabiliriz,

$$\mu(n) = E[u(n)] \quad (3.13.)$$

Burada  $E$  istatistiksel tahmin operatörüdür. Sürecin otokorelasyon fonksiyonunu şu şekilde tanımlayabiliriz,

$$r(n,n-k) = E[u(n)u^*(n-k)], k = 0, \pm 1, \pm 2, \dots, \quad (3.14.)$$

“\*” kompleks konjugeyi göstermektedir ve otokovaryans fonksiyonunu şu şekilde tanımlayabiliriz,

$$c(n,n-k) = E[(u(n) - \mu(n))(u(n-k) - \mu(n-k))^*], k = 0, \pm 1, \pm 2, \dots \quad (3.15.)$$

(3.13) ve (3.14) denklemleri kullanılarak sürecin ortalama değer, oto korelasyon, oto kovaryans fonksiyonlarının ilişkisi denklem 3.16’daki gibi yazılabilir.

$$c(n,n-k) = r(n,n-k) - \mu(n)\mu^*(n-k) \quad (3.16.)$$

Kısmi karakterizasyon için birçok  $n$  ve  $k$  değerleri için ortalama değer, oto korelasyon ve oto kovaryans fonksiyonlarının belirlenmesi gerekir.

Bu tip bir kısmi karakterizasyonun iki önemli avantajı bulunmaktadır.

1. Pratik ölçme sağlar.
2. Durağan süreçler üzerindeki lineer işlemler için çok uygundur.

Katı bir biçimde durağan olan durağan süreçler için (3.13), (3.14) ve (3.15) denklemleri daha basit bir şekilde kabul edilebilir. (3.13) denklemi için,

$$\mu(n) = \mu, \text{ bütün } n \text{ 'ler için} \quad (3.17.)$$

Otokorelasyon ve otokovaryans fonksiyonlarının  $n$  ve  $n-k$  inceleme zamanlarının arasındaki farka (ki buda  $k$ 'dır) bağımlı olduğu bulunmuştur.

$$r(n, n-k) = r(k) \quad (3.18)$$

ve

$$c(n, n-k) = c(k) \quad (3.19)$$

$k=0$  olduğunda  $r(0)$  değeri  $u(n)$ 'nin ortalama karesel değerine eşit olmaktadır.

$$r(0) = E[|u(n)|^2] \quad (3.20)$$

ve  $c(0)$ 'da  $u(n)$ 'nin varyansına eşit olmaktadır.

$$c(0) = \sigma^2 \quad (3.21)$$

(3.17), (3.18) ve (3.19) denklemleri ayrık – zaman durağan sürecin katı bir biçimde durağan olduğunu garanti etmek için yeterli değildir. Bu özellikleri barındıran fakat katı bir biçimde durağan olmayan durağan süreçler için geniş çapta duyarlı (wide - sense) veya 2. dereceden durağan tanımlamaları yapılabilir. Katı bir biçimde durağan olan bir sürecin geniş çaplı durağan olarak nitelendirilebilmesi için gerek şart ise

$E[|u(n)|^2] < \infty$ 'dur , bütün  $n$  ' ler için

### 3.1.3.2. Korelasyon matrisi

$M \times 1$ 'lik gözlem vektörü  $u(n)$ ;  $u(n)$ ,  $u(n-1)$ ,  $\dots$ ,  $u(n-M+1)$  zaman serisinin elemanlarını temsil etsin.

$$u^T(n) = [u(n), u(n-1), \dots, u(n-M+1)] \quad (3.22)$$

Burada  $T$  transpozeyi göstermektedir. Durağan ayırık – zaman durağan sürecin korelasyon matrisi, zaman serisinin gözlem vektörü  $u(n)$ 'nin ürünleri ve kendisinin tahmini olarak gösterilmektedir.  $R$ ;  $M \times M$  'lik ve bu yolla oluşturulan korelasyon matrisi olsun. Böylece;

$$R = E [u(n)u^H(n)] \quad (3.23)$$

$H$  ; burada Hermitian Transpozesidir. (3.22) ve (3.23) denklemlerini birbirinden çıkartarak ve geniş çaplı durağanlık ilkesini kullanarak korelasyon matrisi  $R$ 'nin açılmış biçimini 3.24'deki açıklayabiliriz.

$$R = \begin{bmatrix} r(0) & r(1) & \dots & \dots & r(M-1) \\ r(-1) & r(0) & \dots & \dots & r(M-2) \\ \cdot & \cdot & \cdot & & \\ \cdot & \cdot & & \cdot & \\ \cdot & \cdot & & & \cdot \\ r(-M+1) & r(-M+2) & \dots & \dots & r(0) \end{bmatrix} \quad (3.24)$$

Köşegende bulunan  $r(0)$  değerleri her zaman için gerçek değerlidir ve diğer elemanlar kompleks değerler olabilirler.

Korelasyon matrisinin özelliklerini şu şekilde sıralayabiliriz.

Korelasyon matrisi  $R$ ; istatistiksel analizde anahtar bir rol üstlenmektedir. Bu yüzden korelasyon matrisinin özelliklerini iyi bir şekilde anlamak gerekmektedir.

Kısacası; (3.23) denklemini kullanarak durağan ayırık zamanlı durağan sürecin korelasyon matrisine ait aşağıdaki özellikler sıralanmıştır.

Özellik 1. Durağan ayırık zamanlı durağan sürecin korelasyon matrisi hermitiandır. Kompleks değerli bir matris eğer konjuge transpozuna eşit ise bu matris hermitiandır.

$$R^H=R \quad (3.25)$$

Korelasyon matrisi R'nin hermitian olduğunu belirlemek için bir diğer yol ise durağan süreç oto korelasyon fonksiyonu  $r(k)$ 'nin aşağıdaki şekilde yazılması ile elde edilir.

$$r(-k)=r^*(k) \quad (3.26)$$

Geniş-çaplı Durağan sürece ait korelasyon matrisi R'yi tanımlayabilmek için;  $k=0,1,\dots,M-1$  değerleri için oluşan oto korelasyon fonksiyonu  $r(k)$  "M" değerlerine ihtiyaç duyulmaktadır.

$$R = \begin{bmatrix} r(0) & r(1) & \cdot & \cdot & \cdot & r(M-1) \\ r^*(1) & r(0) & \cdot & \cdot & \cdot & r(M-2) \\ \cdot & \cdot & \cdot & & & \\ \cdot & \cdot & & \cdot & & \\ \cdot & \cdot & & & \cdot & \\ r^*(M-1) & r^*(M-2) & \cdot & \cdot & \cdot & r(0) \end{bmatrix} \quad (3.27)$$

Buradan, yukarıda ki gösterimi geniş-çaplı durağan ayırık zaman durağan sürece ait korelasyon matrisinin genişletilmiş halinin yazılması için kullanılacaktır. Gerçek değerli veriler için her  $k$  için  $r(k)$  reeldir ve korelasyon matrisi R simetriktir.

Özellik 2. Durağan ayırık zaman Durağan sürecin korelasyon matrisi Toeplitz'dir.

Eğer karesel matrisin ana köşegenindeki elemanlar birbirine eşit ve ana köşegene paralel olan diğer elemanlar birbirine eşit ise bu matris Toeplitz'dir. (3.26) numaralı denklemi kullanarak ana köşegendeki elemanların birbirine eşit olduğu ve ana

köşegene paralel olan elemanların birbirine eşit olduğu gözlemleri yapılabilir. Bu sayede korelasyon matrisi R'nin Toeplitz olduğu görülür.

Gözlem vektörü  $u(n)$  tarafından gösterilen ayrık zaman Durağan sürecinin geniş çaplı durağan olduğu kabulünün direk bir sonucu R matrisinin Toeplitz olduğudur.

Özellik 3. Negatif olmayan belirlilik Herhangi bir kompleks değerli X vektörü için ilişki matrisi R aşağıdaki özelliği sağlar.

$$X^H R X \geq 0 \quad (3.28)$$

Böylece R ilişki matrisi daima negatif olmayan veya pozitif yarı belirli bir matristir.

Özellik 4. Durağan ayrık-zamanlı bir sürecin gözlem vektörünü oluşturan elemanların geriye doğru düzenlenmesi ile oluşan etki korelasyon matrisinin transpozunu almayla eşdeğerdir.

$u^{BT}(n)$ ;  $u(n)$ 'nin geriye doğru düzenlenmesini göstermektedir. Buna göre;

$$u^T(n) = [u(n), u(n-1), \dots, u(n-M+2), u(n-M+1)] \quad (3.29)$$

$$u^{BT}(n) = [u(n-M+1), u(n-M+2), \dots, u(n-1), u(n)] \quad (3.30)$$

Burada "B" geriye doğru ifadesini temsil etmektedir.  $u^B(n)$  vektörüne ait korelasyon matrisi aşağıdaki şekildedir.

$$E[u^B(n)u^{BH}(n)] = \begin{bmatrix} r(0) & r^*(1) & \cdot & \cdot & \cdot & r^*(M-1) \\ r(1) & r(0) & \cdot & \cdot & \cdot & r^*(M-2) \\ \cdot & \cdot & \cdot & & & \\ \cdot & \cdot & \cdot & & & \\ \cdot & \cdot & \cdot & & & \\ r(M-1) & r(M-2) & \cdot & \cdot & \cdot & r(0) \end{bmatrix} \quad (3.31)$$

Burada yukarıdaki denklemi denklem 3.27'e göre düzenlersek aşağıdaki tanımlama ortaya çıkar.

$$E[u^B(n)u^{BH}(n)] = R^T \quad (3.32)$$

Özellik 5. Durağan ayırık-zaman Durağan bir sürecin M ve M+1 anlarındaki gözlemlerinden oluşan  $R_M$  ve  $R_{M+1}$  korelasyon matrisleri arasındaki ilişkiyi gösterirsek;

$$R_{M+1} = \begin{bmatrix} r(0) & | & r^H \\ \hline r & | & R_M \end{bmatrix} \quad (3.33)$$

veya

$$R_{M+1} = \begin{bmatrix} R_M & | & r^{B*} \\ \hline r^{BT} & | & r(0) \end{bmatrix} \quad (3.34)$$

Burada  $r(0)$  sürecin sıfır zaman farkı için öz ilişkisidir.

$$r^H = [r(1), r(2), \dots, r(M)] \quad (3.35)$$

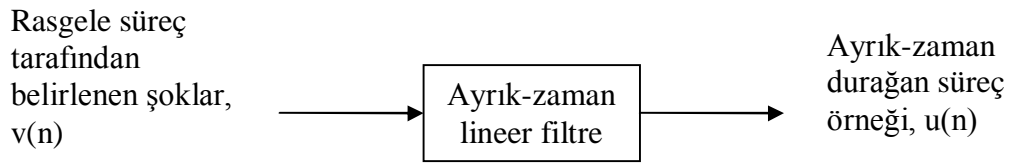
ve

$$r^{BT} = [r(-M), r(-M+1), \dots, r(-1)] \quad (3.36)$$

### 3.1.3.3. Durağan modeller

Model terimi; ilgilenilen verileri anlamakta yardımcı olan saklı kuralları açıklayan veya tanımlayan herhangi bir hipotez için kullanılır. Durağan bir sürecin bir modelle gösterilmesi Yule (1927) tarafından ortaya atılan bir fikre göre başlamıştır. Bu fikir; gözlemlerle yüksek derecede ilişkili olan bir zaman serisi,  $u(n)$ , birbirinden istatistiksel olarak bağımsız olan bir dizi şokun Şeki 3.2.'deki gibi lineer bir filtreye,  $v(n)$ , uygulanması ile elde edilebilmesidir.





Şekil 3.2. Rasgele süreç tarafından oluşturulan ayrık zaman Durağan süreç blok diyagramı

Şoklar genellikle sabit dağılım ile belirlenen rasgele değişkenlerdir. Bu dağılım genellikle sıfır ortalamalı ve sabit varyanslı gauss dağılımıdır. Özel olarak şekildeki girişi,  $v(n)$ , şu şekilde tanımlayabiliriz.

$$E[v(n)] = 0, \text{ bütün } n\text{'ler için} \quad (3.37)$$

$$E[v(n)v^*(k)] = \begin{cases} \sigma_v^2, & k = n \\ 0, & \text{aksitakdirde} \end{cases} \quad (3.38)$$

$\sigma_v^2$  burada gürültü varyansıdır.

Zaman domeninde şekilde belirtilen Durağan süreç için verilen giriş çıkış ilişkisi aşağıdaki şekilde yazılabilir.

$$\left( \begin{array}{c} \text{Modelin} \\ \text{çıkışının} \\ \text{şimdiki} \\ \text{değeri} \end{array} \right) + \left( \begin{array}{c} \text{Modelin çıkışının} \\ \text{geçmiş değerlerine ait} \\ \text{lineer kombinasyonu} \end{array} \right) = \left( \begin{array}{c} \text{Modelin girişinin geçmiş} \\ \text{ve şimdiki değerlerine ait} \\ \text{lineer kombinasyonu} \end{array} \right)$$

Şekil 3.3. Lineer filtre yapısı

Şekil 3.3.'de verilen lineer filtrenin yapısını denklemde belirtilen iki kombinasyonla belirlenir. Bu durağan modelleri popüler olan 3 yolla yapabiliriz.

1. Öz bağımlı (Autoregressive-AR) modeller
2. Hareketli Ortalamalı (Moving average) modeller
3. Öz bağımlı Hareketli Ortalamalı (Autoregressive- Moving Average) modeller

Öz bağımlı (Autoregressive) modeller:

M. dereceden bir zaman serisi,  $u(n)$ ,  $u(n-1)$ , ...,  $u(n-M)$ , eğer aşağıdaki fark denklemini sağlıyorsa M.dereceden bir öz bağımlı modeldir denir.

$$u(n) + a_1^* u(n-1) + a_2^* u(n-2) + \dots + a_M^* u(n-M) = v(n) \quad (3.39)$$

Burada  $a_1, a_2, \dots, a_M$  sabitleri ÖH parametreleri olarak adlandırılır.  $\{v(n)\}$  beyaz gürültü sürecidir. “Öz bağımlı” kelimesi tam anlayabilmek için denklemi tekrardan yazarsak.

$$u(n) = w_1^* u(n-1) + w_2^* u(n-2) + \dots + w_M^* u(n-M) + v(n) \quad (3.40)$$

Burada  $w_k = -a_k$ ’dır. Burada sürecin şuan ki değeri  $u(n)$ , sürecin geçmiş değerlerinin sonlu lineer kombinasyonları olan  $u(n-1)$ , ...,  $u(n-M)$  değerleri ile hata terimi olan  $v(n)$ ’nin toplamıdır. Bu sayede “öz-bağımlı” teriminin kullanım nedeni görülmüştür. Genellikle,  $x_1, x_2, \dots, x_n$  bağımsız değişkenleri ile bir hata terimi “v” ‘nin toplamıyla oluşan kümeye bağımlı olan  $y$  değişkeninden oluşan lineer modele bağımlı model olarak tanımlanır.

$$y = \sum_{k=1}^M w_k^* x_k + v \quad (3.41)$$

Denklem 3.40’da  $u(n)$  değişkeni kendisinin önceki değerlerine bağımlıdır. Bu yüzden öz bağımlı olarak isimlendirilir. Denklem 3.39’un sol tarafı  $u(n)$  giriş dizisinin ve  $a_n^*$  parametre dizisinin konvolüsyonunu göstermektedir. Bu denklemi konvolüsyon toplamı şeklinde tekrar yazarsak,

$$\sum_{k=0}^M a_k^* u(n-k) = v(n) \quad (3.42)$$

Burada  $a_0=1$ ’dir. Denklem 3.30’un her iki tarafının z-dönüşümünü alırsa,

$$V(z) = H_A(z).U(z) \quad (3.43)$$

$$H_A(z) = \sum_{n=0}^M a_n^* z^{-n} \quad (3.44)$$

$$U(z) = \sum_{n=0}^{\infty} u(n)z^{-n} \quad (3.45)$$


$$V(z) = \sum_{n=0}^{\infty} v(n)z^{-n} \quad (3.46)$$

Denklem 3.43'ün z-dönüşümü u(n) ÖB sürecinin kullanım şekline göre, yani giriş veya çıkış olmasına göre, iki türlü gösterim imkânı sağlar.

1. u(n)'i giriş olarak kabul eden Analiz metodu
2. u(n)'i çıkış olarak kabul eden Sentez metodu

Analiz metodu:

Beyaz gürültü  $\{v(n)\}$ 'i üretmek için ÖB bir süreç olan  $\{u(n)\}$ 'i giriş olarak kullanan Şekil 3.4'deki filtre kullanılır. Filtrenin parametreleri ÖB süreç  $\{u(n)\}$ 'nin parametreleri ile birebir eşleşme gösterir. Bu bağlamda, bu filtre  $H_A(z) = V(z) / U(z)$  ayrık transfer fonksiyonuna sahip süreç analizörünü gösterir. Süreç analizörünün dürtü yanıtı  $H_A(z)$ 'nin ters z-dönüşümüdür. Bu dönüşüm sonlu sürelidir. Görüldüğü gibi  $H_A(z)$ 'nin sadece sıfırları vardır. Böylece analiz modeli daima kararlıdır.



Şekil 3.4. Süreç analizörü

Sentez modeli:


ÖB süreç  $\{u(n)\}$ 'i üretmek için beyaz gürültü  $\{v(n)\}$ 'i giriş olarak kullanan Şekil 3.5'deki filtre kullanılır. Bu bağlamda sözü geçen filtre bir süreç üreticiyi temsil etmektedir. bu filtrenin transfer fonksiyonu;

$$H_S(z) = \frac{U(z)}{V(z)} = \frac{1}{H_A(z)} = \frac{1}{\sum_{n=0}^M a_n^* z^{-n}} \quad (3.47)$$

Süreç üreticinin dürtü yanıtı  $H_S(z)$ 'nin ters z-dönüşümüdür. Bu dönüşüm sonsuz sürelidir. Görüldüğü gibi  $H_S(z)$  sadece kutupları vardır. Bu nedenle sentez modelinin kararlılığı kutuplarının yeri tarafından belirlenir.

$$H_S(z) = \frac{1}{(1 - p_1 z^{-1})(1 - p_2 z^{-1}) \dots (1 - p_M z^{-1})} \quad (3.48)$$

Bu sürecin kararlı olabilmesi için bütün kutuplarının z-düzleminde bulunan birim çember içinde bulunması gerekmektedir.



Şekil 3.5. Süreç üretici

Wold Ayrıştırması:

Wold 1983 yılında, herhangi bir durağan ayrık zamanlı rasgele sürecin, bir genel doğrusal süreç ve bir deterministik sürecin toplamına eşit olduğu temel bir teoremi kanıtlamıştır.

$$x(n) = u(n) + s(n) \quad (3.49)$$

Burada;

- 1)  $u(n)$  ve  $s(n)$  ilişkisiz süreçlerdir.
- 2)  $u(n)$  denklem 3.50'deki gibi gösterilen bir doğrusal süreçtir.

$$u(n) = \sum_{k=0}^{\infty} b_k^* v(n-k) \quad (3.50)$$

$b_0=1$  ve


$$\sum_{k=0}^{\infty} |b_k|^2 < \infty \quad (3.51)$$

ve  $v(n)$ ,  $s(n)$  ile ilişkisiz beyaz gürültü sürecidir.

$$E[v(n)s^*(k)] = 0 \text{ (bütün } k \text{ ve } n \text{'ler için)} \quad (3.52)$$

3.  $s(n)$  deterministik bir süreçtir. Yani bu süreç bir öngörü varyansı ile ve kendi geçmişi ile öngörülebilir.


Bu sonuçlar Wold ayrıştırma teoremi olarak bilinir. Denklem 3.49'a göre; genel doğrusal bir süreç tüm sıfır filtre ve Şekil 3.6'daki gibi bir beyaz gürültü tarafından oluşturulabilir. Bu filtrenin transfer fonksiyonunun sıfırları denklemin köklerine eşittir.



Şekil 3.6. Genel doğrusal süreç oluşturulması için tüm sıfır filtreye dayanan model

$$\sum_{n=0}^{\infty} b_n^* z^{-n} \quad (3.53)$$

Bir tüm sıfır filtrenin bütün sıfırları  $z$ -domeninde birim çember içerisinde ise bu filtre için minimum fazlı denilebilir. Böyle bir durumda; Şekil 3.7'deki gibi tüm sıfır filtreyi, aynı darbe cevabına sahip  $(\{h_n\} = \{b_n^*\})$  tüm kutup filtre ile yer değiştirmek mümkündür.



Şekil 3.7. Genel doğrusal süreç oluşturulması için tüm kutup filtreye dayanan model

Öz bağımlı sürecin korelasyon fonksiyonu:

Bir öz bağımlı sürecin korelasyon fonksiyonu için ardışık bir ilişki bulmak istenmektedir.

$$u(n) + a_1^* u(n-1) + a_2^* u(n-2) + \dots + a_M^* u(n-M) = v(n) \quad (3.54)$$

Bu nedenle Denklem 3.54'deki eşitliğin her iki tarafına aynı ifadeyle çarpılıp beklendiği değer işlemi uygulanırsa,

$$E\left[\sum_{k=0}^M a_k^* u(n-k) u^*(n-l)\right] = E[v(n) u^*(n-l)] \quad (3.55)$$

Denklem 3.55'in sol tarafını, beklendiği değer ile toplama işlemi yer değiştirerek ve  $E[u(n-k)u^*(n-l)]$  ifadesinin bir "l-k" gecikmesi için ÖB sürecin oto korelasyon fonksiyonu olduğunu düşünerek sadeleştirebiliriz. Denklem 3.55'in sağ tarafını ise  $l > 0$  için 0 kabul edebiliriz. Bu sayede Denklem 3.55 aşağıdaki şekilde sadeleştirilmiş olur.

$$\sum_{k=0}^M a_k^* r(l-k) = 0, \quad l > 0 \quad (3.56)$$

Burada  $a_0=1$ 'dir. Burada ÖB sürecin oto korelasyon fonksiyonunun denklem 3.57'deki fark denklemini sağladığı gözlemlenmektedir.

$$r(l) = w_1^* r(l-1) + w_2^* r(l-2) + \dots + w_M^* r(l-M), \quad l > 0 \quad (3.57)$$

Burada  $w_k = -a_k$ 'dır. Bu fonksiyonun genel çözümü denklem 3.58'deki gibidir.

$$r(m) = \sum_{k=1}^M C_k p_k^m \quad (3.58)$$

Burada  $C_1, C_2, \dots, C_M$  sabitler ve  $p_1, p_2, \dots, p_M$  denklem 3.36'nın kökleridir.

Öz bağımlı modellerin karakterizasyonu:

M. dereceden bir öz bağımlı modeli tanımlayabilmek için bu modele ait katsayılarını ve varyansını belirlemek gerekir.

Yule-Walker denklemleri:

Denklem 3.57'i  $l=0, 1, \dots, M$  için yazarsak, ÖB sürecin bilinen  $r(0), r(1), \dots, r(M)$  ile ÖB sürecin bilinmeyen  $a_1, a_2, \dots, a_M$  ile gösterilen ÖB katsayılarını içeren M adet denklem yazılabilir. Bu denklemler bir matris şeklinde yazılabilir.

$$\begin{bmatrix} r(0) & r(1) & \cdot & \cdot & \cdot & r(M-1) \\ r^*(1) & r(0) & \cdot & \cdot & \cdot & r(M-2) \\ \cdot & \cdot & \cdot & & & \\ \cdot & \cdot & & \cdot & & \\ \cdot & \cdot & & & \cdot & \\ r^*(M-1) & r^*(M-2) & \cdot & \cdot & \cdot & r(0) \end{bmatrix} \begin{bmatrix} w_1 \\ w_2 \\ \cdot \\ \cdot \\ \cdot \\ w_M \end{bmatrix} = \begin{bmatrix} r^*(1) \\ r^*(2) \\ \cdot \\ \cdot \\ \cdot \\ r^*(M) \end{bmatrix} \quad (3.59)$$

Burada  $w_k = -a_k$ 'dır. Bu denklem kümesi Yule-Walker denklemleri olarak bilinir [28]. Yule-Walker denklemlerinin daha genel bir ifadesi Denklem 3.60'daki şekilde yazılabilir ve çözümü Denklem 3.61'deki gibidir.


$$Rw = r \quad (3.60)$$

$$w = R^{-1}r \quad (3.61)$$



### 3.1.4. Dalgacıklar ve dalgacık dönüşümü

Dalga genel olarak, sinüsoidal olarak zamanın salınım fonksiyonu şeklinde tanımlanır. Fourier analiz aslında dalga analizidir. Matematikte ve mühendislikte özellikle periyodik veya durağan durumlar için dalgaların sinüsoidal terimli fonksiyonlara açılımlarının oldukça değerli olduğu bilinmektedir. Dalgacık, süreksiz, durağan olmayan ve değişken-zamanlı durumlar için çözüm imkanı veren, enerjisi zaman domeninde yoğunlaşmış “küçük bir dalga” ‘dır. Dalgacıkta dalga benzeri salınım karakteristiğine sahiptir. Bununla birlikte dalgacık esnek matematiksel temeller ile aynı anda zaman - frekans çözümlenmelerine imkan verir. Şekil 3.8’de  $-\infty \leq t \leq +\infty$  aralığında salınım yapan sinüs dalgası ile aynı genliğe sahip dalgacık görülmektedir. Burada bir nokta etrafında dalga sonsuz enerjiye sahip iken dalgacık sonlu enerji yoğunluğuna sahiptir.



Şekil 3.8. a) Sinüs dalgası b) Daubechies dalgacığı (Burrus Sidney, Ramesh, Haitao 1998)

Dalgacık dönüşümü işareti çözünürlüğüne göre istenilen ölçekte farklı frekans parçalarına ayırarak inceleme imkanı veren matematiksel bir fonksiyondur. Dalgacık analizi durağan olmayan, süreksiz ve ani yükselmelere sahip olan işaretlerin analizinde fourier analizine göre daha başarılıdır. Dalgacık analizi günümüzde matematikçiler başta olmak üzere fizikçiler, biyomedikal işaret işlemeciler, elektronik mühendisleri, sismik araştırmacılar tarafından veri işlemede başarı ile kullanılmaktadır. Son zamanlarda özellikle protez uzuv kontrollerinde, görüntü sıkıştırma, deprem tahmini ve tıpta hekime yardımcı tanı tahminlerinde kullanılmaktadır.

### 3.1.4.1. Dalgacık açılımı ve dalgacık dönüşümü

Bir  $f(t)$  işareti veya fonksiyonu  $f(t) = \sum_l a_l \psi_l(t)$  (3.62) şeklinde bir doğrusal açılımla tanımlandığında daha iyi analiz edilip yorumlanabilir. Burada  $l$  sonlu bir indeks tamsayı,  $a_l$  gerçek değerlere sahip açılım katsayıları ve  $\psi_l(t)$  t'nin gerçek değerli açılım fonksiyonların kümesidir. Eğer burada açılım tekil ise açılım kümesi, bu küme ile ifade edilebilen işaretler için baz olur. Eğer baz ortogonal ise 3.62.'deki bağıntıdaki sonuç elde edilir.

$$(\psi_k(t), \psi_l(t)) = \int \psi_k(t) \psi_l(t) dt = 0 \quad k \neq l, \quad (3.63)$$

Buradan hareketle saklı bileşenler ile katsayılar 3.63 bağıntısındaki gibi hesap edilebilir.

$$a_k = (f(t), \psi_k(t)) = \int f(t) \psi_k(t) dt \quad (3.64)$$

3.64 bağıntısında 3.62'ü yerine koyup 3.63'i kullandığımızda  $a_k$  katsayılarını verecektir.

Dalgacık dönüşümü için iki parametreden oluşan 3.65 bağıntısındaki açılım kullanılmaktadır.

$$f(t) = \sum_k \sum_j a_{j,k} \psi_{j,k}(t) \quad (3.65)$$

3.65'de  $j$  ve  $k$  tamsayı indeksler  $\psi_{j,k}(t)$ 'ler ise genellikle ortogonal baz oluşturan dalgacık açılım fonksiyonlarıdır.  $a_{j,k}$  açılım kümesi katsayıları ise  $f(t)$  işaretinin ayrık dalgacık dönüşümü(ADD) olarak bilinir.

### 3.1.4.2. Dalgacık sistemi

Dalgacık açılım seti tekil değildir. Bu yüzden etkili olarak kullanılacak birçok farklı dalgacık sistemi tanımlanabilir [5].

- Bir dalgacık sistemi bir işareti oluşturmak için kullanılan temel yapıların kümesi olarak ifade edilebilir.
- Dalgacık açılımı, işaretin lokal zaman-frekans bilgisini verir. Bunun anlamı yeterli sayıda  $a_{j,k}$  katsayıları ile işaretin enerjisinin büyük kısmını tanımlanabilir.
- Etkili bir şekilde dalgacık dönüşümü katsayıları elde edilebilir. Birçok dalgacık dönüşümü yani açılım katsayıları  $O(N)$  operatörü ile hesaplanabilir. Dönüşümün zorluğu, işaretin uzunluğu ile doğru orantılıdır. Daha genel dalgacık dönüşümlerinde, KZFD(Kısa zaman fourier dönüşümü) ile aynı  $O(N \log(N))$  operatörüne ihtiyaç vardır [6].

Genel olarak bütün dalgacık sistemlerinin bu üç özelliğe sahip olduğu söylenebilir. Fourier serileri, 1-boyutlu sürekli değişkenli işareti dalgacık dönüşümü sonucu tekrar 1-boyutlu katsayı dizisine çevirirken dalgacık dönüşümü bu işareti 2-boyutlu katsayı dizisine çevirebilir. Dalgacık dönüşümü ile işaret hem frekans hemde zaman domeninde lokalize özelliğine sahiptir.

### 3.1.4.3. Dalgacık sistemlerinin özel karakteristikleri

Yukarıda 3.1.4.2. 'de açıklanan özelliklere ek olarak dalgacık sistemlerinin 3 önemli karakteristiği vardır.

- İlk zamanlardaki dalgacık sistemleri, tek bir skala fonksiyonu veya dalgacıktan sadece ölçekleme ve kaydırma işlemleri ile türetilmiştir. 2-boyutlu parametrikleştirme 3.66. bağıntısı kullanılarak elde edilmiştir. Burada  $\psi(t)$  ana dalgacık(mother wavelet) olup,  $Z$  tamsayılar kümesi ve  $2^{\frac{j}{2}}$  ise  $j$  ölçeğinden bağımsız olarak sabit durumu muhafaza eden katsayıdır. Böylece zamanın  $k$  ile, frekansında  $j$  ile lokalizasyonundan dalgacık sistemleri oldukça etkilidir.
- Hemen hemen bütün kullanışlı dalgacık sistemleri çoklu-çözünürlük(multi-resolution) şartlarını sağlamaktadır. Bunun anlamı eğer bir işaret uzayı

$\psi(t-k)$  ağırlıklı toplam ile ifade edilebiliyorsa, daha geniş bir küme  $\psi(2t-k)$  ağırlıklı toplamı ile ifade edilebilir. Yani temel açılım frekansları yarı genişlikte olsalar ve yarı mesafe kaydırılsalar daha geniş bir işaret uzayını tam olarak ifade edebilirler. Ayrıca herhangi bir işarete çok daha iyi yakınsama yapılabilir.

- Düşük çözünürlük katsayıları, yüksek çözünürlük katsayılarından filtre bankası denilen ağaç yapısında bir algoritma ile hesaplanabilir. Bu özellik, açılım katsayılarının çok etkili bir şekilde hesaplanmasını sağlamak ve ayrık dalgacık dönüşümü olarak bilinmektedir. Bu özelliği sayesinde dalgacık sistemleri sayısal işaret işlemede kullanılmaktadırlar.

Fourier dönüşümü ve diğer işaret analiz çözümleri kullanımına karar verildiğinde baza fonksiyonları seçilmiş olmaktadır. Neticede sonuçtaki dönüşüm özellikleri değerlendirilmektedir. Buna karşın dalgacık sistemlerinin kullanımında önce dönüşümün özellikleri belirlenmekte daha sonra baz fonksiyonları çıkarılmaktadır. Dolayısıyla özel bir uygulama için dönüşüm ihtiyaçlarına göre genel özelliklere sadık kalınarak dalgacık sistemi özelleştirilebilir. Eğer işaret analizi içine dalgacık dönüşümü seçildiyse yukarıdaki genel özellikleri sağlayan sosuz sayıda baz fonksiyon vardır.

#### 3.1.4.4. Haar ölçekleme fonksiyonu ve dalgacıklar

Çoklu çözünürlük formülasyonu hemen hemen birbirinin aynı olan iki baz fonksiyona ihtiyaç duyar. Bunun yanında dalgacık  $\psi(t)$  değerlendirilmiş olup, ölçekleme fonksiyonu olarak adlandırılan ( $\varphi(t)$ ) fonksiyona ihtiyaç duyacağız. En basit uygun dalgacık sistemi Haar ölçekleme fonksiyonu ve dalgacığından türetilir. 3.66. bağıntısında gösterildiği gibi ölçekleme fonksiyonu ile dalgacıkların kombinasyonu kullanılarak işaretlerin geniş bir kümesi gösterilebilir.

$$f(t) = \sum_{k=-\infty}^{\infty} ck\varphi(t-k) + \sum_{k=-\infty}^{\infty} \sum_{j=0}^{\infty} dj,k\varphi(2^j t - k) \quad (3.66)$$

### 3.1.4.5. Dalgacık analizi

Dalgacık açılımı ve dalgacık dönüşümünün çok çeşitli işaretlerin analizinde etkili olmasının sebepleri şunlardır.


- Dalgacık dönüşüm katsayılarının büyüklüğü  $j$  ve  $k$  arttıkça çok hızlı bir şekilde düşmektedir. Bu özellik koşulsuz (unconditional) baz olma özelliği olarak tanımlanmakta ve işaret sıkıştırma, gürültü arındırma ve konumlamada çok etkili olmaktadır. Donoho dalgacıkların çok geniş türde işaretlerin sıkıştırılması, gürültüden arındırılması ve konumlandırılması için optimale yakın sonuçlar verdiğini göstermiştir [7, 8].
- Dalgacık dönüşümü işaretin daha doğru lokal tanımlamasını yapmakta ve işaret özelliklerinin ayrıştırılabilmesine imkan vermektedir. Fourier katsayıları işaretle her zamanda bulunan bir bileşeni göstermektedir. Bu yüzden geçici olaylar faz karakteristikleri olarak ortaya çıkmaktadır. Oysa dalgacık dönüşüm katsayıları zaten kendisi lokal olan bileşenleri göstermektedir. Dalgacık dönüşümü zaman ve frekansta çakışan bileşenleri de ayrıştırmaktadır.
- Dalgacıklar ayarlanabilir ve uyarlanabilirler. Sadece bir tek dalgacık olmadığı için özel uygulamalara göre özel dalgacıklar oluşturulabilir. İşaretin durumuna göre kendini ayarlayan uyarlamalı sistemler için idealdirler.
- Dalgacıkların oluşturulması ve ayrık dalgacık dönüşümünün hesaplanması bilgisayarlar için çok uygundur. Dalgacıkları tanımlayan denklem çok karmaşık matematik gerektirmemektedir. İşlemlerde türev ve integraller yoktur, sadece temel çarpma ve toplama işlemleri vardır.

### 3.1.4.6. Dalgacıklar ve fourier dönüşümü

- Hızlı fourier dönüşüm (HFD) ve Ayrık dalgacık dönüşüm(ADD)'nin her ikisinde giriş işareti üzerinde doğrusal operasyonlardır.

- Dönüşümde kullanılan matrislerde benzer özelliklere sahiptir. HFD ve ADD için ters dönüşüm matrisleri, dönüşüm matrislerinin devriği olarak ortaya çıkmaktadır. Dolayısıyla iki işlemde fonksiyon uzayında başka domene bir rotasyon olarak düşünülebilir. HFD için rotasyon sonucu oluşan domenin baz fonksiyonları sinüs ve kosinüsler olurken dalgacık dönüşümü için yeni domenin baz fonksiyonları dalgacık, ana dalgacık (mother wavelet) veya analiz dalgacığı olarak adlandırılırlar.
- İki dönüşümünde baz fonksiyonları frekansta lokalize olmuşlardır. Bunun sonucu olarak güç spektrumu (power spectra ve ölçek grafikleri gibi matematiksel araçlar frekans bileşenlerini seçmek ve güç dağılımını hesaplamak için kullanılabilirler.
- İki dönüşüm arasındaki farklardan en dikkat çeken, dalgacık fonksiyonlarının uzayda lokalize olmasıdır. Fourier dönüşümdeki sinüzoidallerde ise bu özellik yoktur. Bu uzayda lokalizasyon özelliği dalgacıkların frekansta lokalizasyonu ile beraber dönüşümü çok etkili kılmakta ve dönüşüm sonucu "sparse" (çoğunluğu sıfır olan) bir yapı elde edilmektedir. Elde edilen bu yapı dalgacık dönüşümünü veri sıkıştırma, görüntü özniteliği çıkartma ve gürültü arındırma gibi işaret işleminin temel uygulamalarında etkin kılmaktadır.

Önemli bir farkta zaman-frekans analizinde ortaya çıkmaktadır. KZFD için pencere basitçe bir dikdörtgendir. Dolayısıyla bu pencere sinüs ve kosinüs fonksiyonların belli bir aralıkta almaktadır. Bütün frekanslar için aynı pencere kullanıldığı için analizin çözünürlüğü zaman-frekans düzleminde hep sabit kalmaktadır. Burada dalgacık dönüşümünün avantajı ortaya çıkar. Çünkü dalgacık dönüşümünde pencere değişmektedir. İşaret süreksizliklerini belirlemek için çok kısa baz fonksiyonları gerekebileceği gibi, detaylı frekans analizi için uzun baz fonksiyonları aynı anda gerekli olabilir. Bu durumda dalgacık dönüşümü kısa-yüksek frekans baz fonksiyonlarını sağladığı gibi, aynı anda, uzun-alçak frekans baz fonksiyonlarını da sağlar.



Şekil 3.9. ADD katsayıları ilişkisinin mozaïği (Burrus, Sidney, Ramesh, Haitao, 1998)


Hatırlanması gereken diğerk bir farkta dalgacık dönüşümünde baz fonksiyonlarının Fourier dönüşümünde olduđu gibi sadece bir küme olmaması, aksine sınırsız sayıda baz fonksiyonu kümesine sahip olmasıdır. Bu sayede uygulamaya yönelik özel çözümler yapılabilmektedir.

### 3.1.4.7. Sürekli dalgacık dönüşümü

Fourier analiz 3.67. 'deki gibi fourier dönüşüm ile gösterilmektedir.

$$F(\omega) = \int_{-\infty}^{\infty} f(t)e^{-j\omega t} dt \quad (3.67)$$

Dönüşüm sonunda Fourier dönüşüm katsayıları,  $F(\omega)$  elde edilmektedir. Bu katsayılar uygun  $\omega$  frekanslı sinüsel dalgalar ile çarpılıp, çarpım sonuçları toplanarak orijinal işaret tekrar elde edilmektedir.



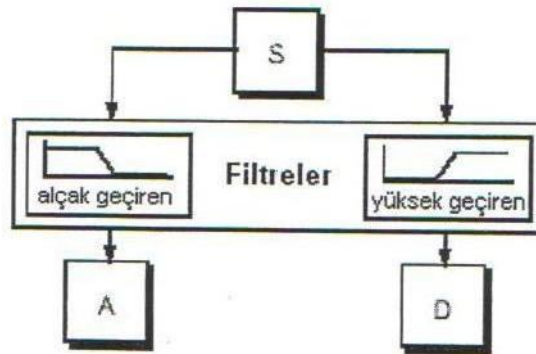
Şekil 3.10. Fourier dönüşümü yapılmış bir işaretin farklı frekanslarda sinüs dalgaları

### 3.1.4.8. Ayrık dalgacık dönüşümü

Mümkün olan bütün ölçekler için, dalgacık katsayılarının hesaplanması hem çok fazla uğraşmayı gerektirmekte hem de gerekli olmayan çok sayıda veri elde edilmesine sebep olmaktadır. Bundan dolayı ölçeklerin ve pozisyonların alt kümeleri seçilerek daha verimli bir dönüşüm yapılması gerekmektedir. Eğer ölçek ve pozisyon 2'nin kuvvetleri ( $2^n$  dyadic ölçek ve pozisyon) şeklinde seçilirse, analiz daha verimli olmakta daha hassas bir sonuç elde edilmektedir. Bu tip analiz ADD (ayrık dalgacık dönüşümü) ile mümkündür.

Tek katlı filtreleme:

Birçok işaret için alçak-frekans içeriği işaretin en önemli kısmıdır. Bu kısım işaretin kimliğini belirlemektedir. Yüksek-frekans içeriği işaretin ince detayları ile ilgili bilgi içermektedir. Örnek olarak insan sesi ele alınırsa, eğer ses işaretinden yüksek frekans kısmı çıkarılırsa, ses farklı bir ses gibi algılanmaktadır. Sesin ne söylediği ise rahat bir şekilde anlaşılabilir. Ancak bu sesin alçak-frekanslı kısmı atılırsa geriye ne olduğu anlaşılmayan bir ses kalmaktadır. Yaklaşım (approximation) işaretin yüksek ölçekli alçak-frekans bileşenidir. Ayrıntılar ise düşük ölçekli yüksek frekanslı bileşenlerdir [9]. Filtreleme işlemi temel olarak Şekil 3.11'deki gibi tanımlanmaktadır.




Şekil 3.11. İşaretin yaklaşım ve ayrıntı katsayılarına ayrılması

Orijinal işaret S, iki filtreden geçmekte ve iki işarete ayrılmaktadır. Fakat bu işlem gerçek dijital işaret üzerinde yapıldığında veri orijinal verinin iki katına çıkmaktadır.

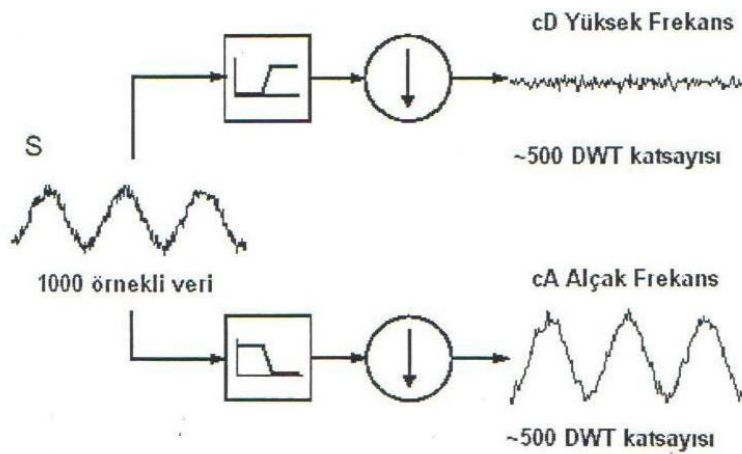


Örnek olarak S, 1000 örneklilik bir veri olsun. İşaret filtreden geçirilince, yaklaşım ve ayrıntı verileri 1000 örnekten oluşacak ve işaret 2000 örnekli veri olacaktır. Bu problemi gidermek için seyreltme yapılmaktadır. Fakat bu işlem sırasında örtüşme denilen hata ortaya çıkmaktadır.



Şekil 3.12. Yaklaşım ve ayrıntı katsayılarının seyrekleştirilmesi


Yukarıda şekil 3.12'in sağ tarafında da görüldüğü gibi seyreltme işlemi sırasında ADD katsayıları üretilmektedir. Bu işlemin daha kazançlı hale gelmesi için, işaretin tek-katlı dalgacık dönüşümü gerçekleştirilmektedir. Örnek olarak işaretin, yüksek frekanslı gürültü eklenmiş sinüs dalgası olduğunu kabul edelim. Şekil 3.13'de bu işaretin şematik şekli görülmektedir. İşaret alçak geçiren ve yüksek geçiren dalgacık filtrelerine girmekte daha sonra seyreltilmektedir. Çıkışta dalgacık katsayıları elde edilmektedir.




Şekil 3.13. Gürültü eklenmiş sinüs dalgasının filtrelenmesi ve seyreltilmesi

### Çoklu-seviye ayrıştırma:

Ayrıştırma işlemi ard arda tekrarlanarak, işaretin düşük çözünürlüklü bileşenlerine ayrılması mümkündür. Bu işleme dalgacık ayrıştırma denmektedir. Şekil 3.14. ve Şekil 3.15'de bir işaretin çoklu seviye ayrıştırması görülmektedir. Şekilde de görüldüğü işaretin birinci seviye ayrıştırmasından soma oluşan yaklaşım katsayıları yeni bir işaret gibi düşünülür ve tekrar dalgacık dönüşümü alınmaktadır. Bu işleme istenilen seviyeye ulaşıncaya kadar devam edilmektedir.



Şekil 3.14. Dalgacık ayrıştırma ağacı



Şekil 3.15. İşaretin çoklu seviye ayrıştırılması

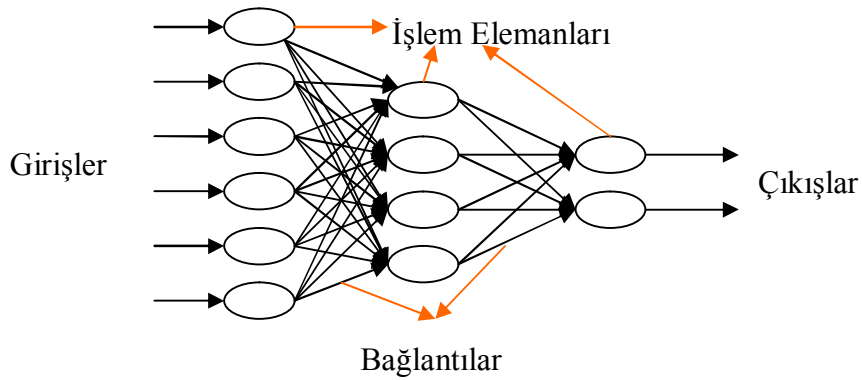
Seviye sayısı:

Analiz işlemi ard arda yapılabildiği için teorik olarak bu işlem sonsuza kadar tekrarlanabilir. Gerçekte ise ayrıştırma işlemi tek örneğe veya piksele ininceye kadar tekrarlanabilir. Pratikte işaretin yapışma göre uygun seviye sayısı seçilmekte veya entropy gibi kriterler dikkate alınarak ayrıştırma seviye sayısı belirlenmektedir.

## BÖLÜM 4. YAPAY SİNİR AĞLARI

Yapay Sinir Ağları, insan beyninin özelliklerinden olan öğrenme yolu ile yeni bilgiler türetebilme, yeni bilgiler oluşturabilme ve keşfedebilme gibi yetenekleri herhangi bir yardım almadan otomatik olarak gerçekleştirmek amacıyla geliştirilen sistemlerdir. Yapay Sinir Ağları, insanlar tarafından oluşturulan ve gerçekleştirilmiş örnekleri kullanarak olayları öğrenebilen, çevreden gelen olaylara karşı nasıl tepkiler üretebileceğini belirleyen sistemlerdir. İnsan beyninin fonksiyonel özelliklerine benzer şekilde öğrenme, ilişkilendirme, sınıflandırma, genelleme, özellik belirleme, optimizasyon gibi konularda başarılı bir şekilde uygulanmaktadır. Örneklerden elde ettikleri bilgiler ile kendi deneyimleri oluşturur ve daha sonra benzer konularda benzer kararları verirler.

Yapay Sinir Ağları (YSA) birçok probleme çözüm üretebilecek değişik şekillerde tanımlanabilir. Bunların en başında YSA birbirine hiyerarşik olarak bağlı ve paralel olarak çalışabilen yapay hücrelerden oluşmaktadır. İşlem elemanı olarak adlandırılan hücrelerin birbirlerine bağlandıkları ve her bağlantının bir değerinin olduğu kabul edilmektedir. İşlem elemanlarının birbirlerine bağlanmaları sonucu oluşan yapıya Yapay Sinir Ağı denir. Bu ağın oluşturulmasında biyolojik sinir sisteminden esinlenilmiştir.



Şekil 4.1. Bir yapay sinir ağı örneği

Bir yapay sinir ağının en temel görevi, kendisine uygulanan bir giriş kümesine ait bir çıkış kümesi oluşturmaktır. Bunun için ağın ilgili olaya ait örneklerle eğitilmesi gerekmektedir. Bu eğitim sayesinde ağa bir genelleme yeteneği kazandırılır. Bu yetenek sayesinde benzer olaylara karşı kullanabilecek duruma gelir.

Yapay sinir ağları aynı zamanda “bağlantılı ağlar“ “paralel dağıtılmış ağlara (parallel distributed networks )” ve “nöromorfik sistemler (neuromorphic systems)” olarak da adlandırılır.

#### 4.1. Yapay Sinir Ağlarının Genel Özellikleri

Yapay sinir ağlarının özellikleri uygulanan ağ yapısına göre değişiklik göstermektedir. Bu bölümde değişik modeller için genel geçerlilik gösteren özellikler ele alınacaktır.

- Yapay sinir ağları makine öğrenmesini gerçekleştirir.
- Yapay sinir ağlarında bilgi, ağın bağlantılarının değerleri ile ölçülmekte ve bağlantılarda saklanmaktadır.
- Yapay sinir ağları örnekleri kullanarak öğrenirler. Örnekleri kullanarak ilgilenilen olay hakkında genelleme yapabilecek yeteneğe kavuşur. Örnekler ise gerçekleşmiş olan olaylardır. Ağa olayla ilgili bütün değişkenleri kapsayan bir eğitime verisi uygulanamazsa başarılı sonuçların elde edilemez. Bu nedenle örneklerin etkin bir şekilde oluşturulması yapay sinir ağlarında çok önemli bir noktadır.
- Yapay sinir ağlarının güvenle çalıştırılabilmesi için önce eğitilmeleri ve performanslarının test edilmesi gerekir.
- Görülmemiş örnekler hakkında bilgi üretebilirler.
- Algılamaya yönelik uygulama ve olaylarda kullanılabilirler.
- Örüntü ilişkilendirme ve sınıflama yapabilirler.
- Örüntü tamamlama yapabilirler.
- Kendi kendine organize etme ve öğrenebilme yeteneklerine sahiptirler.
- Eksik bilgiler ile çalışabilmektedirler.
- Hata toleransına sahiptirler.

- Belirsiz, tam olmayan bilgileri işleyebilmektedirler.
- Dereceli bozulma gösterirler. Yapay sinir ağlarının hatalara karşı toleranslı olmaları bozulmalarının da dereceli olmasına neden olur. Bir ağ zaman içerisinde yavaş yavaş ve zarif bir şekilde bozulur. Bu bozulma eksik bilgiden veya hücrelerin bozulmasından kaynaklanır.
- Dağıtık belleğe sahiptirler. Yapay sinir ağlarında bilgi ağa yayılmış durumdadır. Hücrelerin birbirleriyle olan bağlantıların değerleri ağın bilgisini oluşturur. Bu yüzden ağ öğrendiği bilgilerle olayın bütünü karakterize eder. Bu ise dağıtık bir belleğin oluşmaktadır.
- Sadece nümerik bilgiler ile çalışmaktadırlar. Sembolik ifadelerle gösterilen bilgiler nümerik bilgilere çevrilmelidirler.

Yukarıda belirtilen bilgiler ile beraber her ağın kendine ait özellikleri bulunmaktadır.

#### **4.1.1. Yapay sinir ağlarının dezavantajları**

Bir önceki bölümde yapay sinir ağlarının birçok avantajlı yönlerinden söz edilmektedir. Bununla beraber yapay sinir ağlarının dezavantajlı özellikleri de vardır. Bu özelliklerden kısaca bahsedelim.

- Yapay sinir ağlarının donanıma bağımlı çalışmaları bir dezavantaj olarak görülebilir. Ağların temel var oluş nedenlerinden biride paralel işlemciler üzerinden çalışabilmeleridir. Günümüzdeki makinelerin çoğu seri şekilde çalışabilmektedir ve aynı zamanda sadece tek bir bilgiyi işleyebilmektedir. Paralel işlemleri seri makinelerde yaparken zaman kaybı olabilir.
- Probleme uygun ağ yapısının seçimi genellikle deneme yanılma yöntemi ile yapılmaktadır. Bu ise önemli bir problemdir. Eğer uygun ağ bulunamazsa çözümü olan sorunun çözülememesi veya performansı düşük çözümlerin elde edilmesi söz konusu olabilir.
- Bazı ağlarda ağ parametrelerinin seçimi için bir kuralın olmaması diğer bir problemdir. Bu parametrelerin belirlenmesi kullanıcının tecrübelerine dayanarak alacağı bir karardır.
- Ağın öğreneceği problemin ağa tanıtılması da bir diğer önemli sorundur.

- Ağın eğitiminin ne zaman bitirileceği hakkında yine genel geçer bir kural yoktur. Ağın örnekler üzerindeki hatasının belirli bir değerin altına indirilmesi eğitim tamamlanması için yeterli görülüp eğitim kesilmektedir.

Yukarıda belirtilen dezavantajlara rağmen yapay sinir ağları birçok probleme değişik şekillerde çözümler üretebilmekte ve başarılı uygulamalar sağlayabilmektedir.

## 4.2. Çok Katmanlı Algılayıcı Ağlar

Bir yapay sinir ağının öğrenmesi istenen olayların girdi ve çıktıları arasındaki ilişkiler doğrusal olmayan ilişkiler olursa basit algılayıcı (perceptron) gibi modellerle öğrenme gerçekleştirmek mümkün değildir. Bu tür olayların öğrenilmesi için daha gelişmiş modellere ihtiyaç vardır. Çok katmanlı ağ (ÇKA) modeli bu modellerden biridir. Olayın doğrusal olup olmadığı konusunu en iyi XOR problemiyle anlayabiliriz. Bu problemin özelliği doğrusal olmayan bir ilişkiyi göstermesidir. Yani çıktıların arasına bir doğru veya doğrular çizerek onları iki veya daha fazla sınıfa ayırmak mümkün değildir. Bu problem Tablo 4.1’de gösterilmektedir.


Tablo 4.1. XOR problemi

X <sub>1</sub>	X <sub>2</sub>	Çıkış (Y)
0	0	0
0	1	1
1	0	1
1	1	0

XOR problemini çözmek amacıyla yapılan çalışmalar sonucunda çok katmanlı algılayıcı ağları (ÇKA) geliştirilmiştir. Rumelhart ve arkadaşları (Rumelhart ve Hinton ve Williams, 1986) tarafından geliştirilen bu modele hata yayma modeli veya geriye yayılım modeli (backpropagation network) de denmektedir. ÇKA modeli yapay sinir ağlarına olan ilgiyi arttırmıştır. Bu modeller özellikle sınıflandırma, tanıma ve genelleme yapılması gereken problemlerde kullanılırlar. Bu model Delta öğrenme kuralı denen bir öğrenme yöntemini kullanırlar.

#### 4.2.1. Çok katmanlı ağların yapısı

Çok katmanlı ağların yapısı Şekil 5.2.'deki gibidir.



Şekil 4.2 Çok katmanlı ağ yapısı

Şekil 4.2'de görüldüğü gibi ÇKA modeli üç katmandan oluşmaktadır. Bu katmanlar sırasıyla giriş katmanı, saklı katman, çıkış katmanıdır.

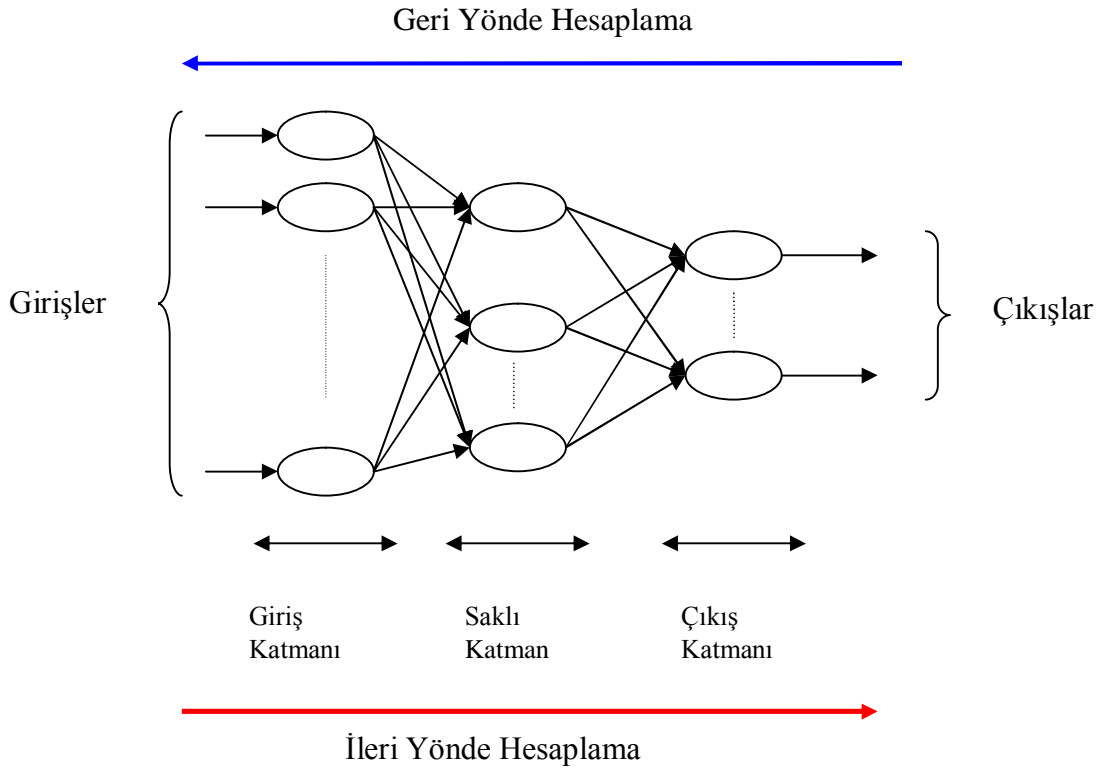
- Giriş Katmanı: Probleme ait verilerin geldiği katmandır. Bu katmanda bilgi işleme olmaz. Gelen her bilgi geldiği gibi bir sonraki katmana yani saklı katmana iletilir.
- Saklı Katman: Giriş katmanından gelen bilgiler bu katmanda işlemlerden geçer. Saklı katman sayısı ile ilgili bir sınırlama yoktur. Saklı katmandaki her işlem elemanı sonraki katmanlardaki her bir işlem elemanına bağlantısı vardır.
- Çıkış Katmanı: Saklı katmandan gelen bilgileri işleyerek ağa giriş katmanından verilen bilgilere ait çıkışları üretir. Çıkış katmanında birden fazla işlem elemanı bulunabilir. Her işlem elemanın sadece bir çıkışı vardır.



#### 4.2.2. Çok katmanlı ağlarda öğrenme

ÇKA ağlarda eğitici öğrenme kullanılır. Ağa hem örnekler hem de bu örneklere ait çıktılar verilir. Ağ bu verilere göre genelleme yapar ve daha sonra gelen verilere bu genellemeye dayanarak çıktılar üretir. Bu ağ tipinin kullandığı öğrenme kuralı en küçük kareler yöntemini kullanan delta öğrenme kuralının genelleştirilmiş halidir. Ağın öğrenebilmesi için bir eğitime kümesine ihtiyacı vardır. Genelleştirilmiş Delta Kuralı iki fazdan oluşmaktadır.

1. İleri doğru hesaplama: Ağın çıktısını hesaplama fazıdır.
2. Geriye doğru hesaplama: Ağırlıkları değiştirme fazıdır.



Şekil 4.3 Çok katmanlı ağlarda öğrenme

1. İleri doğru hesaplama: Bu safhada bilgi işleme eğitim kümesindeki bir örneğin giriş katmanından ( $x_1, x_2 \dots$ ) ağa verilmesi ile başlar. Bilindiği üzere giriş katmanında herhangi bir işlem yapılmaz. Gelen girdiler hiçbir değişiklik olmadan saklı katmana gönderilirler. Burada işlem elemanlarına gelen girişler ağırlıklar ( $w_1, w_2, \dots$ ) ile işlenerek net girdi "F(NET)" elde edilir.

$$NET_j^a = \sum_{k=1}^n w_{kj} x_k^i \quad (4.1)$$

Burada “ $w_{kj}$ ” giriş katmanı işlem elemanını j. ara katman elemanına bağlayan bağlantının ağırlık değerini göstermektedir. j. ara katman elemanının çıktısı ise bu net girdinin aktivasyon fonksiyonundan geçirilmesiyle hesaplanır. Önemli olan kullanılan aktivasyon fonksiyonunun türevinin alınabilir olmasıdır. Çünkü geriye doğru hesaplama fazında bu fonksiyonun türevi alınacaktır. Bu nedenle net girdinin hesaplanmasında kullanılan aktivasyon fonksiyonunun bu kritere uyan herhangi bir fonksiyon olması gerekmektedir. Aktivasyon fonksiyonu olarak “Sigmoid” fonksiyonu kullanılırsa

$$y_j^a = \frac{1}{1 + e^{-(F(NET)_j^a + \beta_j^a)}} \quad (4.2)$$

Burada “ $\beta_j$ ” , ara katmanda bulunan j. elemana bağlanan eşik değer elemanının ağırlığını göstermektedir. bu eşik değeri elemanının çıkışı sabit olup 1’e eşittir. Ağırlık değeri ise sigmoid fonksiyonunun uyumunu belirlemek üzere konulmuştur. Eğitim esnasında ağ bu değeri kendisi belirlemektedir.

Saklı katmanın bütün işlem elemanları ve çıkış katmanının işlem elemanlarının çıkışlarının aynı şekilde kendilerine gelen net girdinin hesaplanması ve aktivasyon fonksiyonuna tabi tutulması sonucu belirlenir. çıkış katmanından çıkan değerler bulununca ağın ileri yönde hesaplama işlemi bitmiş olur.

2. Geriye Doğru Hesaplama: Ağa sunulan giriş için ağın ürettiği çıkış beklenen çıkışlarla ( $d_1, d_2, \dots$ ) karşılaştırılır. Bunların arasındaki fark hata olarak kabul edilir. Amaç bu hatanın düşürülmesidir. Bundan dolayı geriye doğru hesaplamada bu hata ağın ağırlık değerlerine dağıtılarak bir sonraki adımda hatanın azaltılması sağlanır. Çıkış katmanındaki m. işlem elemanı için oluşan hata;

$$E_m = d_m - y_m \quad (4.3)$$

şeklinde. Bu bir işlem elemanı için oluşan hatadır. Çıktı katmanı için oluşan toplam hatayı (TH) bütün hataların toplanması gerekmektedir. Bazı hata değerleri negatif olacağından toplamın sıfır olmasını önlemek amacıyla ağırlıkların kareleri alınarak sonucun kare kökü alınır. Toplam hata şu formülle bulunur.

$$TH = \frac{1}{2} \sum_m E_m^2 \quad (4.4)$$

Toplam hatayı en aza indirmek için hatanın kendisine neden olan işlem elemanlarına dağıtılması gerekmektedir. Bu da işlem elemanlarının ağırlıklarını değiştirmek demektir. Ağırlıkların değiştirilmesi için iki durum söz konusudur.

- Saklı katman ile çıkış katmanı arasındaki ağırlıkların değiştirilmesi
- Saklı katmanlar arası veya giriş katmanı arasındaki ağırlıkların değiştirilmesi

Saklı katman ile çıkış katmanı arasındaki ağırlıkların değiştirilmesi

Saklı katmandaki j. işlem elemanı ile çıkış katmanındaki m. işlem elemanına bağlayan bağlantının ağırlığındaki değişim miktarına  $\Delta w^a$  denirse; herhangi bir "t" anında ağırlığın değişim miktarı şöyle hesaplanır.

$$\Delta w_{jm}^a(t) = \alpha \delta_m x_j^a + \eta \Delta w_{jm}^a(t-1) \quad (4.5)$$

Burada  $\alpha$  öğrenme katsayısı,  $\eta$  ise momentum katsayısını göstermektedir. öğrenme katsayısı ağırlıkların değişim miktarını, momentum ise ÇKA ağırlık öğrenmesi esnasında yerel bir optimum noktaya takılıp kalmaması için ağırlık değişim değerinin belirli bir oranda bir sonraki değişime eklenmesini sağlar. Denklem 4.5'deki " $\delta_m$ " ise m. çıkış ünitesinin hatasını göstermektedir. Hesaplanma şekli Denklem 4.6'daki gibidir.

$$\delta_m = f'(NET).E_m \quad (4.6)$$

Buradaki  $f'$ (NET) aktivasyon fonksiyonunun türevidir. Sigmoid fonksiyonunun kullanılması durumunda;

$$\delta_m = y_m(1 - y_m).E_m \quad (4.7)$$

olacaktır. Değişim miktarı hesaplandıktan sonra ağırlıkların  $t$ . adımdaki yeni değerleri şöyle olacaktır.

$$w_{jm}^a(t) = w_{jm}^a(t-1) + \Delta w_{jm}^a(t) \quad (4.8)$$

Benzer şekilde eşik değer ünitesinin de ağırlıklarının değiştirilmesi gerekmektedir. Bu yüzden öncelikle değişim miktarını hesaplamak gerekir. Eğer çıkış katmanında bulunan işlem elemanlarının eşik değer aralıkları  $\beta^c$  ile gösterilirse;

$$\Delta\beta_m^c(t) = \alpha\delta_m + \eta\Delta\beta_m^c(t-1) \quad (4.9)$$

olacaktır. Eşik değerinin  $t$ . adımdaki ağırlığının yeni değeri ise,

$$\beta_m^c(t) = \beta_m^c(t-1) + \Delta\beta_m^c(t) \quad (4.10)$$

şeklinde hesaplanır.

Saklı katman ile çıkış katmanı arasındaki ağırlıkların değişiminde her ağırlık için sadece çıkış katmanındaki bir işlem elemanının hatası dikkate alınmıştır. Bu hataların oluşmasında giriş katmanı ile saklı katman arasındaki ağırlıkların payı vardır. Çünkü en son saklı katmana gelen bütün bilgiler giriş katmanı veya önceki saklı katmanlardan gelmektedir. O nedenle giriş katmanı ile saklı katman arasındaki veya iki saklı katman arasındaki ağırlıkların değiştirilmesinde çıkış katmanındaki işlem elemanlarının hepsinin hatası dikkate alınmalıdır. Mesela giriş katmanı ile çıkış katmanı arasındaki ağırlıkların değişimi  $\Delta w^i$  ile gösterilirse değişim miktarı;

$$\Delta w_{kj}^i(t) = \alpha\delta_j^a x_k^i + \eta\Delta w_{kj}^i(t-1) \quad (4.11)$$

olacaktır. Buradaki hata terimi  $\delta^a$  ise;

$$\delta_j^a = f'(NET) \sum_m \delta_m w_{jm}^a \quad (4.12)$$

şeklindedir. Aktivasyon fonksiyonu olarak sigmoid fonksiyonu düşünülürse bu hata değeri aşağıdaki şekilde hesaplanacaktır.

$$\delta_j^a = y_j^a (1 - y_j^a) \sum_m \delta_m w_{jm}^a \quad (4.13)$$

Hata değeri hesaplandıktan sonra yukarıda verilen eşitlik ile değişim miktarını bulmak mümkündür. Ağırlıkların yeni değerleri aşağıdaki şekildedir.

$$w_{kj}^i(t) = w_{kj}^i(t-1) + \Delta w_{kj}^i(t) \quad (4.14)$$

Benzer şekilde, eşik değer ünitesinin yeni ağırlıkları da yukarıdaki gibi hesaplanır. Saklı katman eşik değer ağırlıkları  $\beta^a$  ile gösterilirse değişim miktarı;

$$\Delta \beta_j^a(t) = \alpha \delta_j^a + \eta \Delta \beta_j^a(t-1) \quad (4.15)$$

olacaktır. Ağırlıkların yeni değerleri ise t. adımda şöyle hesaplanacaktır.

$$\beta_j^a(t) = \beta_j^a(t-1) + \Delta \beta_j^a(t) \quad (4.16)$$

Bu sayede ağırlıkların hepsi değiştirilmiş olacaktır. Bir adım hem ileri hem de geriye hesaplamaları yapılarak tamamlanmış olacaktır. İkinci bir örnek verilerek sonraki adıma başlanır ve aynı işlemler öğrenme tamamlanıncaya kadar yinelenir.

### 4.3. Radyal Temelli Ağlar

Yapay Sinir Ağlarının bir türü olan Radyal Temelli Fonksiyon Ağları (RTFA) 80'lerin sonunda ortaya çıkmıştır. Bu ağların kökleri; potansiyel fonksiyonlar,

kümeleme (clustering), fonksiyonel yaklaşım gibi eski örüntü tanıma yöntemlerine dayanmaktadır (Tou ve Gonzalez, 1974). RTFA saklı her ünitesi Radyal fonksiyonları temsil eden iki katmanlı bir yapay sinir ağıdır. Ağın çıkışı saklı ünitelerin çıkışlarının toplamıdır. RTFA'nın girişi non-lineer iken çıkışları lineerdir. Bu ağların lineer olmayan yaklaşım fonksiyonlarından dolayı, RTFA'lar karmaşık haritalamalarda modelleme için kullanılmaktadır. Bu durumlarda perceptron ağları birçok katmanlar kullanarak ancak bu işlemi yapabilmektedir (Haykin, 1994).

Radyal Temelli Fonksiyon Ağlarını kullanabilmek için bazı tanımları belirlemek gerekir. Bunlar; saklı ünitelerin aktivasyon fonksiyonu, öğrenme algoritması, işlemci ünitelerin sayısı gibi parametrelerdir. RTFA'nın ağırlıklarının bulunması ağın eğitilmesidir. Eğer elimizde eğitime kümesi olarak bilinen giriş ve çıkış çiftleri bulunuyorsa; elde edilen çıkışların bilinen çıkışlara göre optimize ederek ağın parametreleri bulunur. Bu parametreleri hesaplarken genelde ortalama karesel hata (mean square error) yöntemi kullanılmaktadır. Eğitimden sonra, RTFA eğitime verisine benzer özellikteki veri için kullanılabilir.

RTF ağları; interpolasyon (Broomhead ve Lowe, 1988; Matej ve Lewitt, 1996), kaotik zaman serileri modelleme (Moody, 1989; Casdagli, 1989), sistem tanımlama, kontrol mühendisliği (Saner ve Slotine, 1994), elektronik aletlerin parametre modellemesi, kanal eşitleme (Bors ve Gabbouj, 1994), ses tanıma (Niranjan ve Fallside, 1990), görüntüleri yenileme (Cha ve Kassam, 1996), 3-D modelleme (Bors ve Pitas, 1999), hareket tahmini (Bors ve Pitas, 1998) gibi geniş çaplı uygulamalarda kullanılmaktadır.

#### **4.3.1. Ağ topolojisi**

Radyal Temelli Fonksiyonlar 2-katmanlı ileri beslemeli Yapay Sinir Ağının içine gömülmüştür. Böyle bir ağ giriş kümesi ve çıkış kümesi ile karakterize edilmektedir. Giriş ve çıkışların arasında saklı birimler olarak tanımlanan işlem elemanlarından oluşan bir katman bulunmaktadır. Bu birimlerin her biri Radyal temelli fonksiyonları yerine getirmektedir. Örüntü tanıma ve zaman serileri analizinde kullanılan ağlarda veri modelleme yöntemleri farklılık göstermektedir. Birinci durumda, girişler belirli

bir aralıkla örneklenmiş geçmişe ait veri örneklerini göstermektedir ve işaret değerini temsil eden bir çıkıştan oluşmaktadır. Örüntü tanıma uygulamasında giriş özellik değerlerini ve her çıkışta bir sınıfı göstermektedir. Saklı birimlerse alt sınıfları göstermektedir.

İlk katman; giriş vektörleriyle merkez vektörleri arasındaki uzaklığa bağlı çok boyutlu bir fonksiyondur. RTF ağının ilk katmanı depolanmış veri kümelerinin ağ girişlerine ne kadar uzak olduğunu hesaplar. Giriş katmanından saklı katmana olan bağlantıların ağırlıksız olduğu düşünülür. Her bir temel fonksiyon burada hesaplanan bir uzaklıkla ilişkili bir fonksiyondur. En fazla bilinen uzaklık ölçüsü denklem 4.17’de gösterilen “Euclidean” uzaklığıdır. Bir diğer uzaklık çeşidi ise denklem 4.18’de gösterilen “Hamming” uzaklığıdır.

$$r = \|x - c\| \quad (4.17)$$

$$D = \sum_k |x_k - c_k| \quad (4.18)$$

Radyal temelli fonksiyon ağlarının genel formülü ise aşağıdaki şekildedir.

$$F(x) = \sum_{i=1}^N w_i \phi(\|x - c\|) \quad (4.19)$$

Bu ağlarda RTF seçildikten sonra yapılması gereken en önemli şey veri uzayını doğru bir şekilde ayırmak için ağırlık parametrelerinin belirlenmesidir. Temel bir RTF ağında merkezler ve uzaklık ölçekleme (genişlik,  $\sigma$ ) parametreleri genellikle sabit tutulur ve öğrenme işlemi anında değiştirilmezler. Sadece ağırlıklar güncellenir. Aşağıdaki tabloda en önemli Radyal temelli fonksiyonlar verilmiştir.

Tablo 4.2 Çeşitli radyal temelli fonksiyonlar

Fonksiyon adı	$\varnothing(r)$
Parçalı doğrusal yaklaşım	r
Kübik yaklaşım	$r^3$
Gauss fonksiyonu	$\exp(-r^2/\sigma^2)$
Multi-kuadratik fonksiyon	$\sqrt{r^2 + \sigma^2}$
İnce tabaka eğrileri	$r^2 \log(r)$
Ters Multi-kuadratik fonksiyon	$\frac{1}{\sqrt{r^2 + \sigma^2}}$

#### 4.3.2. Radyal temelli ağların eğitilmesi

Radyal Temelli fonksiyon ağlarının eğitilmesi genelde 3 adımda yapılır. Bu adımlar merkezlerin yerleştirilmesi, ölçekleme parametrelerinin bulunması, ağırlıkların eğitilmesi adımlarıdır.

Merkezlerin yerleştirilmesi:

Bir merkezle bu merkeze karşı gelen saklı katman işlem elemanı, eğitme kümesindeki her bir giriş vektörüne yerleştirilebilir. Bu yöntemin dezavantajı gereğinden fazla saklı katman işlem elemanının karşımıza çıkmasıdır. Bu da uzun eğitim ve çok sayıda hesaplama ortaya çıkarır.

En basit teknik merkez vektörlerini eğitme verilerinin bir alt kümesinden rasgele seçmektir. Böyle bir durumda saklı işlem elemanlarının sayısı bütün giriş uzayını kapsıyacak şekilde geniş olmalıdır.

Ölçekleme parametrelerinin belirlenmesi:

Ölçek parametrelerinin belirlenmesinin amacı; giriş uzayının mümkün olduğu kadar alıcı alanlarla kaplamaktır. Merkezler birbirinden çok uzaksa uzaklık ölçekleme



parametresi “ $\sigma$ ” yeterince büyük olmalıdır. Merkezler birbirine çok yakınsa tersi durum söz konusudur.

Ağırlıkların eğitilmesi:

Hatayı istenen bir değere minimize edecek şekilde saklı katman ve eğitim çıkış verilerini kullanarak en küçük kareler metoduyla saklı katmandan çıkışa olan ağırlıklar ayarlanır.

### **4.3.3. Radyal temelli ağların öğrenme algoritmaları**

Sabit merkezlerle en küçük kareler algoritması:

Bu yöntemde RTFA merkezlerinin yerleşimlerini ağ giriş vektörlerinden veya giriş verilerinin bulunduğu bölgeden rasgele seçilir. Merkezler sabitlendikten sonra eğitici moda en küçük kareler metoduyla ağırlıklar güncellenir.

Ortogonal en küçük kareler algoritması:

Bu yöntemde RTFA için tek bir merkez alınır ve hata kontrolü yapılır. Hata istenilen seviyede değilse bir merkez daha eklenir. İstenilen seviyeye ulaşıldığında merkez eklenmesi kesilir ve ağ eğitici moda geçer ve en küçük kareler yöntemi ile ağırlıklar güncellenir.

İteratif Kümeleme ve en küçük kareler algoritması:

RTFA merkezleri iteratif bir kümeleme algoritması kullanılarak ayarlanır. Bu işlem kendi kendine organize (self - organizing) olan bir işlemdir. Çıkış katmanının ağırlıkları eğitici bir öğrenme kuralı kullanılarak hesaplanır ve güncellenir.

#### 4.4. LVQ Ağı

Bazı durumlarda ağa çıktının ne olduğunu vermek mümkün olamamaktadır; fakat, ağın üretmiş olduğu çıktının doğru veya yanlış olduğu belirtilebilmektedir. Destekleyici öğrenme olarak belirlenen bu yöntemi kullanan modellerin bir tanesi doğrusal vektör parçalama modeli diyebileceğimiz LVQ (Linear Vektör Quantization) modelidir. Bu bölümde bu model ayrıntılarıyla ele alınmaktadır.

##### 4.4.1. LVQ ağının özellikleri

LVQ ağı Kohonen tarafından 1984 yılında geliştirilmiştir [29]. Temel felsefesi n boyutlu bir vektörü bir vektörler setine haritalamaktır (uydurmaktır). Aslında bir vektörün belirli sayıda vektörler ile gösterimi amaçlanmaktadır. Öğrenme ile de girdi vektörünün hangi vektör seti tarafından temsil edilmesi gerektiği bulunmak kastedilmektedir. Bu vektör setine referans vektörleri denirse LVQ ağının görevi öğrenme yolu ile bu referans vektörleri belirlemektir. Yani, girdi vektörlerinin üyesi olabilecekleri vektör sınıfını belirlemektir.

LVQ ağları genel olarak sınıflandırma problemlerinin çözümünde kullanılmaktadırlar. Çıktılardan sadece birisi 1 diğerleri 0 değerlerini almaktadırlar. Çıktı değerinin 1 olması girdinin ilgili çıktının temsil ettiği sınıfa ait olduğunu göstermektedir.

Eğitim sırasında girdilerin sınıflara ayrılması en yakın komşu (nearest neighbour) kuralına göre gerçekleştirilmektedir. Girdi vektörü ile referans vektörleri arasındaki en kısa mesafe aranmakta ve girdi vektörünün en kısa mesafede bulunan vektör grubuna ait olduğu varsayılmaktadır. Ağın ağırlıklarının değiştirmek yolu ile girdileri doğru sınıflara ayıracak referans vektörleri belirlenmektedir. Kullanılan öğrenme stratejisi destekleyici (reinforcement learning) öğrenmedir. Çıktı değerlerinin belirlenmesinde ise "kazanan herşey alır" (winner takes all) stratejisi uygulanmaktadır. Ağ eğitilirken her iterasyonda ağın ürettiği çıktının değeri yerine sadece doğru olup olmadığı söylenir. Sadece girdi vektörüne en yakın olan vektör'ün (kazanan vektör) değerleri (ağın bu vektöre ait ağırlıkları) değiştirilir.

Diğer ağlarda olduğu gibi LVQ ağında da ağırlıklar öğrenme katsayısına göre değiştirilmektedir. Kullanılan öğrenme katsayısının zaman içerisinde sıfır olacak şekilde monoton olarak azaltılması istenmektedir. LVQ ağının öğrenme hızı da ÇKA gibi ağlara göre daha yüksektir. Yani LVQ ağı bir olayı ÇKA ağlarından daha kısa zamanda öğrenebilmektedir.

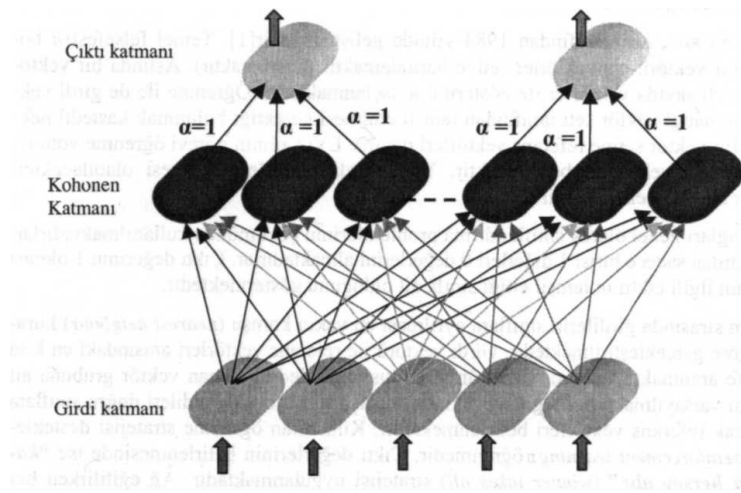
#### 4.4.2. LVQ ağının yapısı

ÇKA'larda olduğu gibi LVQ ağları da 3 katmandan oluşmaktadır. Şekil 4.4.'de bu katmanları göstermektedir.

Girdi katmanı: Bu katmanda bilgi işleme olmaz. Dış dünyadan alınan örneklerin ağa gösterilmesi bu katmanda sağlanmaktadır. Gelen bilgiler girdi vektörünü oluşturur.

Kohonen katmanı (ara katmanda denmektedir). Bu katmanda girdi setine en yakın olan ağırlık vektörü belirlenmektedir. Bu katmandaki her eleman bir referans vektörünü göstermektedir. Girdi vektörü, girdi katmanı ile Kohonen katmanı arasındaki ağırlıkların oluşturduğu referans vektörlerine haritalanmaktadır.

Çıktı katmanı: Bu katmanda ise girdinin ait olduğu sınıf belirlenir.



Şekil 4.4 LVQ ağının topolojik yapısı

Şekil 4.4.'de görüldüğü gibi LVQ ağırlı girdi katmanı ile Kohonen katmanı arasında tam bağlantılı, Kohonen katmanı ile çıktı katmanı arasında ise kısmi bağlantılıdır. Yani Girdi katmanındaki her proses elemanı Kohonen katmanındaki her proses elemanına bağlıdır. Kohonen katmanındaki proses elemanları ise sadece çıktı katmanındaki bir tek proses elemanına bağlıdır. Kohonen katmanı ile çıktı katmanı arasındaki ağırlıklar ( $a$ ) sabit olup 1 'e eşittir. Yani bu ağırlıkla değişmezler. Sadece girdi katmanı ile Kohonen katmanı arasındaki ağırlıklar değiştirilirler. Öğrenme bu ağırlıklar üzerinden gerçekleştirilir. Kohonen katmanında kaç tane proses elemanı var ise o kadar referans vektörü oluşacaktır. Referans vektörü girdi değerlerini Kohonen katmanındaki proses elemanlarına bağlayan bağlantıların ağırlık değerlerinden oluşur. Dolayısı ile referans vektörünün eleman sayısı girdi katmanındaki eleman sayısı kadardır.

Kohonen ve çıktı katmanlarındaki proses elemanlarının çıktıları ikili (binary) değerler olup sadece bir proses elemanının çıktısı 1 diğerlerinin ki ise 0'dır. Kohonen katmanında proses elemanları birbirleri ile yansır. Yansı kazanan proses elemanının çıktısı 1 değerini alır diğerlerinin çıktısı ise 0 olur. Hangi proses elemanının yarışı kazandığına öğrenme kuralına göre karar verilir. Kohonen katmanında hangi proses elemanının çıktısı 1 olursa onun bağlı olduğu çıktı katmanındaki proses elemanının çıktısı 1 değerini alır diğerlerinin çıktısı da 0 olur. Böylece ağı sunulan bir girdi için çıktı katmanında sadece bir proses elemanının çıktısı 1 olmakta ve girdi vektörü o çıktının gösterdiği sınıfın üyesi kabul edilmektedir. Öğrenme ile girdi için doğru sınıfın belirlenmesi sağlanmaktadır.

#### 4.4.3 . LVQ ağırlı çalışma prosedürü

LVQ ağırlı kullanmak için şu prosedürü izlemek gerekmektedir:

1. Örneklerin belirlenmesi
2. Ağırlı topolojisinin belirlenmesi (girdi ve çıktı sayısının belirlenmesi, referans vektör sayısının belirlenmesi)
3. Ağırlı öğrenme parametrelerinin belirlenmesi (öğrenme katsayısı ve
4. istenen sabit değerlerin belirlenmesi)

5. Ağırlıkların başlangıç değerlerinin atanması
6. Öğrenme setinden bir örneğin ağa gösterilmesi
7. Kazanan proses elemanının bulunması
8. Ağırlıkların değiştirilmesi
9. Bütün örnekler doğru sınıflandırılıncaya kadar yukarıdaki adımları  
(5-7) tekrar etmek...

Bir LVQ ağının performansı doğru sayıda referans vektörünün belirlenmesi, ağırlıkların başlangıç değerleri ve öğrenme katsayısının belirlenmesi ile yakından ilgilidir. Bunları belirlerken tasarımcıların çok dikkatli olmaları ve tecrübelerini kullanmaları gerekmektedir.

#### 4.4.4. LVQ ağının öğrenme kuralı

LVQ ağının öğrenme kuralına Kohonen öğrenme kuralı da denmektedir. Öğrenme kuralı, Kohonen tabakasındaki proses elemanlarının birbirleri ile yarışmaları ilkesine dayanır. Yarışma girdi vektörü ile ağırlık vektörleri (referans vektörler) arasındaki öklid (euclid) mesafesinin hesaplanmasına dayanmaktadır. Hangi proses elemanının referans vektörü girdi vektörüne en yakın ise o yarışmayı kazanmaktadır. Girdi vektörü  $X$  ile referans vektörü  $A$  arasındaki mesafe  $d$  ile gösterilirse;  $i$ . proses elemanının mesafesi şu şekilde hesaplanmaktadır.


$$d_i = \|A_i - X\| = \sqrt{\sum_j (A_{ij} - x_j)^2} \quad (4.20)$$

Burada  $A_{ij}$  ve  $x_j$  ağırlık vektörü ve girdi vektörünün  $j$ . değerlerini göstermektedir, girdi vektörü ile referans vektörlerinin hepsinin aralarındaki mesafesi tek tek hesap edildikten sonra hangi proses elemanının referans vektörü girdi vektörüne en yakın ise o yarışmayı kazanmaktadır. Öğrenme sırasında, sadece girdi katmanını bu proses elemanına bağlayan ağırlık değerleri değiştirilir. Diğer ağırlıklar değiştirilmezler. Kazanan proses elemanı için iki durum söz konusudur.


- a) Kazanan proses elemanı doğru sınıfın bir üyesidir. Bu durumda ilgili ağırlıklar girdi vektörüne biraz daha yaklaştırılırlar. Bu, aynı örnek ağa tekrar gösterildiğinde yine aynı proses elemanının kazanması için yapılmaktadır. Bu durumda, ağırlıkların değiştirilmesi şu formüle göre yapılmaktadır.

$$Ay = Ae + \lambda(X - Ae) \quad (4.21)$$

Burada  $X$  öğrenme katsayısıdır. Zaman içersini de sıfır değerini alacak şekilde monoton olarak azaltılır. Bunun nedeni girdi vektörünün referans vektörüne çok yaklaştığında durması ve aksi yönde tekrar uzaklaşmaması içindir. Aksi takdirde ters yönde tekrar uzaklaşma olacaktır. Bu durum Şekil 4.5. ve Şekil 5.6.'da gösterilmiştir.



Şekil 4.5 Girdi vektörüne en yakın ağırlık



Şekil 4.6 Ağırlık vektörünü girdi vektörüne yaklaşması

Şekil 4.5'de görüldüğü gibi, girdi vektörüne en yakın vektör  $A_1$  vektörüdür. Bu vektörün sürekli  $X$  vektörüne yaklaştırılması zaman içinde onu geçerek ters yönde uzaklaşması anlamına gelecektir. 4.6.'da bu durum vurgulanmak istenmektedir. Görüldüğü gibi  $A_1$  vektörü sürekli  $X$  vektörüne yaklaşmaktadır. Belirli bir süre sonra bu iki vektör birbirine çok yakın (bazen üst üste) olmakta ve daha sonra  $A_1$  vektörü tekrar  $X$  vektöründen uzaklaşabilmektedir. O nedenle, girdi ve ağırlık vektörleri

birbirine çok yakın olduğunda ağırlıkların değişmemesi için öğrenme katsayısı sıfır değerine indirilmektedir. Burada tasarımcıların çok dikkatli olması gerekir. Öğrenme katsayısının ne çok erken nede çok geç sıfıra indirgenmemesi lazımdır. Eğitim süreci çok ayrıntılı incelenerek öğrenmenin ne zaman durdurulacağına karar verilmelidir.

- b) Kazanan proses elemanı yanlış sınıftandır. Bu durumda ağırlık vektörü girdi vektöründen uzaklaştırılır. Bir daha aynı örnek geldiğinde aynı proses elemanı kazanmasın diye bu uzaklaştırma yapılır. Şu formül ile ağırlıklar değiştirilir.

$$A_y = A_e - X(X - A_e) \quad (4.22)$$

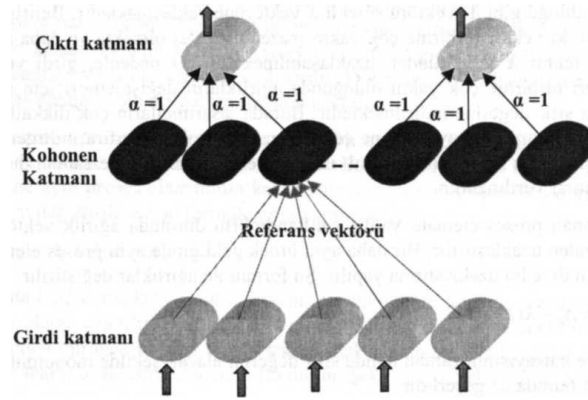
Öğrenme katsayısının zaman içinde sıfır değerini alacak şekilde monotonik olarak azalması burada da geçerlidir.

Şu ana kadar anlatılan algoritma ve tanıtılan model standart LVQ olarak bilinmektedir. Yukarıda anlatılan yöntemin en önemli dezavantajı daha önce belirtildiği gibi öğrenme katsayısının zamanında sıfır değerini almaması durumunda yani fazla eğitim yapılması durumunda ağırlık öğrendiklerini unutması ve doğru ağırlık değerlerinden uzaklaşmasıdır. Ayrıca bazı problemlerde sürekli aynı referans vektörü yarışmayı kazanmaktadır. Bu da, ağırlık esnekliğini ortadan kaldırmaktadır. Diğer bir sorun ise sınıflandırmayı yaparken iki sınıfın tam ortasında veya sınırlara çok yakın bulunan vektörlerin hangi sınıfa gireceklerinin belirlenememesidir. Bu problemleri önlemek için LVQ ağı farklı şekillerde değiştirilmiş ve öğrenme kuralı sürekli geliştirilmiştir. Aşağıda değişik LVQ ağlarına örnekler verilecektir.

#### 4.4.5. LVQ Ağının Eğitilmesi

LVQ ağının eğitilmesinde amaç her iterasyonda girdi vektörüne en yakın referans vektörünü bulmaktır. Referans vektörleri Kohonen katmanındaki proses elemanlarını girdi katmanındaki proses elemanlarına bağlayan ağırlık değerleridir. Şekil 4.7'de Kohonen katmanındaki 3. proses elemanını girdi katmanına bağlayan referans vektörü görülmektedir.

Öğrenme esnasında sadece referans vektörlerinin ağırlık değerleri değiştirilir. Değişimin ne şekilde olacağı yukarıda öğrenme kuralı anlatılırken belirtilmiştir. Şekil 4.7'de aynı zamanda girdi katmanı ile çıktı katmanı arasındaki ağırlıkların ( $\alpha$ ) sabit ve 1 değerine sahip olduklarını da göstermektedir. Bu ağırlıklar eğitim sırasında da değiştirilmezler.




Şekil 4.7 Referans vektörü örneği

Öğrenme sırasında girdi katmanından gösterilen bir örnek sonucu referans vektörlerinin ağırlık değerleri kullanılarak girdi vektörü ile arasındaki mesafeleri hesaplanır. Bu mesafelerden en küçük değeri hangi proses elemanına ait referans vektörü üretiyor ise o proses elemanının çıktısı 1 diğerlerinininki 0 olur. Yani Kohonen katmanındaki her proses elemanın çıktısı Çk ise, Kohonen katmanındaki proses elemanlarının çıktıları bu proses elemanları çıktı katmanına bağlayan ağırlık değerleri ile çarpılarak ağın çıktısı hesaplanır.

Bu Kohonen katmanında yarışmayı kazanan proses elemanına bağlı olan çıktı elemanın değerinin 1, diğerlerinin değerinin 0 olması anlamına gelmektedir. Burada Kohonen katmanındaki proses elemanlarının sadece bir tane çıktı elemanına bağlı olduğu unutulmamalıdır. Şekil 4.8'de bu durum bir örnek ile gösterilmektedir. Örnekte girdi katmanından gelen bilgileri Kohonen katmanındaki 3. proses elemanının kazandığı varsayılmaktadır. Kazanan referans vektörü A3 ile gösterilmektedir. Ağ 5 girdi 6 Kohonen katmanı elemanı ve 2 çıktı elemanından oluşmaktadır. Kohonen katmanındaki 3. eleman çıktı katmanındaki 1. elemana bağlı olduğundan çıktı katmanında 1. eleman 1, diğerleri ise 0 değerini almaktadır. Ağın çıktıları

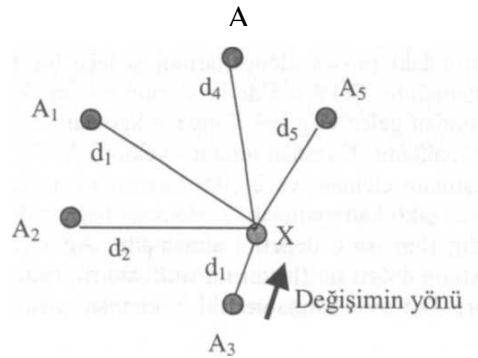


belirlendikten sonra yapılacak iş çıkının doğru sınıflandırılıp sınıflandırılmadığını sorgulamaktır. Bu sorunun cevabına göre Kohonen katmanındaki 3. elemanı girdi katmanına bağlayan ağırlıklar değiştirilir.



Şekil 4.8.LVQ öğrenme prosedürünün geometrik gösterimi

Bulunan sonuç eğer doğru ise o zaman Şekil 4.9'da gösterildiği gibi referans vektörü ( $A_3$ ) ok yönünde girdi vektörüne ( $X$ ) yaklaştırılır. Öğrenme setindeki bütün örnekler doğru sınıflandırılınca kadar bu işlemler tekrarlanır. Hepsi doğru sınıflandırılınca öğrenme gerçekleştirilmiş olur. Bazı durumlarda girdi setinden bir iki (çok az sayıda) adet öğrenilemeyebilir. Bu örneklerin yapısından kaynaklanabilir. Bu durumda da ağ öğrenemedi denilemez. Önemli olan tasarımcının eğitim sonucunda öğrenilen sınıflandırmadan memnun olması ve test seti sınıflandırılmasının kabul edilebilir olmasıdır.



Şekil 4.9.LVQ öğrenmede ağırlıkların değişim yönü

## **BÖLÜM 5. MALZEME VE YÖNTEM**

Bu çalışmada seçilen 3 el hareketi; nesnelerin bilinçli kontrol altında amaca uygun kullanılmasını sağlayan hareketlerden baş parmak fleksiyonu, baş parmak addüksiyonu, parmakların abdüksiyonudur.


### **5.1. EMG Kaydı Yapılan El Hareketleri**

Çalışmamızda seçilen hareketler şunlardır.

Baş parmak fleksiyonu; başparmağın küçük parmağının bitimi hizasında hayat çizgisine dokundurularak konumlandırılması hareketidir. Şekil 5.1.'de baş parmak fleksiyon hareketi gösterilmiştir. Bu harekete katılan kaslar Flexor pollicis brevis ve Flexor pollicis longusdur.



Şekil 5.1. Baş parmak fleksiyon hareketi



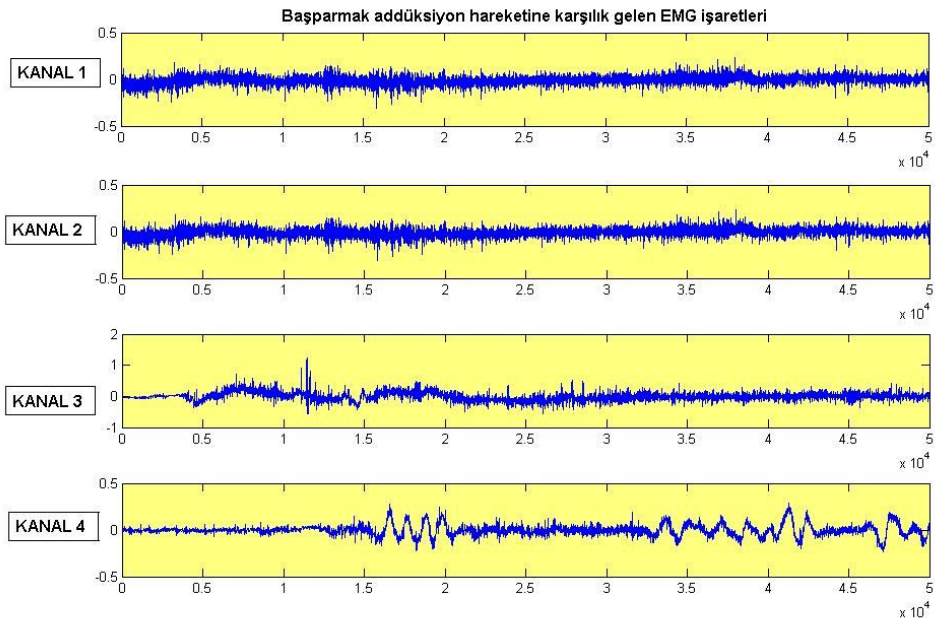
Şekil 5.2. Başparmağın fleksiyon hareketine karşılık gelen EMG işaretleri

Baş parmak addüksiyonu; baş parmağın işaret parmağına bitişik haldeyken diğer dört parmağın ön kol ile açı yapmayacak şekilde bitişik şekilde konumlandırılması

hareketidir. Şekil 5.3’de baş parmak addüksiyonu hareketi gösterilmiştir. Bu harekete katılan kaslar Adductor pollicis ve 1. dorsal interosseousdur.



Şekil 5.3. Baş parmak addüksiyon hareketi




Şekil 5.4. Başparmağın addüksiyon hareketine karşılık gelen EMG işaretleri

Parmakların abdüksiyonu; başparmak hariç diğer dört parmağın yelpaze misali birbirinden ayrılması hareketidir. Şekil 5.5.'de Parmakların abdüksiyonu hareketi gösterilmiştir. Bu harekete katılan kaslar Flexor pollicis brevis ve flexor indicis propriusdur. Bu harekete katılan kaslar Abductor digiti minimi ve 1. dorsal interosseusdur.



Şekil 5.5. Parmakların abdüksiyonu hareketi



Şekil 5.6. Parmakların abdüksiyonu hareketine karşılık gelen EMG işaretleri

## 5.2. Seçilen Kas Grupları

Ölçüm yaptığımız EMG kayıt cihazı 4 kanallı olduğundan eş zamanlı olarak kayıt en fazla 4 farklı kas grubundan alınabildi. Seçmiş olduğumuz 3 el hareketinin oluşumuna farklı ölçeklerde, farklı kombinasyonlarda katılan 4 kas grubu aşağıda belirtilmiştir. Bu kasların seçilmesinin diğer bir nedeni de bu kasların yüzeysel yerleşimli olmalarıdır. Bu sayede yüzeysel elektrotlar kullanılarak biyoelektriksel faaliyetleri kaydedilebilmektedir. Kas gruplarından eş zamanlı olarak yapılan kayıtlamalar, tanımlanan kompleks hareketlere hangi kasın ne derecede ve ne süre ile katıldığı bilgisini de taşımaktadır.

1. Baş parmak kökünde yerleşmiş kaslar (Tenar Kasları)
2. Küçük parmak kökünde yerleşmiş kaslar (Hipotenar Kasları)
3. İşaret parmağı kökünde yerleşmiş kas (1. Dorsal İnterosseus Kası)
4. Ön kolda yerleşmiş, parmakları büken kaslar (Yüzeysel Fleksor Kasları)

Kayıtlama için seçilen kaslar, füziform (mekik şeklinde), çizgili iskelet kaslarıdır. Bu kaslar; biyoelektriksel faaliyet ile tetiklenip kasılma işlevini gerçekleştirmektedirler.

İstemli kası sırasında; hareket nöronları hareket emrini hedef kaslara ulaştırır, sinir – kas arasındaki kavşağı geçen hareket emri kas lifleri üzerinde biyoelektriksel faaliyet yaratır. Bu biyoelektriksel faaliyet, hücre dışı yakın alan kayıtlamalarında, tek bir kas lifi için trifazik konfigürasyonda kaydedilen “aksiyon potansiyeli” dir. Bu aksiyon potansiyeli kas lifi üzerinde tendonlara doğru yayılırken, kas lifi içerisine kalsiyum iyonu girişini tetikler. İçeri giren kalsiyum iyonu da kasılmayı sağlayacak elemanter birim olan sarkomer’leri uyatarak; kasın boyunu kısaltan, böylelikle kasın kat ettiği eklem üzerinden bu eklemi oluşturan iki kemiği birbirine yaklaştırarak hedeflenen hareketi sağlayan bir dizi olaylar zincirini başlatır. Anlaşıldığı gibi, istemli kası sırasında izlenen hareketin iki fizyolojik boyutu vardır. Bunlardan birincisi biyoelektriksel boyut, diğeri de kas kasılması ve 3 boyutlu uzayda uzvun yer değiştirmesidir. Sağlıklı, amaca uygun istemli hareket için bu iki boyutun eş güdüm içerisinde işlev görmesi gerekir. Başka bir deyişle, kasa hareket emri getiren sinir hücreleri sağlıklı olmalı, kas lifine bu hareket emri sağlıklı kavşaklardan geçip kas lifi üzerinde aksiyon potansiyeli tetikleyebilmeli, kas lifinin kasılmayı sağlayan kontraktıl birimleri yani sarkomerler sağlıklı olmalı, kas liflerinin kemiğe tutunduğu tendonlar ve en nihayetinde kemik ve eklem sağlıklı olmalıdır ki; istemli hareket amaca uygun gerçekleştirilebilsin.


### **5.3. EMG kayıt alma metodu**

Bu çalışma da kullanılan EMG işaretleri, İstanbul Üniversitesi İstanbul Tıp Fakültesi Nöroloji anabilim dalına ait EMG laboratuvarında kullanılan Medtronic marka 4 kanallı EMG cihazı ile kayıtlanmıştır. Cihazın yazılımı Key point version 5.09’dur. Seçilen 3 hareketin her birinde 4 farklı kas grubundan eş zamanlı olarak istemli hareket sırasında biyoelektriksel faaliyet kaydedilmiştir. Kayıtlama için yüzeysel Ag – AgCl “cup” elektrotlar kullanılmıştır. Örneklem hızı 5 khz’dır. Yüzeysel elektrotlar, kasın göbeğine aktif elektrot (biyoelektriksel faaliyetin kas lifleri üzerinde ilk olduğu yer, sinir – kas kavşaklarının dizildiği zon = motor son plak zonu), kasın tendonuna (elektriksel olarak görece sessiz) da referens elektrot gelecek şekilde yerleştirilmiştir Yüzeysel elektrotların kayıt için seçilmesinin sebebi, daha geniş bir görüş alanına sahip olmaları ve kasılma – kayıtlama sırasında kasın içerisine yerleştirilecek iğne elektrotlara göre ağrıya sebep olmamalarıdır.

Kayıt pozisyonunda, vücut dik oturur bir vaziyette iken sağ kol yere paralel ve omuz hizasında tutulmuş dirsek tam açık vaziyette tutulmuştur. Hareketler esnasında el bilekten bükülmemiştir. Deney pozisyonuna tüm gönüllülerin riayet etmesi sağlanmış olup tüm ölçümlerde el dışında konum değişikliğine müsaade edilmeyerek örnek uzayında bir standart yakalanmaya çalışılmıştır.

Tüm gönüllüler için kayıt düzeneği aynı olup aynı yere oturup, aynı materyalleri kullanmışlardır. Parmakların abduksiyonu hareketinde yelpaze gibi açılan dört parmağın bir lastik ile gerginliği sabitlenmeye çalışılmıştır.

Kayıt alınan gönüllüler sağ elini kullanan, daha önce sinir-kas zedelenmesi geçirmemiş kişilerden seçildi. Gönüllüler, yaşları 18 ile 37 arasında değişen 2'si bayan toplam 8 kişiden oluşturuldu. Her bir gönüllüden her bir harekete karşılık 20 kayıt alınmıştır. Her kayıt 15 saniye boyunca alınmış olup her kayıt arasında gönüllülerin 15 saniye dinlenmeleri sağlanmıştır. Her gönüllü için her bir kasın istirahat halinde de kaydı alınmıştır. 8 gönüllüden 3 harekete karşılık toplam 488 kayıt alınmıştır.



Şekil 5.7. Medtronic marka EMG kayıt cihazı

Ön kolda yerleşmiş yüzeysel flexorler kaslarına yüzey elektrotlarının bağlantısı Şekil 5.8.'de görülmektedir. Burada sarı kabloya bağlı yüzey elektrotu kasın göbeğine,



kırmızı kabloya baęlı referans elektrot ise dirsek altında sessiz bir yere tendona sıkıca baęlanmıřtır.



Şekil 5.8. Ön kolda yerleşmiş yüzeyel flexorler kaslarına elektrotların baęlanması


Küçük parmak köküne yerleşmiş hipotenar kaslarına yüzey elektrotlarının baęlanması Şekil 5.9.'da görülmektedir. Burada mavi kabloya baęlı yüzey elektrotu kasın göbeęine, kırmızı kabloya baęlı referans elektrot ise küçük parmak kökünde sessiz bir yere tendona sıkıca baęlanmıřtır.



Şekil 5.9. Hipotenar kaslarına elektrotların baęlanması



İşaret parmak köküne yerleşmiş 1. Dorsal İnterosseus kasına yüzey elektrotlarının bağlantısı Şekil 5.10.'de görülmektedir. Burada siyah kabloya bağlı yüzey elektrotu kasın göbeğine, kırmızı kabloya bağlı referans elektrot ise işaret parmağının kökünde sessiz bir yere tendona sıkıca bağlanmıştır.



Şekil 5.10 1. Dorsal İnterosseus kasına elektrotların bağlantısı

Başparmak köküne yerleşmiş tenar kaslarına yüzey elektrotlarının bağlantısı Şekil 5.11.'de görülmektedir. Burada siyah kabloya bağlı yüzey elektrotu kasın göbeğine, kırmızı kabloya bağlı referans elektrot ise işaret parmağının kökünde sessiz bir yere tendona sıkıca bağlanmıştır.



Şekil 5.11. Tenar kaslarına elektrotların bağlantısı

## **BÖLÜM 6. SONUÇLAR VE ÖNERİLER**

### **6.1. Sonuçlar**

Bu çalışmada kayıtlanan EMG işaretlerinin analizi ve sınıflandırılması Matlab programında yapılmıştır. Sınıflandırma da 3 hareket karşılık gelen EMG işaretlerinin 5., 10. ve 20. dereceden öz bağımlı katsayılar ve dalgacık tabanlı öz bağımlı modeller ağ girişleri için öznelik vektörleri olarak kullanılmıştır. Dalgacık tabanlı öz bağımlı modellerde bior1.5, coif3, db1, db3, sym2 ana dalgacıkları 4, 5, 6, ve 7. seviyeye ayrıştırılmış işaretlerin 5., 10. ve 20. dereceden öz bağımlı katsayıları öznelik vektörleri olarak kullanılmıştır.

Sınıflandırma için ileri beslemeli geri yayımlı çok katmanlı ağlar, radyal temelli ağlar ve LVQ ağları kullanılmıştır. Eğitim ve test kümesi olarak her harekete karşılık alınan 160 örnekten 120'si eğitim için 40'ı test için kullanılmıştır. Toplamda 360 örnek eğitim için 120 örnek test kümesi için kullanılmıştır. Her hareket için elde edilen toplam doğru sayısı test için kullanılan toplam veri sayısına bölünerek her hareketin ortalama doğruluğu bulunmuştur. Tüm hareketler için toplam doğru sayısı test için kullanılan toplam veri sayısına bölünerek her biri ağın doğruluk oranı bulunmuştur.

İleri beslemeli geri yayımlı ağlar 2 katmandan oluşturulmuştur. Öznelik vektörlerinin boyutlarına göre giriş katmanı 5, 10 ve 20 elemandan ve çıkış katmanı ise 2 elemandan oluşturulmuştur. Transfer fonksiyonu ve geri yayılım transfer fonksiyonu olarak “tansig” ve “logsig” fonksiyonları ile testler gerçekleştirilmiştir. Eğitim algoritması olarak Levenberg-Marquardt eğitim algoritması kullanılmış olup 0.7, 0.8 ve 0.9 öğrenme oranları(lr) ile ağlar test edilmiştir. İleri beslemeli ağların ilk koşullara bağlılığından dolayı oluşturulan her ağ arka arkaya beş kere çalıştırılarak ortalamaları alınmış ve doğruluk oranları elde edilmiştir.

Her denemede her hareket için en yüksek doğruluk oranları, her hareket için doğruluk oranları ve tüm hareketlerin ortalama doğruluk oranları tespit edilmiş olup aşağıda yer alan tablolardaki sonuçlar elde edilmiştir.

Buna göre ileri beslemeli geri yayımlı ağlar için en yüksek doğruluk oranı, bir1.5 ana dalgacığı ile 5. seviyeye kadar ayrıştırılmış işaretin 20. dereceden öz bağımlı katsayılarının öznitelik vektörü olarak kullanıldığı ağda % 90 oranında gerçekleşmiştir. Bu ağın giriş katmanı 20 giriş elemanından, çıkış katmanı ise 2 çıkış elemanından oluşmakta olup parametreleri epoch=2000, lr=0.8, tf=tansig, btf=trainlm.'dir.

Tablo 6.1. 5,10 ve 20. dereceden öz bağımlı model katsayıların öznitelik vektörü olarak kullanıldığı 5,10 ve 20 giriş elemanı 2 çıkış elemanına sahip ileri beslemeli geri yayımlı yapay sinir ağı test sonuçları. Parametreler epoch=2000, lr=0.9, tf=logsig, btf=trainlm.

Hareket/ Katsayı	BPA		PA		BPF		ORTALAMA	
	Ort.(%)	Maks.(%)	Ort.(%)	Maks.(%)	Ort.(%)	Maks.(%)	Ort.(%)	Maks.(%)
AR5	50,5	87,5	58	100	64,5	100	57,6	83,3
AR10	83	90	95,5	97,5	71	82,5	83	86,6
AR20	70,5	85	74,5	82,5	71,5	80	72,16	80,8

Tablo 6.2. 5,10 ve 20. dereceden öz bağımlı model katsayıların öznitelik vektörü olarak kullanıldığı 5,10 ve 20 giriş elemanı 2 çıkış elemanına sahip ileri beslemeli geri yayımlı yapay sinir ağı test sonuçları. Parametreler epoch=2000, lr=0.7, tf=logsig, btf=trainlm.

Hareket/ Katsayı	BPA		PA		BPF		ORTALAMA	
	Ort.(%)	Maks.(%)	Ort.(%)	Maks.(%)	Ort.(%)	Maks.(%)	Ort.(%)	Maks.(%)
AR5	64	85	73,5	97,5	79	90	72,16	88,3
AR10	79	92,5	93	97,5	68	70	80	84,1
AR20	74,5	82,5	59,5	77,5	70,5	77,5	68,16	76,6

Tablo 6.3. 5,10 ve 20. dereceden öz bağımlı model katsayıların öznitelik vektörü olarak kullanıldığı 5,10 ve 20 giriş elemanı 2 çıkış elemanına sahip ileri beslemeli geri yayımlı yapay sinir ağı test sonuçları. Parametreler epoch=2000, lr=0.8, tf=tansig, btf=trainlm.

Hareket/ Katsayı	BPA		PA		BPF		ORTALAMA	
	Ort.(%)	Maks.(%)	Ort.(%)	Maks.(%)	Ort.(%)	Maks.(%)	Ort.(%)	Maks.(%)
AR5	73	82,5	73,5	95	63,5	70	70	75
AR10	47,5	82,5	49,5	92,5	86	100	61	80,8
AR20	57	72,5	63,5	85	75,5	100	65,33	75,8

Tablo 6.4 Dalgacık tabanlı 5. dereceden öz bağımlı model katsayıların öznelik vektörü olarak kullanıldığı 5 giriş elemanı 2 çıkış elemanına sahip ileri beslemeli geri yayımlı yapay sinir ağı test sonuçları. Parametreler epoch=2000, lr=0.9, tf=logsig, btf=trainlm.

Hareket/ Katsayı	BPA		PA		BPF		ORTALAMA	
	Ort.(%)	Maks.(%)	Ort.(%)	Maks.(%)	Ort.(%)	Maks.(%)	Ort.(%)	Maks.(%)
bior1.5-5	75,8	77,5	80,8	90	51,6	60	69,4	71,6
coif3-4	82,5	82,5	86,6	90	52,5	55	73,8	74,1
db1-4	81,6	90	85,8	92,5	65,8	70	77,7	78,3
db3-6	88,3	100	60	92,5	33,3	55	60,5	75,8
db3-7	64,5	82,5	70,5	90	60,5	72,5	65,1	76,6
sym2-7	81	90	90,5	95	68	77,5	79,8	86,6

Tablo 6.5 Dalgacık tabanlı 5. dereceden öz bağımlı model katsayıların öznelik vektörü olarak kullanıldığı 5 giriş elemanı 2 çıkış elemanına sahip ileri beslemeli geri yayımlı yapay sinir ağı test sonuçları. Parametreler epoch=2000, lr=0.7, tf=logsig, btf=trainlm.

Hareket/ Katsayı	BPA		PA		BPF		ORTALAMA	
	Ort.(%)	Maks.(%)	Ort.(%)	Maks.(%)	Ort.(%)	Maks.(%)	Ort.(%)	Maks.(%)
bior1.5-5	75,5	82,5	36	95	72	90	61,6	80
coif3-4	79	85	70,5	92,5	54,5	77,5	68	75
db1_4	77,5	85	70	92,5	61	82,5	69,5	76,6
db3_6	82,5	100	71	95	45	60	66,15	76,6
db3_7	62,5	85	89,5	92,5	65	87,5	72,3	80,3
sym2_7	90,5	95	90	92,5	70	75	83,5	87,5

Tablo 6.6 Dalgacık tabanlı 5. dereceden öz bağımlı model katsayıların öznelik vektörü olarak kullanıldığı 5 giriş elemanı 2 çıkış elemanına sahip ileri beslemeli geri yayımlı yapay sinir ağı test sonuçları. Parametreler epoch=2000, lr=0.8, tf=tansig, btf=trainlm.

Hareket/ Katsayı	BPA		PA		BPF		ORTALAMA	
	Ort.(%)	Maks.(%)	Ort.(%)	Maks.(%)	Ort.(%)	Maks.(%)	Ort.(%)	Maks.(%)
bior1.5-5	47,5	80	55,5	95	65,5	100	56,15	73,3
coif3-4	62,5	85	64	82,5	64,5	100	63,2	74,2
db1-4	32,5	82,5	50,5	90	76	100	56	75
db3-6	60,5	85	71,5	95	58	100	63,4	75
db3-7	62,5	100	51,5	90	49	100	54,3	71,7
sym2-7	62,5	87,5	68	87,5	65	100	65,2	75,8

Tablo 6.7 Dalgacık tabanlı 10. dereceden öz bağımlı model katsayıların öznelik vektörü olarak kullanıldığı 10 giriş elemanı 2 çıkış elemanına sahip ileri beslemeli geri yayımlı yapay sinir ağı test sonuçları. Parametreler epoch=2000, lr=0.9, tf=logsig, btf=trainlm.

Hareket/ Katsayı	BPA		PA		BPF		ORTALAMA	
	Ort.(%)	Maks.(%)	Ort.(%)	Maks.(%)	Ort.(%)	Maks.(%)	Ort.(%)	Maks.(%)
bior1.5-5	55,8	85	56,6	92,5	82,5	100	65	85,8
coif3-4	79,1	85	82,5	87,5	63,3	65	75	76,6
db1-4	92,5	95	85,8	87,5	70	75	82,7	84,1
db3-6	52,5	97,5	61,6	92,5	45,5	80	75	87,5
db3-7	67	90	69	92,5	70	100	68,6	78
sym2-7	82,5	87,5	62	95	75,5	82,5	73	84,1

Tablo 6.8 Dalgacık tabanlı 10. dereceden öz bağımlı model katsayıların öznelik vektörü olarak kullanıldığı 10 giriş elemanı 2 çıkış elemanına sahip ileri beslemeli geri yayımlı yapay sinir ağı test sonuçları. Parametreler epoch=2000, lr=0.7, tf=logsig, btf=trainlm.

Hareket/ Katsayı	BPA		PA		BPF		ORTALAMA	
	Ort.(%)	Maks.(%)	Ort.(%)	Maks.(%)	Ort.(%)	Maks.(%)	Ort.(%)	Maks.(%)
bior1.5-5	70,5	97,5	53	95	77	100	66,8	87,5
coif3-4	66,5	87,5	77,5	82,5	68,5	82,5	70,8	79,1
db1-4	87	95	83	92,5	66	75	78,6	86,6
db3-6	73	95	68	92,5	74,5	100	71,8	83,2
db3-7	86	92,5	90	92,5	71	77,5	82,4	75
sym2-7	90	92,5	84	90	74	82,5	82,6	86,7

Tablo 6.9 Dalgacık tabanlı 10. dereceden öz bağımlı model katsayıların öznelik vektörü olarak kullanıldığı 10 giriş elemanı 2 çıkış elemanına sahip ileri beslemeli geri yayımlı yapay sinir ağı test sonuçları. Parametreler epoch=2000, lr=0.8, tf=tansig, btf=trainlm.

Hareket/ Katsayı	BPA		PA		BPF		ORTALAMA	
	Ort.(%)	Maks.(%)	Ort.(%)	Maks.(%)	Ort.(%)	Maks.(%)	Ort.(%)	Maks.(%)
bior1.5-5	80,5	87,5	79	92,5	64	70	74,5	78,3
coif3-4	65	82,5	60,5	85	65,5	90	64,8	77,5
db1-4	64,5	90	61,5	80	76	100	67,3	78,3
db3-6	34	85	77	100	64	87,5	58,3	80,8
db3-7	79,5	90	81,5	92,5	66	77,5	75,6	79,1
sym2-7	66	92,5	44	82,5	81	100	63,6	82,5

Tablo 6.10 Dalgacık tabanlı 20. dereceden öz bağlantımlı model katsayıların öznelilik vektörü olarak kullanıldığı 20 giriş elemanı 2 çıkış elemanına sahip ileri beslemeli geri yayımlı yapay sinir ağı test sonuçları. Parametreler epoch=2000, lr=0.9, tf=logsig, btf=trainlm.

Hareket/ Katsayı	BPA		PA		BPF		ORTALAMA	
	Ort.(%)	Maks.(%)	Ort.(%)	Maks.(%)	Ort.(%)	Maks.(%)	Ort.(%)	Maks.(%)
bior1.5-5	89,5	90,5	93	93	80	82	87,5	89,5
coif3-4	47,5	82,5	51	87,5	82,5	100	60,33	80,83
db1-4	55,5	95	74,5	95	86,5	100	72,16	90
db3-6	87	90	93	95	83,5	87,5	87,83	90
db3-7	88,5	95	95	97,5	85,5	90	89,66	93,33
sym2-7	90	95	91	95	80,5	82,5	87,16	89,16

Tablo 6.11 Dalgacık tabanlı 20. dereceden öz bağlantımlı model katsayıların öznelilik vektörü olarak kullanıldığı 20 giriş elemanı 2 çıkış elemanına sahip ileri beslemeli geri yayımlı yapay sinir ağı test sonuçları. Parametreler epoch=2000, lr=0.7, tf=logsig, btf=trainlm.

Hareket/ Katsayı	BPA		PA		BPF		ORTALAMA	
	Ort.(%)	Maks.(%)	Ort.(%)	Maks.(%)	Ort.(%)	Maks.(%)	Ort.(%)	Maks.(%)
bior1.5-5	90,5	95	93,5	97,5	83,5	87,5	89,1	93,3
coif3-4	63	90	83	87,5	71	90	72,3	80
db1-4	74	97,5	96	97,5	81,5	85	83,3	91,6
db3-6	73	95	87,5	92,5	86	95	82,1	90
db3-7	68,5	95	93	95	81,5	95	81	89,1
sym2-7	89,5	95	93,5	97	83,5	85	88,8	91,6

Tablo 6.12 Dalgacık tabanlı 20. dereceden öz bağlantımlı model katsayıların öznelilik vektörü olarak kullanıldığı 20 giriş elemanı 2 çıkış elemanına sahip ileri beslemeli geri yayımlı yapay sinir ağı test sonuçları. Parametreler epoch=2000, lr=0.8, tf=tansig, btf=trainlm.

	BPA		PA		BPF		ORTALAMA	
	Ort.(%)	Maks.(%)	Ort.(%)	Maks.(%)	Ort.(%)	Maks.(%)	Ort.(%)	Maks.(%)
bior1.5-5	91,5	95	94	97,5	84,5	87,5	90	92,5
coif3-4	62,5	85	67	90	69	97,5	66,1	79,1
db1-4	75	97,5	73,5	95	79	100	75,8	87,5
db3-6	84	92,5	90,5	95	83,5	90	86	90,8
db3-7	85,5	90	90,5	100	77,5	80	84,5	89,1
sym2-7	92	97,5	92	97,5	80	85	88	90

Sınıflama için kullanılan bir başka ağ olan radyal temelli ağlar 70, 80, 90, 112 ve 120 yayılım değerleri için test edilmiştir. Her hareket için doğruluk oranları ve tüm hareketlerin ortalama doğruluk oranları tespit edilmiş olup aşağıda yer alan

tablolardaki sonuçlar elde edilmiştir. Buna göre radyal temelli ağların testinde yayılım değeri 112 için en yüksek ve kabul edilebilir doğruluk oranına ulaşılmıştır. db3 ana dalgacığı ile 7. seviyeye kadar ayrıştırılmış işaretin 20. dereceden öz bağımlı katsayılarının öznitelik vektörü olarak kullanıldığı bu ağda doğruluk % 92,3 oranında gerçekleşmiştir.

Tablo 6.13. 5,10 ve 20. dereceden öz bağımlı model katsayıların öznitelik vektörü olarak kullanıldığı  $sp=70$  için radyal temelli yapay sinir ağı test sonuçları.

	BPA(%)	PA(%)	BPF(%)	ORTALAMA.(%)
AR5	77,5	90	77,5	81,6
AR10	80	90	72,5	80,8
AR20	77,5	95	77,5	83,3

Tablo 6.14. 5,10 ve 20. dereceden öz bağımlı model katsayıların öznitelik vektörü olarak kullanıldığı  $sp=80$  için radyal temelli yapay sinir ağı test sonuçları.

	BPA(%)	PA(%)	BPF(%)	ORTALAMA.(%)
AR5	72,5	87,5	90	81,6
AR10	80	92,5	80	84,1
AR20	80	92,5	80	84,1

Tablo 6.15. 5,10 ve 20. dereceden öz bağımlı model katsayıların öznitelik vektörü olarak kullanıldığı  $sp=90$  için radyal temelli yapay sinir ağı test sonuçları.

	BPA(%)	PA(%)	BPF(%)	ORTALAMA.(%)
AR5	75	77,5	80	77,5
AR10	75	92,5	75	80,8
AR20	80	92,5	72,5	81,6

Tablo 6.16. Dalgacık tabanlı 5. dereceden öz bağımlı model katsayıların öznitelik vektörü olarak kullanıldığı  $sp=70$  için radyal temelli yapay sinir ağı test sonuçları.

	BPA(%)	PA(%)	BPF(%)	ORTALAMA.(%)
bior1.5-5	80	77,5	50	65,8
coif3-4	80	77,5	60	72,5
db1-4	80	80	47,5	69,1
db3-6	65	82,5	47,5	65
db3-7	66	80,5	48,5	65
sym2-7	80	80	55	71,6

Tablo 6.17. Dalgacık tabanlı 5. dereceden öz bağlantımlı model katsayıların öz nitelik vektörü olarak kullanıldığı  $sp=80$  için radyal temelli yapay sinir ağı test sonuçları.

	BPA(%)	PA(%)	BPF(%)	ORTALAMA.(%)
bior1.5-5	70	77,5	52,5	66,6
coif3-4	82,5	75	62,5	73,3
db1-4	77,5	80	50	69,17
db3-6	65	82,5	47,5	65
db3-7	65	82,5	47,5	65
sym2-7	80	82,5	52,5	71,6

Tablo 6.18. Dalgacık tabanlı 5. dereceden öz bağlantımlı model katsayıların öz nitelik vektörü olarak kullanıldığı  $sp=90$  için radyal temelli yapay sinir ağı test sonuçları.

	BPA(%)	PA(%)	BPF(%)	ORTALAMA.(%)
bior1.5-5	70	77,5	52,5	66,6
coif3-4	82,5	77,5	60	73,3
db1-4	80	82,5	50	70,8
db3-6	67,5	80	47,5	65
db3-7	67,5	80	45	64,16
sym2-7	80	82,5	52,5	71,6

Tablo 6.19. Dalgacık tabanlı 10. dereceden öz bağlantımlı model katsayıların öz nitelik vektörü olarak kullanıldığı  $sp=70$  için radyal temelli yapay sinir ağı test sonuçları.

	BPA(%)	PA(%)	BPF(%)	ORTALAMA.(%)
bior1.5-5	82,5	82,5	60	75
coif3-4	75	87,5	62,5	75
db1-4	82,5	80	67,5	76,6
db3-6	77,5	82,5	67,5	75,8
db3-7	85	90	65	80
sym2-7	82,5	82,5	62,5	75,8

Tablo 6.20. Dalgacık tabanlı 10. dereceden öz bağlantımlı model katsayıların öz nitelik vektörü olarak kullanıldığı  $sp=80$  için radyal temelli yapay sinir ağı test sonuçları.

	BPA(%)	PA(%)	BPF(%)	ORTALAMA.(%)
bior1.5-5	82,5	85	60	75,8
coif3-4	77,5	82,5	62,5	74,1
db1-4	72,5	80	60	70,8
db3-6	77,5	77,5	67,5	74,1
db3-7	82,5	87,5	65	78,3
sym2-7	87,5	80	62,5	76,6



Tablo 6.21. Dalgacık tabanlı 10. dereceden öz bağımlı model katsayıların öz nitelik vektörü olarak kullanıldığı  $sp=90$  için radyal temelli yapay sinir ağı test sonuçları.

	BPA(%)	PA(%)	BPF(%)	ORTALAMA.(%)
bior1.5-5	75	80	67,5	74,1
coif3-4	75	85	65	75
db1-4	77,5	85	57,5	73,3
db3-6	80	85	70	78,3
db3-7	82,5	87,5	67,5	79,1
sym2-7	77,5	77,5	65	73,3

Tablo 6.22. Dalgacık tabanlı 20. dereceden öz bağımlı model katsayıların öz nitelik vektörü olarak kullanıldığı  $sp=70$  için radyal temelli yapay sinir ağı test sonuçları.

	BPA(%)	PA(%)	BPF(%)	ORTALAMA.(%)
bior1.5-5	90	87,5	60	79,1
coif3-4	75	80	65	73,3
db1-4	90	90	62,5	80,8
db3-6	87,5	92,5	85	88,3
db3-7	85	97,5	77,5	86,6
sym2-7	90	90	70	83,3

Tablo 6.23. Dalgacık tabanlı 20. dereceden öz bağımlı model katsayıların öz nitelik vektörü olarak kullanıldığı  $sp=80$  için radyal temelli yapay sinir ağı test sonuçları.

	BPA(%)	PA(%)	BPF(%)	ORTALAMA.(%)
bior1.5-5	90	90	65	81,6
coif3-4	75	82,5	67,5	75
db1-4	92,5	87,5	65	81,6
db3-6	82,5	95	80	85,3
db3-7	85	97,5	80	87,5
sym2-7	85	72,5	87,5	81,6

Tablo 6.24. Dalgacık tabanlı 20. dereceden öz bağımlı model katsayıların öz nitelik vektörü olarak kullanıldığı  $sp=90$  için radyal temelli yapay sinir ağı test sonuçları.

	BPA(%)	PA(%)	BPF(%)	ORTALAMA.(%)
bior1.5-5	87,5	87,5	65	80
coif3-4	77,5	75	72,5	75
db1-4	87,5	90	60	79,1
db3-6	85	95	82,5	87,5
db3-7	92,5	97,5	80	90
sym2-7	90	85	75	83,3

Tablo 6.25. db3-7 tabanlı 20. dereceden öz bağımlı model katsayıların öznitelik vektörü olarak kullanıldığı sp= 112 ve sp=120 için radyal temelli yapay sinir ağı test sonuçları.

	BPA(%)	PA(%)	BPF(%)	ORTALAMA.(%)
sp=112	92,5	99	85	92,16
sp=120	92,5	100	80	90,8

Sınıflama için kullanılan bir diğer ağ LVQ ağı olup bu ağ 9 gizli elemandan oluşmaktadır. Her denemede her hareket için en yüksek doğruluk oranları, her hareket için doğruluk oranları ve tüm hareketlerin ortalama doğruluk oranları tespit edilmiş olup aşağıda yer alan tablolardaki sonuçlar elde edilmiştir. Buna göre LVQ ağında en yüksek doğruluk oranı, sym2 ana dalgacığı ile 7. seviyeye kadar ayrıştırılmış işaretin 20. dereceden öz bağımlı katsayılarının öznitelik vektörü olarak kullanıldığı ağda % 75,5 oranında gerçekleşmiştir.

Tablo 6.26. 5,10 ve 20. dereceden öz bağımlı model katsayıların öznitelik vektörü olarak kullanıldığı 9 gizli düğüme sahip LVQ yapay sinir ağının test sonuçları. Parametreler lr=0,01, lf=leranlv2

Hareket/ Katsayı	BPA		PA		BPF		ORTALAMA.(%)	
	Ort.(%)	Maks.(%)	Ort.(%)	Maks.(%)	Ort.(%)	Maks.(%)	Ort.(%)	Maks.(%)
AR5	51,6	52,5	50,8	52,5	87,5	90	63,3	65
AR10	25,8	50	60,8	87,5	81,6	92,5	56,1	60,8
AR20	60	60	47,5	47,5	71,25	72,5	59,5	60

Tablo 6.27. Dalgacık tabanlı 5. dereceden öz bağımlı model katsayıların öznitelik vektörü olarak kullanıldığı 9 gizli düğüme sahip LVQ yapay sinir ağının test sonuçları. Parametreler lr=0,01, lf=leranlv2

Hareket/ Katsayı	BPA		PA		BPF		ORTALAMA.(%)	
	Ort.(%)	Maks.(%)	Ort.(%)	Maks.(%)	Ort.(%)	Maks.(%)	Ort.(%)	Maks.(%)
bior1.5-5	73,3	77,5	8,3	25	85,8	90	55,8	55,8
coif3-4	82,5	90	4,1	12,5	82,5	97,5	56,3	58,3
db1-4	65	67,5	45	45	86,6	87,5	65,5	65,8
db3-6	73,3	75	28,3	30	82,5	82,5	61,3	61,6
db3-7	72,5	72,5	20,8	22,5	92,5	93	61,9	62,5
sym2-7	65,8	67,5	41,6	42,5	94,16	95	67,2	67,5

Tablo 6.28. Dalgacık tabanlı 10. dereceden öz bağlantımlı model katsayılarının öznitelik vektörü olarak kullanıldığı 9 gizli düğüme sahip LVQ yapay sinir ağının test sonuçları. Parametreler  $l_r=0,01$ ,  $l_f=leranlv2$

Hareket/ Katsayı	BPA		PA		BPF		ORTALAMA.(%)	
	Ort.(%)	Maks.(%)	Ort.(%)	Maks.(%)	Ort.(%)	Maks.(%)	Ort.(%)	Maks.(%)
bior1.5-5	33,3	100	0	0	66,6	100	33,3	33,3
coif3-4	50	100	0	0	50	100	33,3	33,3
db1-4	85	85	52,5	52,5	88,3	90	75,2	75,8
db3-6	86,2	87,5	2,5	2,5	82,5	82,5	57	57,5
db3-7	80	80	8,7	12,5	96,2	97,5	61,6	62,5
sym2-7	77,5	80	53,7	55	82,5	82,5	71,2	72,5

Tablo 6.29. Dalgacık tabanlı 20. dereceden öz bağlantımlı model katsayılarının öznitelik vektörü olarak kullanıldığı 9 gizli düğüme sahip LVQ yapay sinir ağının test sonuçları. Parametreler  $l_r=0,01$ ,  $l_f=leranlv2$

Hareket/ Katsayı	BPA		PA		BPF		ORTALAMA.(%)	
	Ort.(%)	Maks.(%)	Ort.(%)	Maks.(%)	Ort.(%)	Maks.(%)	Ort.(%)	Maks.(%)
bior1.5-5	77,5	80	57,5	60	90	90	75	75
coif3-4	0	0	50	100	50	100	33,3	33,3
db1-4	85	85	52,5	52,5	87,5	90	75	75
db3-6	75,8	82,5	22,5	22,5	86,6	90	61,6	64
db3-7	80	83	30	30	92,5	94	67,5	67,5
sym2-7	82,5	82,5	52	52	91,6	82,5	75,5	75,8

## 5.2. Öneriler

Bu tez çalışmasında protez-biyonik el çalışmalarında önem arz eden nesnelere bilinçli kontrol altında amaca uygun kullanılmasını sağlayan hareketlerden başparmak addüksiyonu, başparmak fleksiyonu ve parmakların abdüksiyonu hareketlerinin konumlarına karşılık gelen elektromiyogram işaretleri kayıtlanmıştır. Daha sonra kayıtlanan bu ham elektromiyogram işaretlerin dalgacık tabanlı öz bağlantımlı modelleri yapay sinir ağlarında öznitelik vektörü olarak kullanılarak sınıflandırma yapılmıştır.

Sınıflandırmanın başarısını artırabilmek için gönüllülerin yaş grubu, vücut kitle indeksi – cinsiyet dağılımı – hobi ve hünere farkları daha geniş bir aralıkta homojenize edilip sayıları artırılabilir. Çalışmada baskın el kayıtlamaları yapılmış olup baskın olmayan elden de işaretler alınabilir, ayrıca önem arz eden başka hareketler kullanılarak sınıflandırma problemi genişletilebilir.

Kayıtların gönüllülere rahatsızlık vermeyen can yakmayan yüzeysel elektrotlarla alınması çalışmanın faydalarındandır.

Bu çalışma ayrıca eli beceriksiz bırakan hastalıklardan, serebellar sendromlar, bazal gangliyon hastalıkları) tanısı, takibi için önem arz etmektedir. Çalışmanın ileriki safhalarında fizik tedavi alanında, biyoelektrik – işlevsellik bağıntısını yakalayan yeni bir geri bildirim algoritması türetilir.

## KAYNAKLAR

- [1] PUDULSKI; The Boston Arm. Forum, IEEE Spectrum 6, 1969.
- [2] REITER, R.; Eine neue Elektrokuntshand, Grenzgeb Med., 4:133-135, 1948.
- [3] DORCAS, D.S.; A three-state myoelectric control, Med Biol. Eng., 4:367-370, 1966.
- [3] TRAVIS, R.C.; Prediction and automatic control of alertness 3-calibration of alertness indicator and further results. A three-state myoelectric control, J Comp Physio Pscyhiatry, 42:45-57, 1949.
- [4] BERGER, N.; The electrical and mechanical muscle forces for the control of and electrical prosthesis, Am J Occup Ther., 1:110-114.
- [5] MUZUMDAR, A.; Powered Upper Limb Prostheses: Control, Implementation and Clinical, Springer, 2004.
- [6] DU, Y.C., HU, W.C., SHYU, L.Y.; The effect of data reduction by independent component analysis and principal component analysis in hand motion identification, Engineering in Medicine and Biology Society, 26th Annual International Conference of the IEEE, 2004.
- [7] MAHDI, K., MEHRAN, J.; A Novel Approach to Recognize Hand Movements Via sEMG Patterns, Engineering in Medicine and Biology Society, 29th Annual International Conference of the IEEE, 2007.
- [9] ZHIZENG, L., XIAOLIANG, R., YUTAO Z.; Multi-pattern recognition of the forearm movement based on SEMG, IEEE, 2004.
- [10] WANG, F., WANG, R., ZHIZENG, L.; Study of Multi-Freedom Myoelectric Prostheses with Tactile Sense, Engineering in Medicine and Biology Society, 27th Annual International Conference of the IEEE, 2005.
- [11] KHZERİ, M., JAHED, M., SADATİ, N.; Neuro-Fuzzy surface EMG pattern recognition for multifunctional hand prosthesis control, Industrial Electronics, IEEE International Symposium, 2007.
- [82] KHANDPUR, R.S., Biomedical instrumentation technology and applications, 1, The McGraw-Hill Companies, 178-179, 2005.

- [13] MEDVED, V., Measurement of human locomotion, CRC Press, 2001, 170-173.
- [14] MERLETTI, R., PARKER, P., Electromyography: Physiology, Engineering and Noninvasive Applications, Wiley-IEEE, 178-179, 2004.
- [15] YAZGAN, E., KORÜREK M., Tıp elektroniği, İstanbul Teknik Üniversitesi, 1996.
- [16] COHEN, A., Biomedical signal processing, CRC Press, 1986.
- [17] BURRUS, S.C., GOPINATH, R.A., GUO, H., Introduction wavelets and wavelets transforms, Prentice HALL, 1998.
- [18] SWELDENS, W., Wavelets: what next ?, Proceedings of the IEE, 84(4):680-685, 1996.
- [19] BURRUS, C.S., PARKS, T.W., DFT/FFT and convolution Algorithms, John Wiley&Sons, New York, 1985.
- [20] DONOHO, D.L., De-noising by Soft Thresholding, IEEE Trans. On. Inf. Theory, 41, 613-627, 1995.
- [21] DONOHO, D.L., JHONSTONE I.M., Ideal De-noising in an Orthonormal Basis Chosen from Library of Bases, CRAS, Paris, 1994.
- [22] COIFMAN, R., MEYER, Y., WICKERHAUSER, M., Wavelet Analysis and Signal Processing., Wavelets and Their Application, 1992.
- [23] COHEN, A., DAUBECHIES I., Multiresolution Analysis, Wavelets and Fast Wavelet Transform on an Interval, CRAS, Paris, 1993.
- [24] NAZARPOUR, K., SHARAFAT, A.R., FİROOZABADİ, S.M.P., Surface EMG signal classification using a selective of higher statistics, Engineering in Medicine and biology 27<sup>th</sup> Annual Conference, China, 2005.
- [25] GUANGYİNG, Y., Study of myoelectric prostheses hand based on independent component analysis and fuzzy controller, ICEMI'2007, 2007.
- [26] JIANG, M.W., WANG, R.C., WANG, J.Z., JIN, D.W., A method of recognizing finger motion using wavelet transform of surface EMG signal, Engineering in Medicine and biology 27<sup>th</sup> Annual Conference, China, 2005.
- [27] ZHAO, J., XIE, Z., JING, L., CAI, H., HONG, L., HIRZINGER, G., EMG control for a five-fingered prosthetic hand based on wavelet transform and autoregressive model, International conference on mechatronics and automation, China, 2006.

- [28] HAYKIN, S., Adaptive Filter Theory, PRENTICE HALL, 2001.
- [29] ÖZTEMEL, E., Yapay Sinir Ağları, Papatya Yayıncılık Eğitim Bilgisayar Sis. San. ve Tic. A.Ş. 2003.

## Ek

% Bu program Matlab' de \*.exp. uzantılı EMG işaretini db3 7 seviyeden dalgacık katsayılarından oluşan vektörün 20. dereceden öz bağlanımını katsayılarını elde eder--

```
clear all; close all; clc;
```

```
bpa01=openkeyp(' bpa01. exp');  
dbpa01=bpa01. Data;
```

% EMG Sinyalinin Dalgacık tabanlı AR modeli-----

```
[C, L]=wavedec(top1, 7, ' db3');  
top1A7=wrcoef(' a', C, L, ' db3', 7);  
top1D1=wrcoef(' d', C, L, ' db3', 1);  
top1D2=wrcoef(' d', C, L, ' db3', 2);  
top1D3=wrcoef(' d', C, L, ' db3', 3);  
top1D4=wrcoef(' d', C, L, ' db3', 4);  
top1D5=wrcoef(' d', C, L, ' db3', 5);  
top1D6=wrcoef(' d', C, L, ' db3', 6);  
top1D7=wrcoef(' d', C, L, ' db3', 7);  
top1=[top1A7; top1D7; top1D6; top1D5; top1D4; top1D3; top1D2; top1D1];
```

```
artop1_20=ar(top1, 20);  
artop1_20=artop1_20. Parametervector;  
artop1_20=artop1_20' ;
```

% İleri beslemeli geri yayılımı YSA-----

```
net = newff([minmax(P)], [20 2], {'tansig' ' tansig'}, 'trainlm');  
net. trainParam. epochs = 2000;  
net. trainParam. show = 2000;  
net. trainParam. lr = 0.8;  
net. trainParam. goal = 1e-15;  
net = train(net, P, T);  
Y = sim(net, Test);
```

% Lvq Ağ Yapısı-----

```
Tc=  
T = ind2vec(Tc)  
net = newlvq(minmax(P), 10, [.3 .4 .3]);  
net = train(net, P, T);  
Y = sim(net, P)  
Yc = vec2ind(Y)
```

% Radyal temelli ağ yapısı-----

```
net = newrb(P, T, 0, 90);  
Y = sim(net, Test);
```



## ÖZGEÇMİŞ

İsmail Yazıcı, 27.08.1979'da İstanbul'da doğdu. İlk, orta ve lise eğitimini İstanbul'da tamamladı. Şişli Çağlayan lisesinden mezun oldu. 1997 yılında başladığı Sakarya Üniversitesi Elektrik-Elektronik mühendisliği bölümünü 2001 yılında bitirdi. 2002-2003 yıllarında Hava Kuvvetleri Komutanlığı MEBS başkanlığında proje subayı olarak görev yaptı. 2003-2005 yılları arasında Elektrik mühendisi olarak özel sektörde çalıştı. Halen İstanbul Büyükşehir Belediyesinde çalışmaktadır.