

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

**EMG İŞARETLERİNİN MODERN YÖNTEMLERLE  
ÖNİŞLENMESİ VE SINIFLANDIRILMASI**

**DOKTORA TEZİ**

**Elektronik Yük.Müh. Mehmet Recep BOZKURT**

**Enstitü Anabilim Dalı : ELEKTRİK ELEKTRONİK MÜH.  
Enstitü Bilim Dalı : ELEKTRONİK MÜH.  
Tez Danışmanı : Prof. Dr. Etem KÖKLÜKAYA  
Ortak Danışman : Yrd. Doç. Dr. Abdülhamit SUBAŞI**

**Kasım 2007**

T.C.  
SAKARYA ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ

EMG İŞARETLERİNİN MODERN YÖNTEMLERLE  
ÖNİŞLENMESİ ve SINIFLANDIRILMASI

DOKTORA TEZİ

Elektronik Yük. Müh. Mehmet Recep BOZKURT

Enstitü Anabilim Dalı : ELEKTRİK ELEKTRONİK MÜH.

Enstitü Bilim Dalı : ELEKTRONİK

Bu tez 06 / 11 /2007 tarihinde aşağıdaki jüri tarafından Oybirliği ile kabul edilmiştir.



Prof. Dr. Etem KÖKLÜKAYA  
Jüri Başkanı



Prof. Dr. Hüseyin EKİZ  
Üye



Doç. Dr. Uğur ÇAM  
Üye



Yrd. Doç. Dr. Yusuf OYSAL  
Üye



Yrd. Doç. Dr. Cabir VURAL  
Üye

## TEŞEKKÜR

Bu tezin hazırlanması aşamasında sağladıkları her türlü destek ve yardımlarından dolayı tez danışmanlarım Sayın Prof. Dr. Etem KÖKLÜKAYA ile Sayın Yrd. Doç. Dr. Abdülhamit SUBAŞI'ya ve medikal alanların editörlüğünü yapıp tıbbi konularda kaynak temininde yardımlarını esirgemeyen Sayın Opr. Dr. H. Ayşe KATRANCI'ya en içten teşekkürlerimi sunarım. Ayrıca, üzerimdeki haklarını hiçbir zaman ödeyemeyeceğim, yaptığım işleri her zaman Hakkı ile yapmamı öğütleyen anne ve babama, gösterdikleri fedakarlıklardan, sabır ve desteklerinden dolayı eşim ve çocuklarıma sonsuz şükranlarımı sunarım.

Bu tezin<sup>1</sup> bu konuda yapılacak bundan sonraki çalışmalara ışık tutmasını dilerim.

---

<sup>1</sup> Bu tez Sakarya Üniversitesi Bilimsel Araştırma Projeleri Komisyon Başkanlığı tarafından 2006-FBD-040 numaralı proje kapsamında desteklenmiştir.

## İÇİNDEKİLER

TEŞEKKÜR.....	ii
İÇİNDEKİLER .....	iii
SİMGELER VE KISALTMALAR LİSTESİ .....	vi
ŞEKİLLER LİSTESİ .....	viii
TABLolar LİSTESİ.....	x
ÖZET .....	xi
SUMMARY .....	xii

### BÖLÜM 1.

GİRİŞ .....	1
1.1. Giriş .....	1
1.2. Geleneksel ve Sayısal Yaklaşımlar .....	3
1.3. EMG İşaretlerinin Modern Yöntemlerle Analizi.....	4

### BÖLÜM 2.

ELEKTROMİYOGRAM İŞARETLERİ VE İNCELENMESİ.....	8
2.1. EMG.....	8
2.2. Kasların Elektriksel Modeli ve EMG işareti.....	8
2.3. EMG İşaretinin Ölçülmesinin Temelleri .....	10
2.4. EMG 'nin Oluşumu ve Ölçülmesi .....	13
2.4.1. Uyarılabilen hücrelerin elektriksel aktivitesi .....	13
2.4.2. Dinlenme durumu .....	13
2.4.3. Kasların yapısı .....	14
2.4.4. EMG neden istenir ve nasıl uygulanır .....	20
2.5. EMG İşaretlerini İnceleme Metodları .....	21
2.6. EMG ile Teşhis Konabilen Hastalıklar .....	23
2.7. Myopati ve Nöropati Tanısında EMG' nin Rolü .....	24

## BÖLÜM 3.

SPEKTRUM KESTİRİM YÖNTEMLERİ .....	28
3.1. Parametrik Olmayan Spektrum Kestirim Yöntemleri .....	29
3.1.1. Hızlı fourier dönüşümü (HFD/FFT) .....	29
3.1.2. Hızlı fourier dönüşümünün EMG uygulaması.....	30
3.1.3. Periodogram yöntemi.....	31
3.1.4. Parametrik olmayan spektrum kestirim tekniklerinin incelenmesi	32
3.2. Parametrik Spektrum Kestirim Yöntemleri .....	33
3.2.1. Özbağlanımlı (AR) spektrum kestirimi .....	34
3.2.2. Özbağlanımlı (AR) spektrum kestirimi için Burg yöntemi .....	35
3.2.3. Özbağlanımlı (AR) spektrum kestirimi için Otokorelasyon (Yule Walker) yöntemi .....	36
3.2.4. Özbağlanımlı (AR) spektrum kestirimi için Kovaryans yöntemi ..	37
3.2.5. Özbağlanımlı (AR) spektrum kestirimi için İyileştirilmiş Kovaryans yöntemi .....	38
3.3. Modern Spektral Analiz Yöntemlerinin EMG Uygulaması .....	39
3.3.1. Model parametrelerinin hesaplanması .....	39
3.3.2. EMG işaretlerinin özbağlanım (AR) ile modellenmesi .....	40
3.4. Özellik Çıkarımı ve EMG.....	43
3.4.1. Yeni bir yaklaşım.....	44
3.4.2. Belirleyici özelliklerin seçilmesi .....	46

## BÖLÜM 4.

YAPAY SİNİR AĞLARI .....	50
4.1. Giriş .....	50
4.2. Yapay Sinir Ağlarının Temel Özellikleri.....	53
4.2.1. Yapay sinir ağlarının biyolojik kökeni .....	53
4.2.2. Yapay sinir hücresi .....	54
4.3. Yapay Sinir Ağlarının Yapısı .....	59
4.4. Ağ Çeşitleri .....	59
4.4.1. Tek katmanlı-ileri beslemeli sinir ağları (FFNN).....	60
4.4.2. Çok katmanlı-ileri beslemeli sinir ağları (MLFFNN).....	60

4.4.3. Döngülü yapay sinir ağıları (RNN).....	61	
4.4.4. Bileşik yapay sinir ağıları (CNN) .....	61	
4.5. YSA'da Öğrenme ve Hatırlama.....	63	
4.5.1. Eğitim ve test verisi seçimi .....	64	
4.6. Yapılan Uygulamada YSA Parametrelerinin Belirlenmesi ve Modelin Geliştirilmesi .....	65	
BÖLÜM 5.		
DENEYSEL EMG VERİLERİNİN SINIFLANDIRILMASI VE PERFORMANS KRİTERLERİ .....		69
5.1. Sınıflandırma Deneylerinin Sonuçları .....	70	
BÖLÜM 6.		
SONUÇLAR ve ÖNERİLER .....		76
6.1. Sonuçlar .....	76	
6.2. Öneriler .....	77	
KAYNAKLAR .....	79	
EKLER.....	85	
ÖZGEÇMİŞ .....	99	

## SİMGELER VE KISALTMALAR LİSTESİ

$\Sigma$	:	YSA'da Toplama Fonksiyonu
$a(k)$	:	AR katsayıları
$b$	:	YSA'da Bias
$b(0)$	:	Varyans (AR)
$\hat{e}$	:	En küçük karesel hata ( $\hat{e}_{f,p} + \hat{e}_{b,p}$ )
$e(n)$	:	Beyaz gürültü
$\hat{e}_{b,p}$	:	geri kestirim hatası
$\hat{e}_{f,p}$	:	ileri kestirim hatası
$f(\text{Net})$	:	YSA'da Aktivasyon Fonksiyonu
$f_s$	:	Örnekleme frekansı
$k_p$	:	yansıma katsayısı
$n$	:	Örnek zamanı
$p$	:	AR yönteminde model derecesi
$P(f)$	:	Güç Spektral Yoğunluğu
$W_n$	:	YSA'da Ağırlıklar
$X(f)$	:	Fourier dönüşümü
$X(k)$	:	Fourier katsayıları
$x_n$	:	YSA'da Girişler
$\mu\text{V}$	:	mikrovolt
A/D (ADC)	:	Analog Dijital Çevirici (Analog Digital Converter)
AC	:	Alternatif Akım (Alternative Current)
AFD	:	Ayrık Fourier Dönüşümü
AIC	:	Akaike bilgi kriteri (Akaike Information Criterion)
ANN	:	Yapay Sinir Ağı (Artificial Neural Network)
AR	:	Özbağlanım Modeli (Autoregressive)
ARMA	:	Özbağlanımlı Yürüyen Ortalama Modeli

CNN	:	Bileşik Yapay Sinir Ağı (Combined Neural Network)
CT	:	Bilgisayarlı tomografi (Computed tomography)
DC	:	Doğru Akım (Direct Current)
EEG	:	Elektroensefalografi (Electroencephalography)
EKG	:	Elektrokardiyografi (Electrocardiography)
EMG	:	Elektromiyografi (Electromyography)
ENG	:	Eelektronörografi (Electronorography)
EOG	:	Elektrookülografi (Electrooculography)
FEBANN	:	İleri Beslemeli Hata Geri yayımlı YSA (feedforward error backpropagation ANN)
FFNN	:	Tek Katmanlı-İleri Beslemeli Sinir Ağları (Feedforward NN)
FFT	:	Hızlı Fourier Dönüşümü (Fast Fourier Transform)
GA	:	Genetic Algoritma (Genetic Algorithm)
GSY	:	Güç Spektral Yoğunluğu (Power Spectral Density)
HFD	:	Hızlı Fourier Dönüşümü (Fast Fourier Transform)
Hz	:	Hertz
MA	:	Yürüyen Ortalama Modeli (Moving Average)
MLFFNN	:	Çok Katmanlı-İleri Beslemeli Sinir Ağları (Multi Layer FFNN)
MRI	:	Manyetik rezonans görüntüleme (Magnetic resonance imaging)
MUAP	:	Motor Ünite Aksiyon Potansiyeli (Motor Unit Action Potential)
mV	:	milivolt
MYO	:	Miyopati hastası Denek
NEU	:	Nörojenik Denek
NOR	:	Normal (Sağlıklı) Denek
PSD	:	Güç Spektral Yoğunluğu (Power Spectral Density)
RNN	:	Döngülü Yapay Sinir Ağları (Recurrent NN)
SNR	:	Sinyal – Gürültü Oranı (Signal to Noise Ratio, $P_{\text{signal}}/P_{\text{noise}}$ )
WNN	:	Wavelet Sinir Ağı (Wavelet Neural Network)
YSA	:	Yapay Sinir Ağı



## ŞEKİLLER LİSTESİ

Şekil 2.1. Klinik EMG düzeni basitleştirilmiş blok diyagramı.....	10
Şekil 2.2. Çeşitli EMG işaretleri.....	12
Şekil 2.3. EMG düzeneğinin uygulanışı.....	12
Şekil 2.4. İstemli hareket kaslarının yapısı.....	14
Şekil 2.5. Çizgili kasların kasılabilen elemanları.....	15
Şekil 2.6. Kaslarda servomekanizma.....	17
Şekil 2.7. EMG işaretlerinin oluşumu ve yüzey elektroda ulaşması.....	19
Şekil 2.8. Kasa uyarımın gelişi ve kasın kasılması.....	19
Şekil 2.9. EMG işaretlerinin (a) monopolar ve (b) bipolar deteksiyonu.....	21
Şekil 2.10. EMG işaretinin elektrotlara ulaşmaya kadar karşılaştığı işlemler.....	22
Şekil 2.11. Çeşitli şekillerin EMG potansiyelleri.....	24
Şekil 2.12. Normal, Nörojenik ve Myopatik EMG işaretleri.....	25
Şekil 2.13. Çeşitli motor ünite – EMG ilişkileri.....	27
Şekil 3.1. EMG işaretleri ve bu işaretlerin frekans spektrumları.....	32
Şekil 3.2. Miyopati hastası için kovaryans ve i. kovaryans S.G.Yoğunluğu.....	38
Şekil 3.3. Sağlıklı kişiye ait EMG işareti için AR-Burg spektrumu.....	42
Şekil 3.4. Miyopatik kişiye ait EMG işareti için AR-Burg spektrumu.....	42
Şekil 3.5. Nörojenik kişiye ait EMG işareti için AR-Burg spektrumu.....	43
Şekil 4.1. Biyolojik sinir sisteminin blok gösterimi.....	53
Şekil 4.2. Gerçek nöron'un yapısı ve nöronların birbirlerine bağlanması.....	54
Şekil 4.3. Yapay Sinir Hücresi.....	55
Şekil 4.4. Lojistik Sigmoid Fonksiyonu.....	57
Şekil 4.5. Hiperbolik tanjant fonksiyonu.....	57
Şekil 4.6. Eşik Fonksiyonu.....	58
Şekil 4.7. Kısmi Doğrusal Fonksiyon.....	58
Şekil 4.8. Yapay Sinir Ağının katman yapısı.....	59
Şekil 4.9. Tek katmanlı yapay sinir ağı.....	60

Şekil 4.10. Çok katmanlı yapay sinir ağı .....	61
Şekil 4.11. MUAP sınıflandırması için kullanılan Bileşik Sinir Ağı topolojisi .....	63
Şekil 4.12. YSA'nın eğitimi .....	64

## TABLolar LİSTESİ

Tablo 3.1. $n$ adet sayısal değerden oluşan veri için belirleyici özellikleri veren ifadeler .....	47
Tablo 4.1. 1970 sonrası YSA gelişimi .....	51
Tablo 4.2. Eğitim ve test veri set örneklerindeki sınıf dağılımları .....	68
Tablo 5.1. EMG İşaret sınıflandırması için farklı özellik çıkarım yöntemlerinin FEBANN kullanılarak karşılaştırılması .....	71
Tablo 5.2. EMG İşaret sınıflandırması için farklı özellik çıkarım yöntemlerinin CNN kullanılarak karşılaştırılması .....	72
Tablo 5.3. FEBANN – AR Yule .....	73
Tablo 5.4. FEBANN – AR Burg .....	73
Tablo 5.5. FEBANN – Kovaryans .....	73
Tablo 5.6. FEBANN – İyileştirilmiş. Kov. .....	73
Tablo 5.7. FEBANN – Belirleyici Özellikler .....	73
Tablo 5.8. CNN – AR Yule .....	73
Tablo 5.9. CNN – AR Burg .....	73
Tablo 5.10. CNN – Kovaryans .....	73
Tablo 5.11. CNN – İyileştirilmiş Kov. .....	73
Tablo 5.12. CNN – Belirleyici Özellikler .....	73
Tablo 5.13. Uygulanan tüm yöntemlere ilişkin başarımlar oranları .....	74

## ÖZET

Anahtar Kelimeler: EMG, Sınıflandırma, AR Spektral Kestirim, YSA, CNN, Miyopati, Nöropati, Motor Ünite Aksiyon Potansiyelleri (MUAP)

Bu çalışmada, intromasküler (kas içi) elektromiyografik işaretlere ait motor ünite aksiyon potansiyellerinin (MUAP) spektral analiz yöntemleri ile önişlenmesi ve desen sınıflandırması yapılmıştır. Sunulan metot otomatik olarak MUAP şablon kümelerinin sayısını bulmakta ve bunları normal, nörojenik veya miyopatik olarak sınıflandırmaktadır. EMG işaretlerinden öznitelik vektörü (feature vector) çıkartmak için farklı AR parametrik metotları ve alternatif olarak işaretin belirleyici özellikleri kullanılmıştır. Bu yaklaşım, 7'si normal, 7'si miyopatik ve 13'ü de nörojenik rahatsızlığı olan deneklerden elde edilen 1200 MUAP'lık EMG kayıtlarının bir veritabanında değerlendirilmesiyle sağlanmıştır. MUAP gruplarının doğru tanınması oranı normal, miyopatik ve nöropatik için sırasıyla %97, 90 ve 87 ve alternatif yöntemde % 97, 89 ve 90 dır. Eklenen MUAP'ların yaklaşık yüzde doksanı doğru olarak tanımlanmıştır. MUAP sınıflandırması için elde edilen doğruluk oranı, Bileşik Sinir Ağları (CNN) için %92'dir. Sunulan metot, çok hızlı EMG ayrışmaları sağlamasa da, işlenmemiş EMG işaretlerinden nöropatik, miyopatik veya normal sınıflara otomatik MUAP adreslemesini yapabilmektedir.

Çalışmada benzer bir sınıflandırma FEBANN ile de yapılmıştır. Elde edilen sonuçlar, bu çalışma için, CNN'in doğruluk oranlarının FEBANN'a göre daha yüksek olduğunu göstermektedir.

# **PRE-PROCESSING AND CLASSIFICATION OF EMG SIGNALS BY USING MODERN METHODS**

## **SUMMARY**

Key Words: Electromyography (EMG); Motor unit action potentials (MUAPs); AR spectral estimation method; Myopathy, Noropathy, Classification

This study proposes an electromyogram (EMG) pattern classification of individual motor unit action potentials (MUAPs) from intramuscular electromyographic signals. The proposed method automatically detects the number of template MUAP clusters and classifies them into normal, neuropathic or myopathic. To extract a feature vector from the EMG signal, we use different AR parametric methods and features of signals. The approach has been validated using a dataset of EMG recordings composed of 1200 MUAPs obtained from 7 normal subjects, 7 subjects suffering from myopathy, and 13 subjects suffering from neurogenic disease. The correct identification rate for MUAP clustering is 97, 90 and 87% for normal, myopathic and neuropathic, respectively. Almost ninety percent of the superimposed MUAPs were correctly identified. The obtained accuracy for MUAP classification is about 92% for combined neural network. The proposed method, apart from efficient EMG decomposition addresses automatic MUAP classification to neuropathic, myopathic or normal classes directly from raw EMG signals.

A similar classification was also made with FEBANN in the study. Obtained results show that the accuracy rates for CNN in this study is higher than FEBANN.

# BÖLÜM 1. GİRİŞ

## 1.1. Giriş

Biyolojik işaretlerin kompleks ve karmaşık bir biçimde olması ve matematiksel bir formülasyonunun kolayca elde edilememesi nedeniyle bu işaretlerin bilgisayarda modellenerek işlenebilmesini ve anlamlandırılmasını oldukça güçleştirmektedir. Ancak son yıllarda, matematiksel bir formülasyona gerek duyulmaksızın işaretlerin işlenmesine yönelik geliştirilen algoritmalar ve programlar biyolojik işaretler üzerindeki çalışmaların da giderek hızla artmasına neden olmuştur [1].

İlk dönemlerdeki çalışmalar daha çok desen tanımaya yönelik olmakla birlikte, günümüzde bu işlem örüntü tanıma ve görüntü işleme teknikleri ile daha paralel bir hal almıştır. Ancak 1960 ve 70'li yıllarda örüntü tanıma tekniği, geliştirilen algoritmalarla bilgisayara belli veri örneklerinin aratılmasından ibaretti. Bu numuneler veya örüntüler belli hastalıklara ait görüntü veya bir grup parametre olabilmekteydi. Çalışmaların daha ilerlediği zamanlarda ise, günümüzde örüntü sınıflandırması denilen teknik geliştirilerek örüntü tanıma tekniğinin kapsamı daraltılmış ve örüntü tanıma sadece belli resimler içerisindeki belli örüntülerin aranması olarak tanımlanmıştır. Örüntü sınıflandırma metoduyla başarılı çalışmalar gerçekleştirilmiştir. Bu alanda başarılı çalışmalar yapanların başında 1972 yılında Dombal ve arkadaşları [2], 1974 yılında Patrick, Stelmock, ve Shen [3], 1978 yılında Raeside ve Chu [4], 1979'da Kulikowski [5], ve 1985 yılında Cohen, Hudson, ve Deedwania [6] gelmektedir.

Gorry'nin bir çalışmasından[7] sonra, 1970li yıllarda yapay zekanın biyomedikaldeki potansiyel kullanımına karşı ilgi artmış ve o günden sonra yapay zeka teknikleri gelişimi hızlanmıştır[8]. Yapay zeka yaklaşımı, örüntü sınıflandırma yönteminden kaynaklanan dezavantajlardan dolayı popüler olmuştu. Bu dezavantajlardan biri de

algoritmaların bir kara kutu gibi olması ve hekimlere sadece sonuçların sunulması buna karşın sonuca dair herhangi bir açıklamanın sunulmamasıydı. Yapay zeka tekniğinin geliştirilmesiyle bilgisayarın verdiği sonuçlara uzmanlar tarafından da veri girişi yapabileme olanağı verildi. Bu sayede yukarıda bahsedilen yetersizliklere bir çözüm getirilebileceği düşünülmüştü. 10 yıl boyunca tıp bilminde kullanılan yapay zekâ (Miller,1988) tekrar kısıtlı bir alanda pratikte yeterli olmaya başlamıştı. Birkaç mükemmel sistemin geliştirilmiş olmasına rağmen çok azı pratikte kullanılabildi. Bu geliştirilen sistemlerden en meşhur olanı 1976 yılında Shortliffe tarafından geliştirilen MYCIN'dır[9]. 1980'lerin ortalarında Yapay Sinir Ağları modelleri, Yapay zekâyâ alternatif olarak çıkmıştır. Bu modellerle örüntü sınıflandırma sistemlerinin pek çok ortak noktası bulunmaktaydı. Bu ortak nokta da sonuçların uzmanlar yerine verilerden alınmasıdır.

Biyomedikal sistemlerde uygun paradigmalardan geliştirilmesi ile alakalı problemlerin yanında karşılaşılan bir diğer problem de tıbbi kayıtlarla ilgilidir. Tıbbi kayıtların karmaşık olmalarının sebebi pek çok farklı bileşenin önemli olmasıdır. Sayısal test sonuçları, elektromiyogram (EMG) ve elektrokardiyogram (EKG) gibi analog çıktılar, radiograf, bilgisayarlı tomografi (CT), Manyetik rezonans görüntüleme (magnetic resonance imaging) (MRI) nükleer tıp taramaları, ultrason ve el yazısı gibi grafiksel çıktılar ve bu veri tiplerinin yanı sıra çıktılar üzerine el yazısıyla alınmış notlar veya sonuçların el yazısıyla verilmesi, işi daha da karmaşık hale sokmaktadır. Geçtiğimiz son 40 yıl içerisinde bu farklı veri tiplerinin otomasyonunun kolayca yapılarak organize edilmesi için değişik denemeler yapılmıştır [1].

Massachusetts General hastanesinden Greenes ve arkadaşları tıbbi kayıtların bilgisayarda tutulmasına dair çalışmalarda bulunmuş [10], hiyerarşik bir veri tabanı olan COSTAR adında bilgisayar tabanlı tıbbi kayıt sistemi oluşturmuştur. Vermont Üniversitesinden Schultz ise PROMIS'i (Problem yönlendirmeli tıbbi bilgilendirme sistemi) geliştirmiştir[11]. Bu sistemde, tıbbi verilerin organizasyonunun yanı sıra verilen tıbbi kararlar da kayıt altına alınmıştır. Tıbbi veriler çerçeveler içinde organize edilmiştir. 1970'lerde Standford üniversitesinde geliştirilen ARAMIS sistemi PROMIS sistemi temel alınarak geliştirilmiş ancak bu sisteme önemli bir unsur olan (TOD) zaman-yönlendirmeli kayıt sistemi eklenilmiştir. Böylelikle

hastanın zaman içerisindeki gelişimi ve uygulanan tedavilere karşı gösterdiği reaksiyonları izlemek mümkün olmuştur[1]. Warner, Rutherford ve Houtchens (1972) tarafından geliştirilen HELP programının amacı tıbbi karar alınımında yardımcı olmaktır. Bu sistemin güzel tarafı, işlenmemiş verilere erişim imkanı vermesinin yanı sıra hastaya ait daha önce yapılan o anki hastalıkla alakalı diğer teşhisler ve bunların tedavisi ile alakalı verileri de sunmaktaydı[12]. Miller MEDUS/A (Ben Bassat et.al., 1980) sisteminin geliştirilmesine 1977 de PROMIS’de olduğu gibi çerçeve sistemini kullanarak Harvard’da başlamıştır[13].

## 1.2. Geleneksel ve Sayısal Yaklaşımlar

Çoğunlukla bir biyolojik sistemin tam olarak nasıl işlediği bilinemediğinden buna ait bir modelinin kesin netlikte çıkartılması da söz konusu olamamaktadır. Dolayısıyla tıpta tedavi için karar vermeye yardımcı olması için oluşturulmuş tam algoritmik yaklaşımlar başarılı olamamıştır. İlk dönemlerde pek az deterministik model tanımlanmıştır. Bu da örüntü tanıma tekniklerinin geliştirilerek sınıflandırma problemlerine uyarlanmasına sebep olmuştur. Bu modeller bilgisayarın veri içerisinde belli bir örüntüyü arayabilmesini olanaklı kılmıştır. Sadece birikmiş verilere dayalı yaklaşımların bazı dezavantajları olmaktadır. Örneğin, model verinin sadece netliğine bağlı değil, verinin diğer popülasyonlara da uygulanabiliyor olmasıyla da sınırlıdır [1].

Yani, eğer veriler 20–30 yaş grubuna ait bir erkek popülasyonundan toplansaydı, askeri bir hastaneden alınan bu örneklerle tüm popülasyonun genellemesini yapmak mümkün olmazdı. Bu problemle tıp alanında yapılan diğer çalışmalarda da karşılaşılmaktadır. Homojen bir topluluk olan Finlandiya’daki kalp hastaları üzerinde yapılan çalışmalar, birbirinden son derece farklı özelliklere sahip olan Amerika’daki kalp hastalarına uyarlanamamaktadır.

Bilgiye dayalı yaklaşım, bilgi tabanlı olduğu için uzman girişi sayesinde bu problemi ortadan kaldırmıştır. Bilgi tabanlı yaklaşımda da problemler mevcuttur. Bilgi tabanını oluşturmak için bir veya ufak çapta bir grup uzmanın görüşünün alınması, bu gruba dahil olmayan başka gruplar tarafından farklı görüşler sunulurak



kabul edilmemekte, eksik bulunabilmektedir. Ayrıca, hızlı gelişen yeni bilgiler için metotların geliştirilmesi de bu sistemin bir başka problemi.

Uzmanlar sembolik ve sayısal yaklaşımlardan hangisinin biyomedikal verilerinin saklanması uygun olacağı konusunda tam bir uzlaşmaya varamamışlardır. Yakın zamanda geliştirilen bazı karma sistemler sayesinde her iki yaklaşımdan elde edilen verilerin kullanılması sağlanmıştır[14]. Bu karma sistemler tek bir problemin çözümlenebilmesi için iki veya daha fazla tekniğin kullanılmasını gerektirmektedirler.

### **1.3. EMG İşaretlerinin Modern Yöntemlerle Analizi**

Omurilik, sinirler veya kasları etkileyen 100'den fazla nöromusküler rahatsızlık bulunmaktadır. Klinik muayeneler ve laboratuvar testleri ile bu rahatsızlıkların erken teşhis edilebilmesi, bu rahatsızlıkların kontrol altında tutulabilmelerinin yanısıra doğum öncesine ait teşhislerin yapılabilmesi için ve genetik alanında alınabilecek uzman tavsiyeleri açısından önemlidir. Ayrıca bu bilgiler rahatsızlığın anlaşılabilmesi ve daha sonrasında da tedavi geliştirilebilmesi çalışmalarına ışık tutacağından araştırmalar açısından çok değerlidir [15]. Motor ünite morfolojisi, Elektromiyografi (EMG) olarak bilinen elektriksel hareketlerin kaydedilmesiyle incelemeye. Klinik EMG motor ünite potansiyelleri (MUP'leri), iğneli elektrodlar ile hafif kasılmalar verildiğinde alınan tepkilerin kaydedilmesiyle ölçülür. MUP, tek bir anatomik motor ünitesinin elektriksel hareketini yansıtmaktadır, elektrodun kayıt kapsamındaki kas liflerinin birleştirilmiş hareket potansiyelini temsil etmektedir. Klinik çalışmalarda MUP'nin özellikleri zaman esastır. Devamlılık süresi, genlik ve aşama parametreleri kas ve sinir hastalıklarının birbirinden ayrılmasında önemlidir. Bunlardan devamlılık süresinin ölçümü klinik çalışmalarda anahtar parametre olarak kullanılmaktadır [16]. Kas gücü arttıkça EMG işaretlerindeki yeni aktif olmuş MUP'lerin de sayısında artış gözlenmektedir, bu da nörofizyolojistlerin her bir MUP dalgacığını ayırt etmesini zorlaştırmaktadır. EMG işaretlerinin ayrıştırılması ve MUP'lerden benzer şekilli olanlarının gruplandırılarak sınıflandırılması nöromusküler patoloji değerlendirme açısından değerli bilgiler sunmaktadır [15].

Nörofizyolojist ve/veya kullanılan bilgisayar destekli metod da önemli bir etken olmak koşuluyla, devam süresi parametresinin ölçümü oldukça karmaşıktır. Bu parametrenin bilgisayar destekli ölçümünde geniş kitlelerce kabul edilen belli bir kriter henüz bulunmamaktadır[17]. Bir diğer yandan, MUP'nin, frekans uzayındaki özellikleri, ortalaması, bantgenişliği ve kalite faktörü gibi, frekans kümesi de nöromasküler rahatsızlıkların değerlendirilmesinde ek bilgiler sunmaktadır. Ayrıca yakın zamanda MUP'nin aritmetik ortalaması veya ortalama frekansının gücünün devam süresi [18] ile veya doruk (spike) devam süresi [19] ile eşdeğer olduğu görülmektedir. Bilgisayar alanındaki son gelişmeler otomatik EMG analizi yapılmasını mümkün hale getirmiştir.

Sayıli miktarda bilgisayar tabanlı nicel EMG analiz algoritması geliştirilmiştir. Bu analiz algoritmalarından bazıları ticari olarak mevcut olmasına rağmen hemen hemen hiçbiri yaygın rutin klinik bulgu için genel olarak kullanılmamıştır. Pattichis ve Elia EMG işaretlerinin sınıflandırılması için özbağlanım (autoregression) ve cepstral analizleriyle zaman uzayında analizi birleştirerek kullanmıştır [18].

Bunun yanı sıra, De Michele ve arkadaşları dalgacık çapraz-korelasyonu analizini iki farklı kasa uygulayarak bu analizin daha geniş ve ayrıntılı sınıflandırmayı mümkün kıldığını belirterek Parkinson hastalığının güvenilir geçici evrim analizinin detaylı açıklamasını da sunmuştur [20].

Pattichis ve arkadaşları, MUP parametrelerini sıralı parametrik örüntü tanıma sınıflandırıcısına giriş değeri olarak kullanmıştır[21]. Loudon ve arkadaşları ise, sekiz MUP özelliğini, sınıflandırma için istatistiksel örüntü tanıma tekniğinde giriş olarak kullanmıştır[22]. Üst üste bindirilmiş (superimposed) dalga formlarının ayrıştırılmasında hem yordamlara (procedure) hem de bilgiye dayalı metotlar kullanılmıştır. Hassoun ve arkadaşları Elektromiyografide (EMG) tekrarlanan vektörler için yapay sinir ağları ayrıştırımını (NNERVE) sunmuştur. Bu çalışmada, zaman uzayındaki dalga formları üç katmanlı yapay sinir ağlarına (YSA) giriş olarak kullanılırken, "Pseudo Unsupervised" öğrenme algoritması ise sınıflandırma için kullanılmıştır[23, 24]. Christodoulou ve Pattichis MUP'lerin sınıflandırılması için iki

farklı örüntü tanıma tekniği kullanmıştır[15]. Christodoulou ve Pattichis kendisini organize eden model (Self Organized Feature Maps) algoritmasını ve Learning Vector Quantization (LVQ, öğrenen vektör nicelendiricisi) ve Öklit (Euclidian) mesafesini temel alan istatistiksel örüntü tanıma tekniklerinden faydalanarak denetimsiz öğrenmeyi temel alan yapay sinir ağları tekniğini kullanmışlardır. Buna ek olarak, Schizas ve Pattichis EMG işaretlerindeki örüntü sınıflandırmaları için genetik tabanlı makine öğrenmesini kullanmışlardır[25]. Mevcut nicel EMG analiz metodlarında klinik çalışmalar için yaygın olarak kullanımını kısıtlayacak bazı sınırlamalar bulunmaktadır.

EMG işaretlerinin incelenmesi ile ilgili olarak son yıllarda yapılan çalışmalarda çoğunlukla dalgacık (wavelet) analizi yöntemi kullanılmıştır. Dalgacık analizinin beraber kullanıldığı yöntem ise çoğunlukla yapay sinir ağları olmaktadır. Subasi ve arkadaşları EMG işaretlerini dalgacık yapay sinir ağları (WNN) ile sınıflandırmışlardır[26]. Yine Xin Guo ve arkadaşları alınan EMG işaretlerini dalgacık analizi ile ayırtmış ve sonrasında Learning Vector Quantization (LVQ, öğrenen vektör nicelendiricisi) temel alan yapay sinir ağları tekniğini kullanmışlardır[27]. Benzer şekilde Mohamad O. Diah ve arkadaşları, rahim kaslarından alınan EMG işaretlerini dalgacık analizi kullanarak ayırtmış ve bunları istatistiksel sınıflandırma metodlarını temel alan yapay sinir ağları ile sınıflandırarak, erken doğum teşhisi için kullanmışlardır[28]. Jilian Salvador ve arkadaşları, fourier güç katsayılarını desen sınıflandırıcı olarak kullanmış ve sonra bunu dalgacık dönüşümünün sınıflandırıcı olarak kullanıldığı yöntemle karşılaştırmışlardır[29]. Jun-Uk Chu ve arkadaşları yine dalgacık dönüşümü kullanarak, çok fonksiyonlu bir sanal-el'de kullanılmak üzere, eşzamanlı (realtime) çalışan bir sistem tasarlamışlardır[30].

Yu Su ve arkadaşları, EMG cihazından gelen işaretlerin frekans analizini yapmışlar ve daha sonra zaman ve frekans uzaylarında desen tanıma tekniklerini kullanmışlardır[31].

J.Z. Wang ve arkadaşları yüzey elektrotlar ile alınan EMG işaretlerini önce AR modeli kullanarak inceleyip veri kalabalığından kurtardıktan sonra, AR modelinin

katsayılarını yapay sinir ağlarına aktararak sınıflandırma çalışması yapmışlardır[32]. M.W. Jiang ve arkadaşları, EMG işaretlerinin sınıflandırması için, önce dalgacık dönüşümü yapmış, sonra dalgacık katsayılarının istatistiksel özelliklerini belirlemiş ve sonra da bu özellikleri yapay sinir ağlarına girerek sınıflandırma yapmışlardır[33]. Benzer şekilde Liyu Cai ve arkadaşları da EMG işaretlerinin sınıflandırılması için öncelikle dalgacık katsayılarından özellik vektörleri (feature vector) çıkarmışlar, ve sonra bu vektörleri yapay sinir ağının giriş değerleri yapıp, standart geriyayılım algoritması kullanarak ağı eğitmişlerdir[34].

Bu çalışmada, EMG'den sınıflandırılabilir sonuçlar çıkartmada AR modellerinin kullanımının detaylı araştırması yapılmıştır. Burada AR güç spektral yoğunluğu (Power Spectral Density / PSD) kullanılarak EMG işaretleri temsil edilmiştir. EMG işaretlerinin PSD değerleri değişik parametrik yöntemlerle elde edilmiş ve bu yöntemler kendi aralarında karşılaştırılmıştır. AR parametreleri otokorolasyon (Yule-Walker), kovaryans, iyileştirilmiş kovaryans, ve Burg yöntemleriyle elde edilmiştir. Parametrik yöntemlerle spektral analizi yapılan işaretler bu aşamadan sonra yapay sinir ağları kullanılarak sınıflandırılmıştır. Sunulan teknikler Normal (sağlıklı), Myopati hastası ve Nöropati hastası deneklerden elde edilen EMG işaretlerinin sınıflandırılması ve ayrıştırılmasında başarıyla uygulanmıştır.

Ayrıca farklı bir çalışma olarak EMG işaretlerinin belirleyici özellikleri çıkartılmış, bu belirleyici özellikler yapay sinir ağının eğitiminde kullanılmıştır. Belirleyici özellikler içinden maksimum ve minimum noktaları, sıfır geçiş sayıları, standart sapma, medyan, ortalama ve karesel ortalama seçilerek kullanılmıştır. Bu özellikler ile eğitilen ağ, daha sonra test verilerinin belirleyici özellikleri çıkartılarak test edilmiş ve EMG işaretlerinin sınıflandırılmasında başarı ile uygulanabilirliği görülmüştür. Bu yöntem işlem yükünü çok azaltmakta ve çok hızlı sonuç vermektedir. Bununla beraber başarı yüzdesi de çok yüksek çıkmaktadır. Literatürde birebir bu tip bir çalışma daha önce bulunmamaktadır. Son olarak yapılan iki farklı çalışma yönteminin başarı verimlilikleri birbirleri ile karşılaştırılmıştır.

## **BÖLÜM 2. ELEKTROMİYOGRAF İŞARETLERİ VE İNCELENMESİ**

### **2.1. EMG**

Elektromiyogram, kasların dinlenme ve kasılma durumlarında üzerlerinde oluşan elektriksel aktivite olarak tanımlanır. Bu aktiviteyi kaydeden sisteme elektromiyograf ve bu işleme de elektromiyografi (EMG) denir. EMG işaretlerinin alınmasında çeşitli elektrotlar kullanılmakla beraber, en geniş ve en genel anlamda EMG işaretleri test edilecek kas üzerindeki deriye yüzey elektrotları yerleştirilerek alınır. Yüzey elektrotları aracılığıyla kasın elektriksel aktivitesi olan dinlenme ve kasılma halinde oluşan biyopotansiyel işaretler kaydedilir [35, 36].

### **2.2. Kasların Elektriksel Modeli ve EMG İşareti**

Kaslarının kasılması sırasında biyopotansiyel işaretler oluşur, bu işaretlere EMG adı verilir. Bu biyopotansiyel işaretlere vücuttaki çeşitli elektrokimyasal olaylar sebep olur. İstemli kas hareketleri, beyinde oluşturulan elektriksel uyarıların sinirler vasıtasıyla kaslara iletilmesi sonucunda meydana gelir. Kas liflerinin kasılmalarına sinirlerden gelen elektriksel uyarılar sebep olduğu gibi, kasların kasılması da yine elektriksel bir işaretin ortaya çıkmasına sebep olur. Ortaya çıkan bu işaret Elektromiyogram cihazına bağlı elektrotlar aracılığıyla ölçülür [35, 36].

Kasların kasılması Motor Ünite Aksiyon Potansiyelleri (MUAP, the Motor Unit Action Potential) olarak bilinen elektriksel potansiyeller sayesinde olur. Bu MUAP'lar sinirler aracılığıyla beyinden iletilmiş olan uyarıcı potansiyeller tarafından oluşturulur. MUAP'ların sayısı ve sıklığı arttıkça kasılma miktarı da artar. Kaslardaki problemlerin belirlenmesi açısından, kasların kasılı olduğu ve olmadığı durumlarda MUAP'ların incelenmesi, MUAP'ların şeklinin veya sıklığının normal

sınırlar içinde olup olmaması, normalde karşılaşılmayan elektriksel aktiviteler olup olmaması gibi durumlar incelenir [37].

Sinir ve kas hücreleri uyarılabilen hücrelerdir ve bu hücrelerdeki elektrokimyasal olaylar sonucunda biyoelektrik potansiyeller ortaya çıkar. Bu hücreler sürekli bir “dinlenme” potansiyeline sahiptir. Uyarıldıklarında ise “aksiyon” potansiyeli meydana gelir. Dinlenme halinde uyarılan hücrelerin içi ve dış ortam arasında genliği -50mV ile -120mV arasında değişen bir elektrik potansiyel farkı vardır. Vücut ısısındaki iyonları geçirebilen bir yapıya sahip olan hücre zarı çok incedir(7-15 nm). Vücut sıvısı içinde Sodyum( $\text{Na}^+$ ) Potasyum ( $\text{K}^+$ ) ve Klor ( $\text{Cl}^-$ ) iyonları mevcuttur.

Aksiyon potansiyelinin mutlak değeri sinir hücrelerinde 100-120mV aralığındadır ve 1-1,5 ms sürer. Kas hücrelerinde ise aksiyon potansiyeli 2-4 ms sürer ve aksonlardaki yayılma hızı 5 m/s kadardır. Hücre uyarıldığında, hücre zarının özelliği değişerek  $\text{Na}^+$  iyonlarının hücre içine girmesine ve az bir miktar  $\text{K}^+$  iyonunun dışarı çıkmasına izin verir. Bunun sonucunda hücre içi pozitif, dışı ise negatif olur. Bu olaya “depolarizasyon” denir [35, 36].

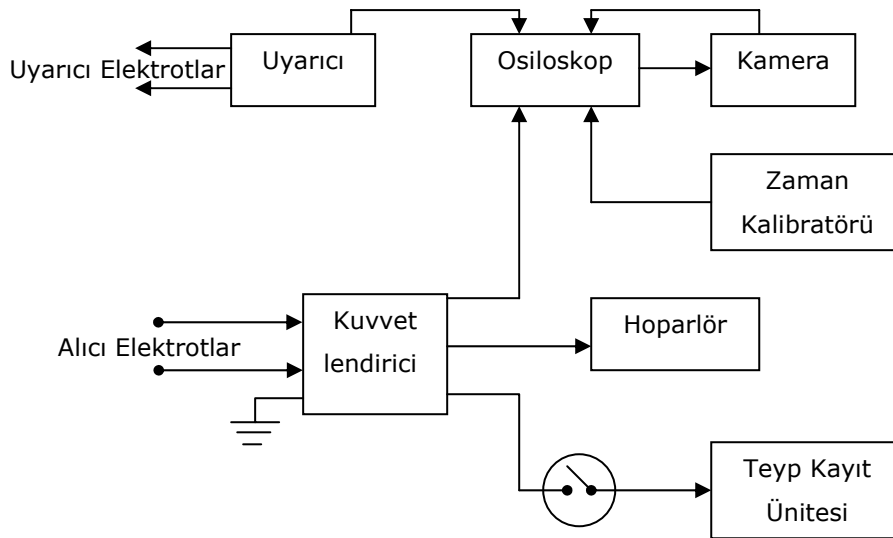
Aksiyon potansiyeli belirli bir tepe değere ulaştıktan sonra, yukarıda anlatılan olaylar tersine işler ve tekrar dinlenme potansiyeli seviyesine düşer. Bu olaya ise “repolarizasyon” denir. Aksiyon potansiyelinin depolarizasyon ve repolarizasyon olayları sırasında geçen 1-3 ms kadar süre içinde hücre tekrar uyarılamaz. Hücrenin tekrar uyarılamadığı bu süreye mutlak bekleme süresi denir. Hücrenin, mutlak bekleme süresinden sonra daha şiddetli uyarılara cevap verdiği bir bağıl bekleme süresi vardır [38].

Ortaya çıkan bu işaretin genliği düşük olduğundan kuvvetlendiriciler yardımıyla genliğinin artırılması gerekmektedir. Bu işaretlerin kuvvetlendirilmesinde farksal kuvvetlendiriciler kullanılır. EMG işaretleri kas ve sinir hastalıklarının teşhislerinde kullanıldığı gibi, kol-bacak vb organ kesilmesi durumlarında kullanılan protezlere hareket sağlayacak kaynak işaret olarak da kullanılmaktadır [39].

İskelet kaslarının fonksiyonel olarak temel birimi motor üniteleridir. Motor ünitesinin bileşenleri gevşek demetlerde demet boyunca uzanır. Kaslarda çeşitli motor ünitelerinin lifleri iç içedir. İğne elektrotlarla tek birim motor ünitesinden uyarılma sonucu oluşan hücre dışı potansiyel değişimleri 3-15 ms kadar sürer ve motor ünitesinin büyüklüğüne bağlı olarak genliği 20-200 mV arasında değişir. Deşarj frekansı ise 6-30 darbe/sn civarındadır [35, 36, 39].

### 2.3. EMG İşaretinin Ölçülmesinin Temelleri


EMG işaretleri yüzey elektrotları ve iğne elektrotları olmak üzere iki tip elektrot aracılığıyla ölçülmektedir. Bunlardan yüzey elektrotları ile yapılan ölçümlerde geniş bir alandaki elektriksel aktivite ile ilgili bilgi edinilmektedir. Bir motor ünitesinin veya üniteler grubunun incelenmesinde, elektrotların bilgi topladıkları alttaki alan çok geniş olabilir. Ayrıca yüzeydeki kasların faaliyetinin alttaki kaslardan gelen bilgiyi maskeleymesi sebebiyle yüzey elektrotlarını yalnız yüzeydeki kasların incelenmesinde kullanmak gerekmektedir. Bir kas grubunun faaliyetinin diğer bir kas grubu faaliyetini maskeleymesi olayı, çok miktarda motor birim aksiyon potansiyellerinin karışması ile olur ve bu olay “girişim olayı” olarak bilinir. Kasılma şiddeti sonucu aktif motor birim sayısı artar. Aynı anda birçok kas lifinin etkinleşmesiyle, her bir kas lifinin ürettiği işaret bir diğerini yok edebilir ya da kuvvetlendirebilir [35, 36, 40].




Şekil 2.1. Klinik EMG düzeni basitleştirilmiş blok diyagramı

EMG işaretini ölçmekte kullanılan sisteme ait blok diyagram Şekil.2.1’de verilmiştir.

Sonuç olarak EMG’nin zaman içerisindeki görüntüsü rasgele değişen bir gürültüye benzer. Şekil 2.2’de çeşitli EMG işaretleri ve Şekil 2.3 te ise EMG düzeneğinin uygulanması gösterilmiştir.




Şekil 2.2.a. Sağlıklı kişiye ait EMG işareti

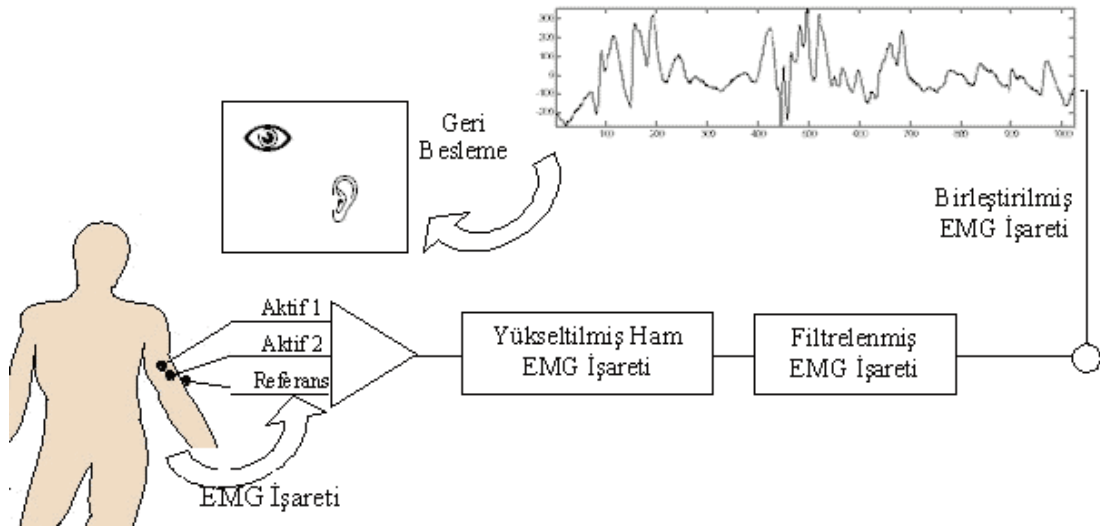


Şekil 2.2.b. Nöropati hastası kişiye ait EMG işareti





Şekil 2.2.c. Myopati hastası kişiye ait EMG işareti



Şekil 2.3. EMG düzeneğinin uygulanışı

EMG işaretlerinin alınmasında kullanılan elektrot çeşitlerinden birisinin yüzey elektrotları olduğuna daha önce değinilmişti. Yüzey elektrotlar, bağlanacak yüzey iletkenliği önleyecek kir, yağ tabakası vs gibi maddelerden temizlemek amacıyla asetonlu pamukla silindikten sonra bağlanır. Yüzey temizleme işleminden sonra elektrot çiftine iletkenliği artırmak amacıyla jel sürülür ve ölçüm yapılacak bölgeye yerleştirilir. Elektrotlardan gelen EMG işaretlerinin genliği kuvvetlendirici tarafından yükseltilir. Daha sonra yükseltilmiş bu işaret kesim frekansı 10 Hz olan bir yüksek geçiren filtreden geçirilerek istenmeyen DC bileşenlerden arındırılır. Ayrıca şebekeden kaynaklanan 50 Hz'lik gürültüyü engellemek amacıyla bant genişliği 2 Hz olan bir çentik filtre kullanılır. İşaretin AC değerinin düzgün olarak

elde edilebilmesi için ortalama deęerinin alınması gerekir. Bunun için önce iřaret tam dalga doęrultucudan ve sonra alak geiren filtrelerden geirilir. Bu ařamada elde edilen EMG iřareti giriřteki ham EMG iřaretinin yükseltir miř ve ortalama deęeri alınmıř řeklidir. Bu ařamadan sonra elde edilen EMG iřareti A/D dnüşürücüden geirilerek bilgisayar ortamında kayıt edilebilir [40].

## **2.4. EMG 'nin Oluřumu ve Ölülmesi**

Bir kasın kasılması sonucu ortaya ıkan biyopotansiyel iřaretlere EMG dendięi daha önce belirtilmiřti. Bu biyopotansiyel iřaretler vücutta meydana gelen çeřitli elektrokimyasal olaylar sonucunda oluşur. İstemli kas hareketleri beyinden gönderilen elektriksel uyarıların sinirler yoluyla kasa iletilmesi sonucu ortaya ıkar. Kas liflerinin kasılmaları sinirlerce iletilen elektriksel uyarılar yoluyla gerekleřtięi gibi kasılmaları da elektriksel bir iřaret doğurur. Bu iřaret ięne veya yüzey elektrotlarıyla ölçülür [38, 39].

### **2.4.1. Uyarılabilen hücrelerin elektriksel aktivitesi**

İnsan vücutunda uyarılabilen hücreler, sinir ve kas hücreleridir. Bu hücrelerdeki elektrokimyasal olaylar sonucunda biyoelektrik potansiyeller meydana gelir. Sinir ve kas hücrelerinde sürekli bir “dinlenme potansiyeli” vardır. Uyarıldıklarında ise “aksiyon potansiyeli” meydana gelir [35, 36, 38].


### **2.4.2. Dinlenme durumu**

Dinlenme halinde iken, yani kaslarda bir kasılma söz konusu deęilken, uyarılabilen hücrelerin ii ile dıř ortam arasında bir elektrik potansiyel farkı vardır. Dinlenme gerilimi adı verilen bu gerilim -50 ile -100 mV aralıęında bir genlięe sahiptir. Hücre zarı ok incedir (7-15 nm) ve yapısı sebebiyle vücut ısısındaki iyonları geirebilir. Vücut sıvısı iinde sodyum (Na<sup>+</sup>), klor (Cl<sup>-</sup>) ve potasyum (K<sup>+</sup>) iyonları mevcuttur. Hücre zarının potasyum iyonlarına karřı geirgenlięi, sodyum iyonlarına karřı geirgenlięinden 50-100 kat daha fazladır. Bu farkın nedeni henüz bilinmemekle beraber hücre zarındaki gözeneklerin yapısına baęlı olduęu düşünölmektedir. Hücre zarı potasyum iyonlarını olduęu gibi klor iyonlarını da daha kolay geirir. Dinlenme

durumunda vücut ısısındaki  $K^+$  ve  $Cl^-$  iyonlarının büyük çoğunluğu hücre içine girerek hücre içinin negatif, hücre dışının ise pozitif olmasına neden olur. Bu duruma polarize durum denir [35, 36, 39].

### 2.4.3. Kasların yapısı

İskelet kasları ince uzun hücrelerden meydana gelir ve bu hücrelere lif (fiber) adı verilir. Bu hücrelerin uzunlukları 1-50 mm ve çapları 10-100 $\mu$ m arasındadır. Dış yüzeyleri sarkolemma ismi verilen bir kılıf ile kaplıdır. Bu lifler kıkırdak dokuya bağlıdır. Liflerin kısalıp şişmesi ile kasın kasılma hareketini sağlar. Kan damarları vasıtasıyla beslenen kaslar, elektriksel uyarıları ise sinirler vasıtasıyla alırlar. Üç tip kas vardır ve bunlar çizgili kaslar, düz kaslar ve kalp kasları olarak adlandırılır [35, 36, 40].




Şekil 2.4. İstemli hareket kaslarının yapısı

### 2.4.3.1. Çizgili kaslar

Yapısı Şekil 2.4 te gösterilen çizgili kaslar, insan vücudunda, istemli hareketlerin gerçekleşmesini sağlayan iskelet kaslarıdır. Mikroskop altında incelenen çizgili kaslarda açık renkli ve koyu renkli bantlar gözlenmiştir. Gözlemlenen bu bantlardan koyu renkli olana A bandı, açık renkli olana ise I bandı olarak isim verilir. Ayrıca koyu renkli A bandının ortasında açık renkli H bandı ve açık renkli I bandının ortasında koyu renkli Z bandı olduğu görülmüştür [40, 41].

Z bantları arasında kalan bölge uyarma anında kasılarak daralır, buna karşılık A bandı ise sabit kalır. Çizgili kaslarda bulunan proteinin myosin bileşeni A bandında mevcuttur. Actin bileşeni ise Z bandında başlar ve H bandında yok olur. Çizgili kaslara ait kas elemanları Şekil 2.5 te verilmiştir [40, 41].



Şekil 2.5. Çizgili kasların kasılabilen elemanları

### 2.4.3.2. Kas kasılması

Kas lifi demetlerinden meydana gelen çizgili kaslarda iki çeşit lif yapısı vardır. Kaslara sinirler vasıtasıyla bir uyarı geldiğinde bu lifler üst üste gelip birbirlerine kilitlenir ve bu sayede kasılma olayı gerçekleşmiş olur.

Kasılma işlemi için kasa gelen uyarı, motor siniri ile taşınır. Kas, çeşitli uyarılara cevap verebildiği gibi elektrik akımından kaynaklanan bir uyarıya da cevap verebilir. İki çeşit kas kasılması vardır. Eğer kas boyu sabit kalıp sadece şişerek kasılıyorsa buna statik (izometrik) kasılma, hem boyu kısalıp hem de şişerek kasılıyorsa buna da

dinamik (izotonik) kasılma adı verilir. Kasa bir uyarı işareti geldikten sonra bir zaman gecikmesi ile önce kasılma ve ardından bir gevşeme oluşur.

Kasın kasılması olayı kimyasal olarak şu şekilde gerçekleşmektedir: Kas aktif hale gelince glikojen depoları boşaltılır, oksijen kullanımı ile glikozen parçalanırken karbondioksit meydana çıkar. Glikojen parçalanarak prüvik aside dönüşürken yüksek enerjili ATP (Adenozin Trifosfat) moleküllerinde depolanmış olan enerji açığa çıkar. Prüvik asidin tekrar oksitlenmesi ile sitrik asit çevriminde karbondioksit (CO<sub>2</sub>) ve su (H<sub>2</sub>O) ile birlikte yeni ATP molekülleri oluşur. Oksijen (O<sub>2</sub>) yetersizliği durumunda ise prüvik asitten oksijensiz (anaerobik) reaksiyonla laktik asit üretilir ve yeni enerji açığa çıkar [40, 41].

Kasların çalışması ile doğru orantılı olarak solunum ve oksijen alımı artar. Artan bu oksijen alımı, enerji üretimi sırasında harcanan oksijen açığını kapatır. Laktik asidin beşte biri oksitlenerek CO<sub>2</sub> ve H<sub>2</sub>O ile birlikte enerji açığa çıkarır ve bu enerji ile laktik asidin geri kalan kısmı tekrar glikojene dönüştürülür. Kasın aktif olarak kullanıldığı sırada üretilen enerjinin bir kısmı mekanik enerjiye (iskelet hareketleri) bir kısmı da ısı enerjisine dönüşür. Kasların verimi en fazla %25'tir. Yani üretilen enerjinin dörtte biri harekete dönüşüyorsa, en az dörtte üçü ısı enerjisi olarak kaybolmaktadır. Motor sinirlerin kas lifine ulaştığı noktaya motor uç plakaları denir. Motor sinirinden motor uç plakalarına bilgi geldiğinde asetilkolin (acetylcholine) salgılanarak kas uyarılır. Bazı düz kaslarda ise kimyasal haber ileticisi olarak noradrenaline kullanılır [38, 40].

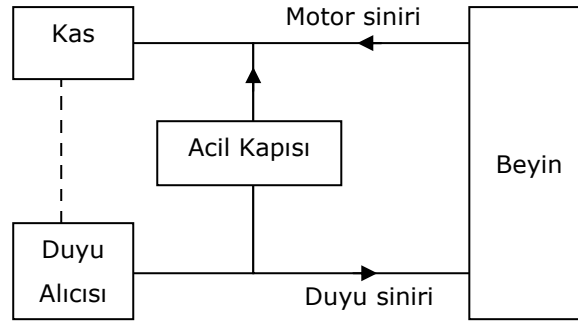
Vücudun farklı yerlerindeki kaslar için, motor ünitelerinin adetleri de farklıdır. Genel olarak kaslar ne kadar büyükse, motor üniteleri de o denli çoktur denebilir. Bunun yanında farklı kaslar için motor üniteleri de birbirinden farklıdır. İnsan vücudunda bir motor ünitesinde 25 ile 2000 arasında kas lifi bulunabilir [38, 40].

#### **2.4.3.3. Kaslarda servo-mekanizma ve motor hareketi**

Bir kas hareketinin düzgünlüğünü kontrol eden iki temel unsur vardır. Bunların birincisi uyarılan motor ünitelerinin sayısı ve ikincisi ise bu motor ünitelerinin

uyarılma hızıdır. Motor ünitelerini oluşturan motor sinirleri yapı olarak sinir hücrelerinden meydana gelmektedir.

Kas hareketlerini kontrol eden sinir sisteminin basit blok şeması Şekil 2.6 da verilmiştir.



Şekil 2.6. Kaslarda servomekanizma

Sistem, bir servomekanizma kontrol sistemidir. Duyu alıcısı, hız veya konum vb. ifade eden bir işaret üretir. Bu işaret duyu sinirleri vasıtası ile beyne iletilir. Beyin duyu sinirleri vasıtasıyla gelen bilgiyi hafızadaki bilgi ile karşılaştırır ve bir hata (Kontrol) işareti üretir. Üretilen bu işaret motor sinirleri ile kasa gönderilerek kas hareketinin kontrolü sağlanır. Örneğin insan parmağını sıcak olmayan bir cisme değdirdiğinde, parmakta bulunan duyu alıcıları sıcaklığı algılar ve duyu sinirleri ile beyne gönderir. Beyin bu işaretin normal sıcaklıktaki bir cisimden geldiğini anlar ve motor siniri ile kası harekete geçirmek üzere bir işaret göndermez. Eğer parmak sıcak bir cisme dokundurulmuşsa, beyin duyu sinirleri ile gelen bilgi sayesinde parmağın sıcak bir cisim üzerinde olduğunu anlar ve motor sinirleri ile kol kaslarına gerekli bilgiyi göndererek parmağın sıcak cisimden uzaklaştırılmasını sağlar. Duyu alıcılarının sıcak cismi hissetmeleri ile parmağın uzaklaştırılması arasında birkaç yüz ms'lik bir gecikme süresi vardır. Bu gecikme kişinin sıcak cisme gösterdiği ilgi ile de ilgilidir. (Eğer parmak çok sıcak bir cisme dokunmuşsa "acil kapısı" devreye girerek beyne ulaşmadan da kaçış emri verilebilir.) [40]

#### 2.4.3.4. Kasın kasılması sırasında oluşan gerilim

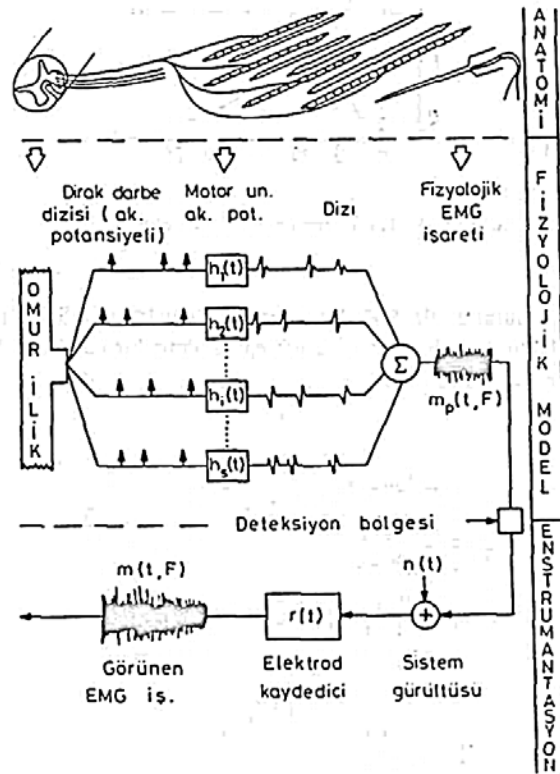
Bir duyu alıcısı uyarıldığı zaman, duyu sinir lifi boyunca yürüyen bir depolarizasyon dalgasını yani aksiyon potansiyelini oluşturur. Oluşan bu darbe dizisi beyne ulaşır. Bu işareti alan beyin, karşılık olarak motor uç plakalarının depolarizasyonuna neden olan uyarıyı, motor sinirleri boyunca yayınlanan aksiyon potansiyelleri şeklinde kasa gönderir. Motor uç plakalarının depolarizasyonu kas lifi içindeki hücreleri depolarize eder ve lifler kasılır.

Eğer ki az sayıdaki hücrenin (mesela bir motor ünitesi gibi) net potansiyel değişimi ölçülmek isteniyorsa bu ölçüm iğne elektrotlarla, bir çok motor ünitesinin oluşturduğu toplam potansiyel ölçülmek isteniyorsa ölçüm yüzey elektrotlarıyla yapılır. Bir mikroelettrot vasıtasıyla sadece bir hücreye ait ölçme yapıldığında hücrenin tüm faaliyetinin 1 ms'den kısa sürdüğü görülecektir. İğne elektrodun bir hücrenin yakınına yerleştirilmesi durumunda elektrot çevre hücrelerden gelen değişimleri de algılar. Aynı motor ünitesine bağlı kas lifleri, motor uç plakalarına bağlı sinir dalları vasıtasıyla yaklaşık aynı zamanda uyarılmasına rağmen, gerek hücrelerin depolarize durumda kalış sürelerindeki farklılıklar ve gerekse kas liflerine gelen sinir dallarının uzunluklarındaki farklılıklar sebebiyle bir motor ünitesinin değişim süreci 2-5 ms civarındadır. Bu asenkron durum, kas hareketinin düzgünlüğüne katkıda bulunur [38, 40].


Bir hastalık olması durumunda, aynı motor ünitesinden alınan EMG şekli sağlıklı hale göre farklılık gösterecektir. Periferik (çevresel) nöropatilerde (bkz. Bölüm 2.6.1), kasın kısmi olarak sinirsel uyarıyı alamaması durumu görülebilir. Sinirler kendilerini yenileyebilen dokulardır. Yani hastalıktan sonra bir düzelme olağandır. Kendini yenilemekte olan sinir liflerindeki iletim hızı, sağlıklı sinir liflerine oranla daha yavaştır. Bunun yanında bir çok periferik nöropatide nöronların uyarılabilirlik özelliği de değişebileceği için sinirsel iletim hızında genel bir yavaşlama görülür [39]. Bunun neticesinde de EMG şeklinde bir dağılma ortaya çıkar. Şekil 2.2 de eş merkezli (konsentrik) iğne elektrot kullanılarak, kas hücresinin uyarılması sonucu sağlıklı ve hastalıklı motor ünitelerinden elde edilen EMG işaretleri görülmektedir.

Şekil 2.7de EMG işaretinin alındığı anatomik yapı, bu yapıya ait fizyolojik model ve bu modelden EMG işaretinin algılanmasını sağlayan enstrümantasyon görülmektedir.

Kasa uyarının gelmesinden sonra kasın kasılmaya başlamasına kadar geçen zamana gecikme süresi denir (latent period). Gecikme zamanı Şekil 2.8'da gösterilmiştir. "T" sembolü, mekanik gerilmeyi göstermektedir [40].



Şekil 2.7. EMG işaretlerinin oluşumu ve yüzey elektroda ulaşması [40]



Şekil 2.8 Kasa uyarının gelişi ve kasın kasılması



#### 2.4.4. EMG neden istenir ve nasıl uygulanır

EMG ve sinir ileti incelemeleri sırasıyla omuriliğin ön boynuz hücreleri, sinir kökleri, sinir ağları, uç sinirler, sinir kas kavşağı ve kas hastalıklarının tanısını koymada kullanılan bir yöntemdir. Uygulanması kolay olması sebebiyle çoğu zaman tek başına veya bazen görüntüleme teknikleri, kan biyokimyası gibi diğer yardımcı yöntemlerle birlikte olası en kesin tanıya götürmek için kullanılmaktadır. Bazen de hekimi tanı için doğrudan biyopsi veya cerrahi müdahale gibi diğer yöntemlere yönlendirmektedir. Sıklıkla bel ve boyun fitıklarının, uç sinirlerin belli noktalarda sıkışmasının neden olduğu ağrılı durumlarda, his kusurlarında, nöropati ve miyopati gibi hastalıkların teşhisinde, kol ve bacak güçsüzlüklerinin görüldüğü bazı durumlarda, sınırlı veya yaygın kas erimelerinde sinir ve kasların ne kadar zarar gördüğünün ölçümünde kullanılır. Bazı durumlarda EMG işaretlerinden protez organların yönlendirilmesi ve hareketi için de faydalanılmaktadır [37].

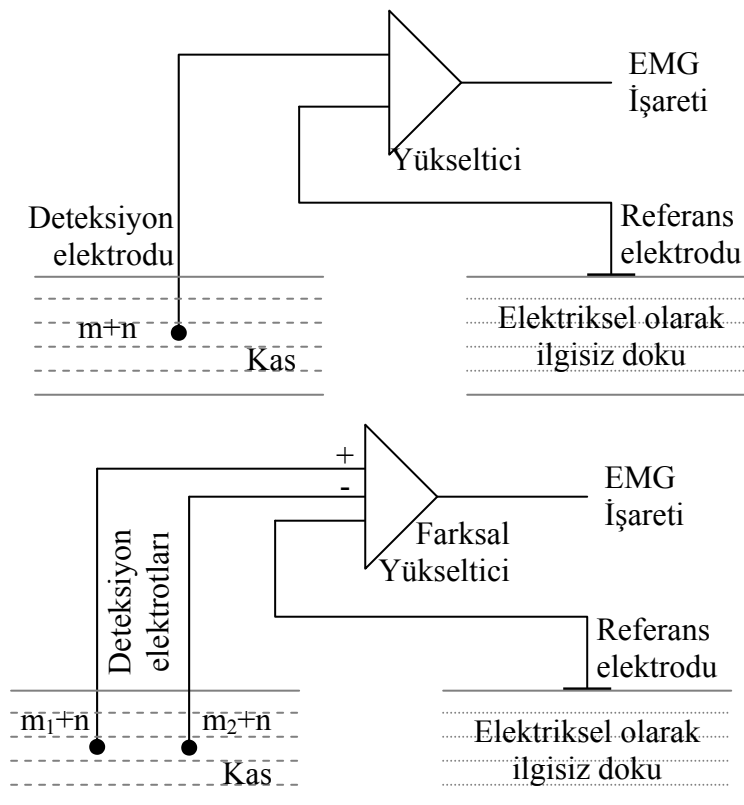
EMG işaretlerinin alınmasında iğne elektrotlar ve yüzey elektrotları olmak üzere iki tip elektrot kullanılmakla birlikte, kaslardaki sorunların tanısı için daha çok iğne elektrotlar tercih edilir. İğne elektrotlar ile yapılan EMG ölçümüne iğne EMG'si de denmektedir. Bu ölçümlerde genellikle konsantrik iğneler kullanılır [39].

İğne EMG incelemesinde genellikle herhangi bir elektriksel uyarı verilmez. Yalnız kaslarda normal veya anormal elektriksel aktivitenin kaydedilmesi için kullanılır. Araştırılan kasa iğnenin ucu direkt olarak yerleştirilir. İğne ucuna yakın olan kas bölgesinde o kasın kasılması için beyinden gönderilen uyarıların oluşturduğu MUP'lar veya diğer elektriksel aktiviteler hassas yükselticiler aracılığıyla büyütülürler ve cihazın ekranından izlenirler. Görsel incelemenin yanında aynı işaretler hoparlör sayesinde işitilir hale getirilir ve bu sesler incelemeyi yapan doktorun değerlendirmesine önemli katkılarda bulunur [36, 37].

EMG ölçümünde kullanılan elektrotlar ile ilgili daha fazla bilgi EK.B bölümünde verilmiştir.

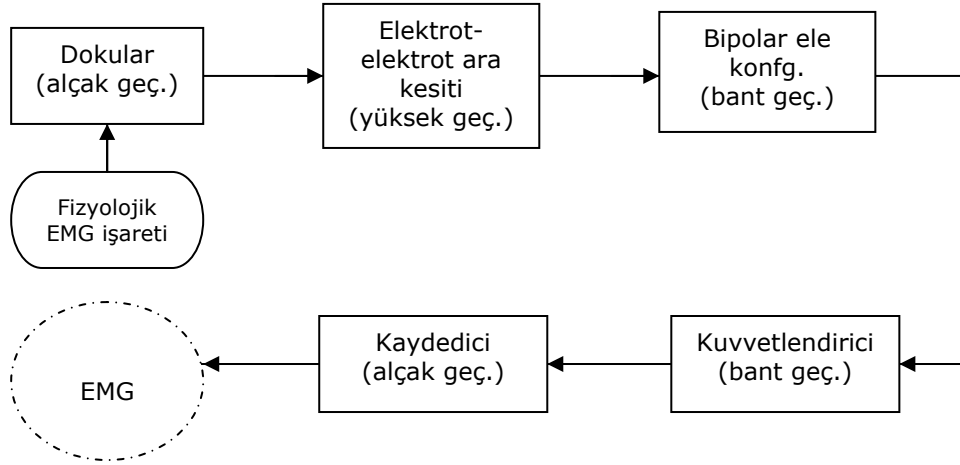
## 2.5. EMG İşaretlerini İnceleme Metodları

EMG işaretleri tek kutuplu (monopolar) ve çift kutuplu (bipolar) olarak alınabilir. Daha iyi sonuç vermesi sebebiyle bipolar mod daha sık tercih edilmektedir[40]. Şekil 2.9'da EMG işaretlerinin monopolar ve bipolar modda algılama yöntemleri verilmiştir.



Şekil 2.9. EMG işaretlerinin (a) monopolar ve (b) bipolar deteksiyonu

EMG işaretlerinin vücuttan alınıp görüntülenebilir hale kadar geçen safhasında çeşitli filtrelerin kullanıldığından daha önce bahsedilmişti (bkz. Bölüm 2.2). Şekil 2.10'da EMG işaretleri oluştuktan sonra görüntülenme aşamasına kadar işaret üzerindeki filtreleme işlemleri gösterilmiştir. Kuvvetlendiricinin bandı, yüzey elektrodu kullanılması halinde 20-500 Hz seçilmelidir. İğne ve tel elektrot kullanılması halinde ise kuvvetlendirici bandı 20-10000 Hz seçilmelidir. EMG işaretleri zaman ve frekans uzaylarında inceleyebilir [38].



Şekil 2.10. EMG işaretinin elektrotlara ulaşıncaya kadar karşılaştığı işlemler

EMG işaretlerinin frekans uzayında incelenmesinde en genel olarak Hızlı Fourier dönüşümü kullanılmaktadır. Bunun haricinde modern spektrum analiz yöntemleri de vardır ve bunlar ayrı bir bölüm olarak incelenecektir.

Bir EMG işaretini zaman uzayında incelemek için ise genel olarak aşağıdaki işlemler yapılır [40]:

**Doğrultma:** EMG işareti ilk işlem olarak doğrultulmalıdır. Üretilen enerjinin tamamının kullanılabilmesi amacıyla tam dalga doğrultma işlemi tercih edilir. Bu durumda doğrultulan işaret, orijinal işaretin mutlak değerini göstermektedir.

**Alçak geçiren filtreden geçirme:** Doğrultulmuş işarete var olan rasgele değişimlerin giderilmesi amacıyla, işaret analog veya sayısal bir alçak geçiren filtreden geçirilir. Diğer bir deyişle işarete smoothing (yumuşatma) işlemi uygulanmış olur.

**Ortalama alma:** Ortalama alma işlemi iki şekilde yapılabilir. Bunlardan birisi matematiksel ortalama olarak bilinen, değerlerin toplamının değer sayısına bölünmesidir. Bir diğer ortalama şekli ise hareketli ortalama (moving average) olarak tanımlanan ve zamanla değişen ortalama. Hareketli ortalama yumuşatma işleminin sayısal olarak yapılması olarak da tanımlanabilir. İşaretin rasgele değişen değerlerinin ortalamasını almak yoluyla, işarettaki büyük değişimleri yok etmek mümkündür.

İntegral alma: Aslen alçak frekansları filtrelemenin özel bir yolu olması sebebiyle alçak geçiren filtrelemeye benzeyen integral alma işlemi EMG işaretlerinde veri azaltmak için kullanılan yöntemler arasında en çok tercih edilenidir.

Etkin değerin ölçülmesi: Düzenli bir şekli olan işaretlerde (örn. kare dalga veya sinüs dalgası gibi) işaretlerin genlikleri kullanılarak etkin değerleri kolaylıkla hesaplanabilir. Ancak EMG işaretleri gibi rasgele değişen işaretlerde, işaretin genliği ile etkin değeri arasında bir bağıntı oluşturulamaz. Bu yüzden, EMG işaretlerinin gücünün belirlenebilmesi için etkin değerinin hesap yoluyla bulunması gerekir.

Sıfır geçişlerinin sayılması: Bu yöntemde, işaretin sıfır noktasından geçiş sayısı bulunur ve bu değer işaret hakkında bir bilgi verir. Sıfır noktası geçiş sayısı pozitif veya negatif alternansların sayılmasıyla da belirlenebilir. Düşük seviyeli kas kasılmalarında, sıfır geçiş sayısı ile Motor Ünitesi Aksiyon Potansiyeli dönüşleri arasında doğrusal bir ilişki vardır.

## **2.6. EMG ile Teşhis Konabilen Hastalıklar**

EMG bir tıbbi ölçüm sistemidir, ve diğer tıbbi ölçüm sistemleri gibi (EKG, EEG, EOG, MR, Ultrasound, Röntgen v.b.) hekimlerin işlerini kolaylaştırmak amacı ile kullanılmaktadır. Genel anlamda hekimlerin teşhis koymasında onlara yardımcı olur. Buradan da anlaşılacağı gibi, bazı hastalıkların teşhisinde, EMG ölçümleri gerekmektedir. Bu hastalıkların başında nöropati ve miyopati gelmektedir.

Bu iki hastalığın belirtileri birbirine çok benzer olabilmektedir. Örneğin ikisinde de hasta hastalıklı bölgedeki kaslarını hareket ettirememeye şikayetinde bulunmaktadır. Ancak hastalıklar birbirinden farklıdır. Nöropatide bu hareket bozukluğu kasa giden sinirlerin bozuk olmasından kaynaklanırken, miyopatide sinirler sağlamdır fakat kasta arıza olmasından dolayı hareket bozukluğu oluşmaktadır.

EMG ile bu iki hastalığın birbirinden nasıl ayrıldığı çok kabaca şu şekilde özetlenebilir: EMG ölçümü sırasında hareket bozukluğu olan kasa iki uçtan elektrik


akımı verilir. Bu akım sonrasında kasta kasılma oluşuyorsa, kasın kasılması için gerekli işareti taşıyan sinirler arızalıdır (nöropati), eğer bu akıma rağmen bir kasılma olmuyorsa, problem kastadır(myopati).

Nöropati ve Miyopati hastalıkları ile ilgili daha fazla bilgi EK.A bölümünde verilmiştir.

## 2.7. Myopati ve Nöropati Tanısında EMG' nin Rolü

Myopati ve nöropati hastalıklarının ayırt edilmesinde EMG en kullanışlı yardımcı testtir. Bu amaçla yapılan EMG, etkilenen kas içine uygulanan iğne elektrodlarla istirahat ve kasılma sırasında yapılır. Kaydedilen elektrik potansiyelleri ekranda grafik şeklinde gösterilir ve eş zamanlı olarak hoparlörden ses olarak işitilir [48].

İstirahat esnasında kas normalde elektriksel olarak sessizdir. Her türlü spontan aktivite patolojiktir. Gevşemiş bir kasa iğne elektrod sokulduğunda geçici olarak birkaç keskin pozitif dalga veya fibrilasyon görülebilir ancak bundan sonraki her aktivite anormaldir.

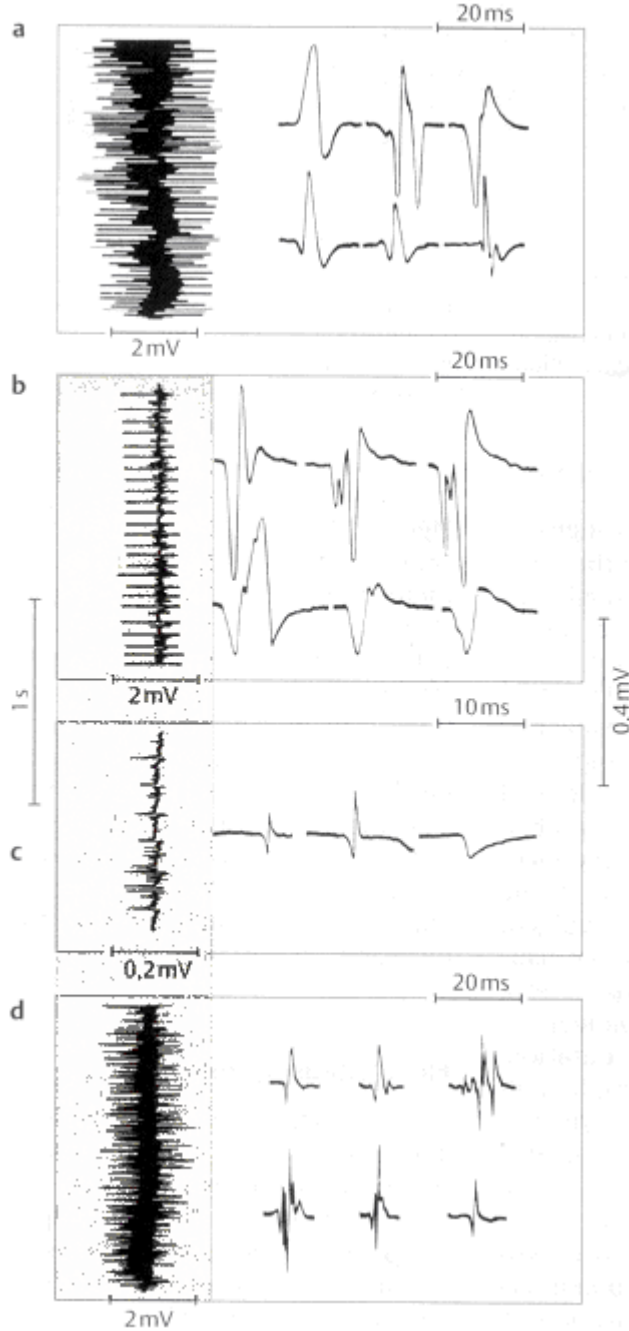


Şekil 2.11. Çeşitli şekillerin EMG potansiyelleri [48]

- Normal MUP
- Denervasyon sebebiyle oluşan fibrilasyon potansiyeli
- Denervasyon sebebiyle oluşan pozitif keskin dalga
- Reinervasyon'da görüldüğü gibi, düşük genliğin, parçalı-çok fazlı olma potansiyeli
- Kronikleşmiş boynuz oluşumundan (horn process) dolayı anormal olarak uzun süredir devam eden yüksek-genlik potansiyeli (dev-potansiyel)

Spontan aktivite: Spontan aktivite tipleri; fibrillasyon potansiyelleri, pozitif keskin dalgalar, fasikülasyonlar ve kompleks tekrarlayıcı deşarjlardır.

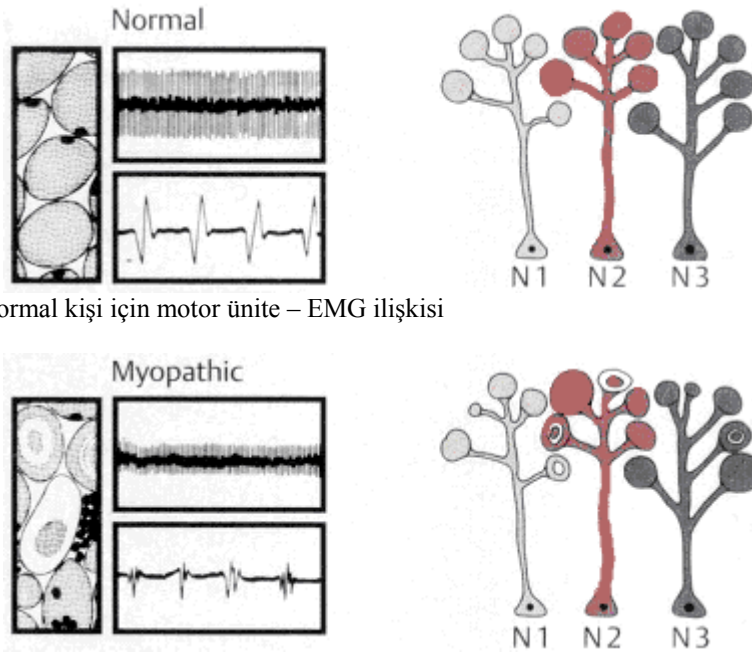
Motor Ünite: Kas kasılması –kasın gücüne ve kasılma gücüne göre değişen–değişken sayıda motor ünite tarafından oluşturulur. Tek bir ön boynuz hücresi tarafından innerve edilen bütün kas lifleri bir motor üniteyi oluşturur.



Şekil 2.12. Normal, Nörojenik ve Myopatik EMG işaretleri [48]


- Normal: Tam arayüz deseni
- Periferel bir sinir deformasyonu ertesindeki reinervasyon: kişisel sınımlar
- Toplam denervasyon: fibrilasyon potansiyelleri ve pozitif keskin dalgalar
- Myopati: güçsüzlüğe (zayıflığa) rağmen arayüz deseni tam. Durumu oluşturan herbir potansiyelin genliği düşük ve kısmen çok fazlı ve parçalı

Hafif kas kasılmasında tek tük potansiyeller görülebilir. Ama daha güçlü veya maksimal kasılmada bu potansiyeller “interferens patterni” (interferens: girişim/ karışım) oluşturmak üzere kaynaşır/ birleşirler. Tek bir motor üiteden elde edilen potansiyelin genlik ve şekli büyük ölçüde elektrot pozisyonunun fonksiyonudur. Normal genlikler genellikle birkaç yüz  $\mu\text{V}$  (mikrovolt) ile birkaç mV (milivolt) arasındadır ve genellikle bir motor üite potansiyeli 4 fazdan daha fazla değildir. Ortalama potansiyel süresinin uzaması, normalden daha yüksek genlik ve artmış sayıda polifazik potansiyel nörojenik süreç göstergeleridir. Ortalama potansiyel süresinin kısalması, normalden düşük genlik ve artmış sayıda polifazik potansiyel kas hastalığını (myopati) gösterir. Periferik sinir hasarı sonrası reinnervasyon (sinirin yeniden ileti yapması) geçici olarak kısa, düşük genlikli polifazik potansiyellerle gösterilebilir, zamanla normale döner.



Şekil 2.13-a Normal kişi için motor üite – EMG ilişkisi

Şekil 2.13-b Myopati hastası için motor üite – EMG ilişkisi



Şekil 2.13-c Nöropati hastası için motor ünite – EMG ilişkisi



### **BÖLÜM 3. SPEKTRUM KESTİRİM YÖNTEMLERİ**

Bir biyomedikal işarete herhangi bir analiz yöntemi uygulanacağı zaman, öncelikle işaret üzerindeki amaca uygun bölümler görsel olarak incelenmek suretiyle seçilir. Bu seçim sırasında gürültü olan kısımlar ve herhangi bir sebeple işaretin bozulduğu kısımlar seçime dahil edilmez. Hangi analiz yöntemi uygulanacaksa, buna uygun bölümler alınarak sınıflandırılır ve ilgili analiz yöntemi uygulanarak gerekli bilgiler elde edilir.

Spektrum kestiriminin başarılı olabilmesi için, gerekli bilgilerin doğru şekilde seçilmesi ve ayrıntılı olarak sunulması gerekir. Bu yüzden gerekli bilgilerin doğru seçilebilmesi için spektrum kestirimi hangi konuda yapılacaksa, bu alana uygun spektrum kestirim yöntemleri performans açısından kıyaslanmalı ve amaca en uygun yöntem bu şekilde belirlenerek kullanılmalıdır [40].

Spektrum kestirim yöntemleri parametrik ve parametrik olmayan spektrum kestirim yöntemleri olarak ikiye ayrılabiliriz[49, 50, 51]. Bazı kaynaklarda ise bu iki sınıfa ek olarak alt uzay yöntemleri de ayrı bir sınıf olarak verilmiştir. Bu çalışmada alt uzay yöntemlerine değinilmeyecektir. Parametrik olmayan yöntemler Fourier Dönüşümü ve Periodogram yöntemi olarak ikiye ayrılır. Parametrik olmayan yöntemler parametrik yöntemlere göre daha az işlem yükü gerektirirler. Ancak parametrik yöntemlerle kıyaslandıklarında spektrumun bozulması sonucu zayıf işaretlerin maskelenmesi gibi dezavantajları vardır. Fourier dönüşümünde, gözlem süresi kısa olan işaretlerde iyi bir frekans çözünürlüğü elde edilememektedir. Parametrik metodlarda ise performans daha iyi olmasına karşın, işlem yükü de aynı şekilde fazla olduğundan, daha fazla işlem zamanı ve daha güçlü bilgisayarlar gerektirmektedir. Biyomedikal işaretlerin spektrum kestiriminde parametrik metodlardan AR (AutoRegresivve) modelleme, parametrik olmayan metodlardan ise Hızlı Fourier Dönüşümü daha çok kullanılmaktadır [49, 51, 52].

İçinde bir çok bilgi taşıyan biyomedikal işaretlerin göz ile incelenmesi yetersiz kalabildiğinden, biyomedikal işaretlere spektrum kestirimi ile yaklaşılması, aynı işaretten daha çok ve daha net bilgi alınmasına imkan vermektedir [40].

EMG işaretleri biyomedikal işaretler içinde rasgele işaretler sınıfına girerler. EKG gibi işaretler periyodik olarak değişirken, EMG kas hareketine veya uyarıcı elektrottan gelen işarete bağlı olarak rasgele değişir. Rasgele işaretler incelenirken, işaretin kendisi değil de özilişki fonksiyonu ile işlem yapmak daha doğru bir yaklaşımdır. Rasgele işaretleri, her bir frekanstaki güç yoğunluğunu gösteren güç spektrumu ile incelenirler [40].

### 3.1. Parametrik Olmayan Spektrum Kestirim Yöntemleri

Bölüm 3'te parametrik olmayan spektrum kestiriminin Hızlı Fourier Dönüşümü ve Periodogram yöntemi olarak ikiye ayrıldığından bahsedilmişti. Bölüm 3.1'de bu iki yöntem incelenecektir.

#### 3.1.1. Hızlı fourier dönüşümü (HFD/FFT)

Hızlı Fourier Dönüşümü işaret içindeki frekans bileşenlerinin güç yoğunluğunu belirlemek için kullanılır. Temeli Fourier Dönüşümüne dayanmaktadır. Fourier Dönüşümü en basit anlatımı ile zaman uzayındaki bir ifadenin, frekans uzayına dönüştürülmesidir. Fourier tarafından bulunan bu dönüşüm ile, her işaret, farklı genlik, frekans ve faz değerlerine sahip sinüs işaretlerinin bileşimi şeklinde ifade edilebilir. Dolayısıyla her işaret Fourier serisi ile ifade edilebilir ve tersine, Fourier serisi bilinen her işaret tekrar türetilebilir. Hızlı Fourier Dönüşümü ise, Fourier Dönüşümünün hızlı bir şekilde yapılmasını sağlayan ve ilk olarak 1965 yılında Cooley ve Tukey tarafından ele alınan bir algoritmadır [53, 54, 55].

Ayrık zamanlı bir  $x_n$  işaretinin ayrık Fourier dönüşümü aşağıdaki gibi tanımlanır [50, 56].

$$X_k = \sum_{n=0}^{N-1} x_n e^{-\frac{2\pi j}{N}kn} \quad k = 0, 1, 2, \dots, N-1 \quad (3.1)$$

Bir işaretin Ayırık Fourier Dönüşümü (AFD), Fourier Dönüşümünün örnekleridir. Örneğin  $N=4$  için (3.1) denklemi kullanılarak 4 noktalı AFD hesaplanabilir. Örneğin daha yoğun bir örnekleme için,  $N=8$  alınabilir. Ancak zaman uzayında sadece 4 nokta vardır. Bu durumda işaretin sonuna “sıfır doldurma” (zero-padding) işlemi uygulanır. Dizinin sonuna sıfır eklemek ile yeni bir bilgi eklenmiş olmaz, ancak daha yoğun bir örnekleme yapılmış olur [52, 53].

Bu işaretin güç spektrumu 3.2 denklemi ile bulunur:

$$\hat{P}(f_k) = \frac{1}{N\Delta t} |X_k|^2 \quad \Delta t = \frac{1}{f_s} \quad (3.2)$$

Burada,  $\hat{}$  sembolü tahmini değeri,  $N$  işaretteki örnek sayısını,  $\Delta t$  örnekleme periyodunu ve  $f_s$  ise örnekleme frekansını göstermektedir.

### 3.1.2. Hızlı fourier dönüşümünün EMG uygulaması

Periyodik sayısal bir işaret, bir Fourier serisi ile temsil edilebilir veya bir dalga şekli Fourier katsayılarından yeniden oluşturulur. Fourier analizinin önemi şuradadır; tek frekans bileşenli bir işarete ait pek çok fiziksel sistemin cevabı, diğer frekans bileşenlerinin genliğinden ve görüntüsünden bağımsızdır. Böyle sistemler, giriş işaretinin büyüklüğündeki bir değişim çıkış işaretinde de aynı oranda değişim verdiği için doğrusal sistemler olarak bilinir. Bundan dolayı, örneğin, kas lifinde uyarma sonucu oluşan aksiyon potansiyeli ile bu kas lifinin kasılması potansiyeli arasındaki ilişki doğrusal ise ve verilen bir frekansta uyarılma-kasılma arasındaki ilişki biliniyorsa, üç basit adımda kompleks bir potansiyel değişiminden, bu potansiyellere ait genlik ve kasılma ile uyarılma arasındaki süre hesaplanabilir. İlk olarak potansiyel değişiminin Fourier katsayıları ayrılır; her frekanstaki genlik katsayıları, aynı frekanstaki potansiyel değişiminden hesaplanır, üçüncü olarak hesaplanan potansiyel değişim katsayıları tüm değişimin dalga şeklini vermesi için birbirleriyle toplanır.

Sonlu uzunlukta olan bir EMG işaretinin Hızlı Fourier Dönüşümünü almak için mevcut işaret, ikinin üstel katları şeklinde 64, 128, 256 gibi çerçevelenir. Her bir çerçeveye karşılık düşen frekans spektrumu bulunurken pencereleme yapılır. Pencereleme sayesinde, gerçekte olmayan frekans bileşenlerinin spektrumda ortaya çıkması önlenir [40].

### 3.1.3. Periodogram yöntemi

Parametrik olmayan spektrum kestirim yöntemlerinden bir diğeri olan Periodogram yöntemi, bir işarettaki frekans bileşenlerinin güç yoğunluğunu belirlemek için kullanılır. İlk defa 1898 yılında Schuster tarafından ortaya konan bu yöntem Temel olarak Hızlı Fourier Dönüşümüne dayanmaktadır. Bu yöntemin hesaplanması kolay olmakla birlikte, özellikle kısa data kayıtları için iyi sonuçlar vermektedir. Parametrik olmayan spektrum kestirim yöntemlerinin HFD ve periodogram haricinde, iyileştirilmiş periodogram yöntemi, Bartlett yöntemi, Welch yöntemi ve Blackman-Tukey yöntemi gibi alt kategorileri mevcuttur [49,51, 57].

Periodogram yöntemi ile güç spektral yoğunluğunu (GSY) elde etmek için, EMG gibi rastgele değişen işaretler 64, 128, 256 gibi ikinin üstel katları olacak şekilde pencerelenir[58].

Biyoelektrik işaretlerin spektral analizi için en uygun pencereler dikdörtgensel pencereler ve hanning pencereleridir[59].

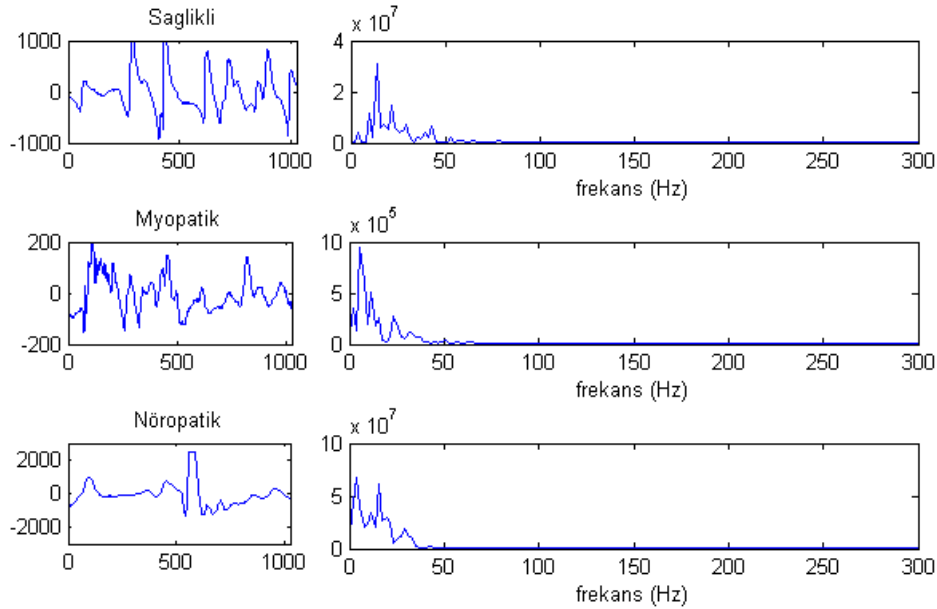
Fourier dönüşümünde konvolüsyon teoremini uyguladığımız zaman, periodogram

$$\hat{P}_{per}(e^{j\omega}) = \frac{1}{N} X_N(e^{j\omega}) X_N^*(e^{j\omega}) = \frac{1}{N} |X_N(e^{j\omega})|^2 \quad (3.3)$$

haline gelmektedir[49]. Burada  $X_N(e^{j\omega})$ ,  $N$  noktalı data dizisi  $x_N(n)$  için ayrık Fourier dönüşümüdür.

$$X_N(e^{j\omega}) = \sum_{n=-\infty}^{\infty} x_N(n) e^{-jn\omega} = \sum_{n=0}^{N-1} x(n) e^{-jn\omega} \quad (3.4)$$

Burada  $X_N(e^{j\omega})$  ayrık Fourier katsayısı, N mevcut veri uzunluğu ve x(n) ise zaman uzayındaki giriş işaretidir. Aşağıdaki şekillerde EMG işaretleri ve bu işaretlere ait frekans spektrumları verilmiştir.



Şekil 3.1. EMG işaretleri ve bu işaretlerin frekans spektrumları

### 3.1.4. Parametrik olmayan spektrum kestirim tekniklerinin incelenmesi

Parametrik olmayan spektrum kestirimlerinde, istatistiksel olarak güvenilebilecek bir spektrum kestirimi yapabilmek için, bir çok işleme ihtiyaç duyulur. Yeterli spektral ayrışımı sağlayabilmek, etkin bir genel tesir ortalaması almak ve yan lobların azaltılmasını sağlamak için eldeki verilerin frekans uzayında ortalaması alınır ve pencereleme işlemi yapılır. Fourier dönüşümüne dayalı olarak iki spektral tahmin tekniği geliştirilmiştir. Bunlardan birincisi Blackman ve Tukey tarafından yapılan, özilişki tahmini ile dolaylı yaklaşıma dayalı güç spektral yoğunluğu kestirimidir. Fourier dönüşümüne dayalı ikinci güç yoğunluk spektrum kestirimi ise periodogram metodudur. Eğer veri kümesi sınırlı ise, kestirimi yapılabilecek ayrık özilişki fonksiyonu değeri sayısı da sınırlı olacaktır [49, 50, 51].

Fourier Dönüşümüne dayalı yöntemler, spektrum kestirimi açısından yeterince iyi yöntemler değildir, çünkü bu yöntemlerin varyansları yüksektir ve ayrıca Fourier dönüşümü yönteminin frekans çözünürlüğü işaretin karakteristiğinden bağımsız olarak eldeki işaretin uzunluğu ile sınırlıdır. Bu olumsuzluklarla birlikte, pencerelemeden kaynaklanan bozulmuş spektrum kestirimi elde edilir. Fourier Dönüşümü yapısı gereği 10ms üzerindeki işaretlerde iyi bir spektral çözünürlük yakalayamaz. Bu nedenle bu süreyi aşan işaretlerde iyi bir çözünürlük yakalayabilmek için işaretin durağan (stabil) hale getirilmesi gerekir ki bu da aynı zamanda işaretin parametrik hale gelmesi demektir. HFD yönteminin bu dezavantajları nedeniyle AR yöntemi ve diğerleri gibi parametrik spektrum kestirim yöntemleri işaret analizinde önemli bir yer edinirler [49, 60].

### 3.2. Parametrik Spektrum Kestirim Yöntemleri

Parametrik olmayan güç spektrumu kestirim yöntemlerinin anlaşılması ve HFD ile hesaplanması parametrik yöntemlere göre daha kolaydır. Ancak uygun frekans çözünürlüğü için uzun veri kayıtlarına ihtiyaç göstermeleri ve Bölüm3.1.4'te bahsedilen diğer dezavantajları sebebiyle parametrik yöntemler daha çok tercih edilirler [52].

Parametrik yöntemler kullanılırken, güç spektrumu, işaretin tepe frekansı, band genişliği veya güç içeriği gibi bir dizi parametre ile özetlenebilir. Parametrik güç spektrum kestirimde, parametrik olmayan yöntemlerde var olan spektral kaçak problemi olmadığından, parametrik yöntemler ile daha iyi bir frekans çözünürlüğü elde edilir. Parametrik yöntemlerin diğer avantajları orijinal spektruma daha yakın bir sonuç vermesi ve daha kısa örnekleme süresine ihtiyaç duyması gösterilebilir.

Parametrik yöntemler kullanılırken, hangi parametrik yöntemin kullanılacağını belirleme aşamasında, işaretin yapısı da göz önüne alınmalıdır. Örneğin frekans spektrumunda ani tepeler olan işaretler için Özbağlanım (autoregressive, AR) modeli, keskin tepeleri bulunmayan işaretler için ise Yürüyen ortalama (moving average, MA) modeli uygundur. Özbağlanımlı yürüyen ortalama (autoregressive moving average, ARMA) modeli ise her iki tip işaret için de kullanılabilir. EMG

işaretleri ani tepeleri olan işaretler olduğundan, özbağlanım (AR) modeli veya özbağlanımlı yürüyen ortalama (ARMA) modeli EMG işaretlerinin incelenmesinde daha uygundur. AR yöntemi işlem yükü açısından, ARMA yöntemine nazaran daha avantajlıdır [50].

### 3.2.1. Özbağlanımlı (AR) spektrum kestirimi

Özbağlanım modeli,  $x(n)$  veri dizisinin bir rasyonel sistem tarafından nitelendirilen doğrusal bir sistemin çıkışı olarak modellenmesi ile temsil edilebilir. Güç spektral yoğunluğunun (GSY) parametrik yöntemlerle kestiriminde, veri dizisi ve kestirimi yapılan yönteme ait parametreler kullanılır. Özbağlanım metodunda işarete ait belli bir andaki genliği elde etmek için, o ana kadar örneklenmiş bölümlerin genlikleri farklı oranlarda toplanır ve bu toplama bir tahmin hatası eklenir.

AR model parametrelerinin çözümünde doğrusal denklemler kullanılır. Bu yüzden AR yöntemi daha yaygın kullanılır. Özbağlanım modeli, birim karşılıklı beyaz gürültü ile sürülen nedensel, tüm-kutuplu ayrık filtre çıkışı olarak gösterilir. “p” inci dereceden AR yöntemine ait güç spektrumu,

$$P_x(e^{j\omega}) = \frac{|b(0)|^2}{\left|1 + \sum_{k=1}^p a_p(k)e^{-jk\omega}\right|^2} \quad (3.6)$$

ifadesiyle verilir[49]. Eğer  $b(0)$  ve  $a_p(k)$  verilerden tahmin edilebilirse (kestirilebilirse) güç spektrumunun kestirimi şu formda da yazılabilir:

$$\hat{P}_{AR}(e^{j\omega}) = \frac{|\hat{b}(0)|^2}{\left|1 + \sum_{k=1}^p \hat{a}_p(k)e^{-jk\omega}\right|^2} \quad (3.7)$$

Burada  $a(k)$  AR katsayılarını,  $p$  model derecesini ve  $b(0)$  ise varyansı ifade etmektedir.

Açıkça görülebilir ki,  $\hat{P}_{AR}(e^{j\omega})$  ifadesinin kesinliği, model parametrelerinin

kestirimindeki kesinliğe, ve daha önemlisi AR modelinin üretilen veri ile birbirini tutup tutmadığına bağlıdır.

AR spektrum kestirimi, işlem için tüm-kutuplu model kurulmasını gerektirdiğinden, tüm kutup parametrelerinin kestirimi için teknikler vardır. Genlik oranlarını belirleyen AR katsayılarını farklı yöntemlerle hesaplamak mümkündür. Bunlara örnek olarak Levinson - Durbin ve Burg algoritmaları verilebilir. Burg yönteminde AR katsayılarını bulmak için işaretten alınan örneklerin ileri - geri hataları kullanılır ve modelin derecesi AR katsayılarının sayısı ile belirlenir. Levinson - Durbin yönteminde AR katsayılarının bulunması için Otokorolasyon denklemlerinin (bkz. Bölüm 3.3.3) çözülmesi gerekmektedir. Bunun için özilişki fonksiyonlarından faydalanılır [50, 51].

### 3.2.2. Özbağlanımlı (AR) spektrum kestirimi için Burg yöntemi

Burg yöntemi 1975 yılında J.P.Burg tarafından geliştirilmiştir[61]. Burg algoritması, AR model parametreleri kümesini, ileri – geri yöndeki kestirim hatalarının kareleri toplamının minimizasyonu ile bulur. Burg yöntemi diğer AR spektrum kestirim metodları gibi özilişki fonksiyonu hesaplamaz. Bunun yerine direkt yansıma katsayısı tahmini yapılır. Burg algoritmasında “p”inci dereceden model için ileri ve geri kestirim hataları şöyle tanımlanır: [49]

$$\hat{e}_{f,p}(n) = x(n) + \sum_{i=1}^p \hat{a}_{p,i} x(n-i) \dots \dots n = p+1, \dots, N \quad (3.8)$$

$$\hat{e}_{b,p}(n) = x(n-p) + \sum_{i=1}^p \hat{a}_{p,i}^* x(n-p+i) \dots \dots n = p+1, \dots, N \quad (3.9)$$

Yansıma katsayısı ( $\hat{k}_p$ ) ile ilişkili AR katsayıları (3.10) nolu ifadede verilmiştir.

$$\hat{a}_{p,i} = \begin{cases} \hat{a}_{p-1,i} + \hat{k}_p \hat{a}_{p-1,p-i}^*, & i=1, \dots, p-1 \\ \hat{k}_p, & i=p \end{cases} \quad (3.10)$$



Yansımaya katsayısı kestirimi için ise

$$\hat{k}_p = \frac{-2 \sum_{n=p+1}^N \hat{e}_{f,p-1}(n) \hat{e}_{b,p-1}^*(n-1)}{\sum_{n=p+1}^N [|\hat{e}_{f,p-1}(n)|^2 + |\hat{e}_{b,p-1}^*(n-1)|^2]} \quad (3.11)$$

ifadesi kullanılır. Daha önce belirtildiği gibi, Burg yönteminde AR katsayılarının bulunmasında kullanılan ileri ve geri yöndeki kestirim hataları ise şu ifadelerle bulunur:

$$\hat{e}_{f,p}(n) = \hat{e}_{f,p-1}(n) + \hat{k}_p \hat{e}_{b,p-1}(n-1). \quad (3.12)$$

$$\hat{e}_{b,p}(n) = \hat{e}_{b,p-1}(n-1) + \hat{k}_p^* \hat{e}_{f,p-1}(n). \quad (3.13)$$

AR parametrelerinin kestirimi yapıldıktan sonra güç spektral yoğunluğunun (GSY) hesaplanması için ise 3.14 nolu ifade kullanılır:

$$\hat{P}_{BURG}(f) = \frac{\hat{e}_p}{\left| 1 + \sum_{k=1}^p \hat{a}_p(k) e^{-j2\pi f k} \right|^2} \quad (3.14)$$

$\hat{e}_p$  ifadesi  $\hat{e}_{f,p} + \hat{e}_{b,p}$  toplamı olarak gösterilir ve toplam en küçük karesel hatadır. Parametre kestiriminde Burg yöntemi verimli ve kararlı bir AR yöntemidir [49, 50, 51].

### 3.2.3. Özbağlanımlı (AR) spektrum kestirimi için Otokorelasyon (Yule Walker) yöntemi

Otokorelasyon yöntemi bazı kaynaklarda Yule-Walker yöntemi olarak da geçmektedir[49]. AR işlemleri için kullanılan Yule-Walker denklemlerinin, otokorelasyon denklemleri ile eşdeğer olması sebebiyle her iki ismin de kullanılması uygundur.

Bu yöntemde AR katsayıları  $a_p(k)$ , normal otokorelasyon denklemleri çözülerek bulunur:

$$\begin{bmatrix} r_x(0) & r_x^*(1) & r_x^*(2) & \cdots & r_x^*(p) \\ r_x(1) & r_x(0) & r_x^*(1) & \cdots & r_x^*(p-1) \\ r_x(2) & r_x(1) & r_x(0) & \cdots & r_x^*(p-2) \\ \vdots & \vdots & \vdots & & \vdots \\ r_x(p) & r_x(p-1) & r_x(p-2) & \cdots & r_x(0) \end{bmatrix} \begin{bmatrix} 1 \\ a_p(1) \\ a_p(2) \\ \vdots \\ a_p(p) \end{bmatrix} = \epsilon_p \begin{bmatrix} 1 \\ 0 \\ 0 \\ \vdots \\ 0 \end{bmatrix} \quad (3.15)$$

Burada,

$$r_x(k) = \frac{1}{N} \sum_{n=0}^{N-1-k} x(n+k)x^*(n); k=0,1,\dots,p \quad (3.16)$$

3.15 eşitliği  $a_p(k)$  katsayıları için çözümlenip, yerine konursa,

$$|b(0)|^2 = \epsilon_p = r_x(0) + \sum_{k=1}^p a_p(k)r_x^*(k) \quad (3.17)$$

elde edilir.

Bu parametrelerin 3.7 nolu eşitliğe dahil edilmesiyle, güç spektrumu için tahmin üretilmiş olur [49].

### 3.2.4. Özbağlanımlı (AR) spektrum kestirimi için Kovaryans yöntemi

AR parametrelerinin kestirimi için bir başka yaklaşım ise Kovaryans yöntemidir. Kovaryans yöntemi AR spektrum kestiriminde ileri kestirim hatalarının kareleri toplamının minimize edilmesi temeli üzerine kuruludur. Bu yöntem, bir dizi doğrusal denklemin çözümünü gerektirir:

$$\begin{bmatrix} r_x(1,1) & r_x(2,1) & \cdots & r_x(p,1) \\ r_x(1,2) & r_x(2,2) & \cdots & r_x(p,2) \\ \vdots & \vdots & & \vdots \\ r_x(1,p) & r_x(2,p) & \cdots & r_x(p,p) \end{bmatrix} \begin{bmatrix} a_p(1) \\ a_p(2) \\ \vdots \\ a_p(p) \end{bmatrix} = - \begin{bmatrix} r_x(0,1) \\ r_x(1,2) \\ \vdots \\ r_x(1,p) \end{bmatrix} \quad (3.18)$$

burada

$$r_x(k,l) = \sum_{n=p}^{N-1} x(n-l)x^*(n-k) \quad (3.19)$$


şeklinde verilmektedir.

Otokorelasyon yöntemindeki doğrusal yöntemlerden farklı olarak, burada verilen matrisler, Toeplitz matris değildir. Bununla beraber, kovaryans yönteminin, otokorelasyon yöntemine göre avantajı, otokorelasyon kestiriminde gerekli olan verilerin pencerelemesi işlemini gerektirmemesidir. Bu yüzden, kısa veri kayıtlarında kovaryans yöntemi, otokorelasyon yöntemine göre daha yüksek çözünürlükte spektrum kestirimi üretir. Ancak veri kayıtları uzadıkça, iki yöntem arasındaki fark da ihmal edilebilir ölçülere gelmektedir [49, 51, 52].

### 3.2.5. Özbağlanımlı (AR) spektrum kestirimi için iyileştirilmiş Kovaryans yöntemi

Bu yöntem verilerin pencerelemesini gerektirmemesi açısından kovaryans yöntemine benzer. Kovaryans yönteminden farklı olarak, ileri kestirim hatalarının kareleri toplamının minimize edilmesi yerine, iyileştirilmiş kovaryans yöntemi ileri ve geri kestirim hatalarının kareleri toplamını minimize eder. Bu sebeple bazı kaynaklarda bu yöntem “ileri-geri yöntemi” veya “en küçük kareler yöntemi” olarak da geçmektedir[49]. Sonuç olarak kovaryans yönteminde kullanılan 3.18 nolu ifade burada da aynen geçerli olmakla birlikte, bu yöntemde 3.19 ifadesi yerine aşağıdaki ifade kullanılır:

$$r_x(k, l) = \sum_{n=p}^{N-1} [x(n-l)x^*(n-k) + x(n-p+l)x^*(n-p+k)] \quad (3.20)$$



Şekil 3.2. Miyopati hastası için kovaryans ve i. kovaryans Spektral Güç Yoğunluğu

Birbirlerine oldukça yakın sonuç veren kovaryans ve iyileştirilmiş kovaryans yöntemleri kullanılarak elde edilen spektrumlara örnek grafikler, miyopati hastası bir denek için Şekil 3.2 de verilmiştir.

### 3.3. Modern Spektral Analiz Yöntemlerinin EMG Uygulaması

Spektral hesaplama yapılırken, kullanılacak modelleme tekniği, seçilecek modelin uygunluğu ve parametre kestiriminde isabet oranının yüksekliği önemlidir. Kestirimi yapılan parametreler kullanılarak söz konusu işaretin güç yoğunluk fonksiyonu bulunur. Kullanılacak modeller AR (Autoregressive), MA (Moving Average) ve ARMA (Autoregressive Moving Average) gibi zaman serisine uygulanan modellerdir. Bir zaman serisinin en uygun şekilde modellenmesi, en düşük sayıda parametre içeren modeli kullanmakla mümkündür. Örneğin AR modeli, EMG işaretine ait frekans spektrumunda ani tepelere sahip olan EMG işaretlerinin zaman serileri için daha uygundur. MA modeli ise derin çukurlara sahip fakat keskin tepeleri olmayan dar aralıklı frekans cevaplarının zaman serileri için daha uygundur. ARMA modeli ise her ikisi durum için de işe yarar sonuçlar vermektedir [49, 50].

Modern spektral analiz yöntemleri ile modelleme yapılırken dikkat edilmesi gereken bir diğer önemli nokta ise iyi sonuç verecek optimum model derecesini belirleme işidir. Model derecesi modeldeki parametre sayısını belirler ve öz ilişki ile kısmi öz ilişki fonksiyonlarının kesim noktaları ile bulunur. Model derecesinin doğru belirlenmemesi hata oranının yüksek çıkmasına, bu da frekans spektrumunun hatalı olmasına yol açar. Hatalı bir spektrumda olmayan tepeler varmış gibi görülebilir veya tersine olan tepeler kaybedilebilir [49, 50].

#### 3.3.1. Model parametrelerinin hesaplanması

Ani tepeleri olan işaretler için AR model parametreleri daha uygun olurken, ani tepeleri olmayan işaretlerde MA model parametrelerinin daha uygun olduğu bir önceki bölümde belirtilmişti.

EMG işaretlerinde her iki durum da karşılaşılan haller olduğundan, genel olarak EMG işaretlerinde en iyi spektral çözünürlük açısından ARMA modeli en uygun

yöntem olarak görülmüştür[50]. ARMA modeli kullanılarak zaman serilerinin doğrusal modeli daha az sayıda parametreye ihtiyaç duyularak elde edilebilir. Kaydedilen EMG işaretlerinin ARMA parametreleri hesaplanırken AR katsayılarına MA katsayıları eklenir[50].

Parametre hesabı sırasında her aşamada ileri ve geri yöndeki hata alanları yeniden hesap edilerek hata giderek azaltılır ve parametre hesabında yakınsaklık elde edilir [49].

### 3.3.2. EMG işaretlerinin özbağlanım (AR) ile modellenmesi

AR yöntemi, EMG işaretlerinin beyaz gürültü tarafından yönlendirilmiş lineer filtrenin çıktısı olarak modellenmesidir. Bu filtreye AR denir. AR, çıktının kendisiyle (auto) önceki örneklerin (regressive) bir lineer kombinasyonudur.

Sabit olmayan içerikli, AR karmaşık sürecinin klasik denklemi Burg yöntemi için daha önce 3.8 ifadesi ile verilmişti. Bu ifadenin biraz düzenlenmesiyle, aşağıdaki denklem elde edilir.

$$x(n) = - \sum_{i=1}^p \hat{a}_{p,i} x(n-i) + e(n) \quad (3.21)$$

Burada  $a_i(n)$  AR nin karmaşık parametreleri,  $p$  AR nin model derecesi,  $e(n)$  beyaz karmaşık gürültü ve  $n$  ise örnek zamandır. Spektrum kestirim aşamasının AR modelleme ile yapılmasında yer alan ana adımlar aşağıdaki gibidir:

- en uygun modelin belirlenmesi
- AR parametrelerinin kestirimi
- Yukarıda belirtilen parametreler kullanılarak güç spektral yoğunluğunun kestirimi.


AR modelinin sıralanması tüm prosedür içerisinde en önemli parçadır. Çünkü bir modelin sıralamasının çok düşük olması, asıl spektrumun spektrum çizgilerini yumuşatır ve sıralamanın çok yüksek olması ise asıl güç spektrumuna aslında olmaması gereken sahte tepeler eklemektedir. Model sıralamasının belirlenmesinde

en sık kullanılan metot Akaike bilgi kriteri (AIC) dir [62]. Bu kıstas, bilginin teorik olarak minimize edilmesine dayanmaktadır[51, 60, 26]. N veri noktalı sıralı AR parametrelerinin yargılanmasında en sık kullanılan metot Burg algoritmasıdır[51, 63, 64]. Bu algoritmaya göre, AR parametreleri, en küçük karelerin daha da küçültülmesiyle bulunmaktadır. İşaretlerin genlik değerlerinin sıfır Gauss dağılımında olması halinde bu model istatistik açıdan kesin sonuçlar vermektedir. Ancak işaretlerin dağılımlarının belli bir düzende olmaması halinde de oldukça iyi yaklaşık sonuçlar vermektedir. Model, veri dizisini sabit olarak kabul eder. Yani birinci ve ikinci sıradaki dizinin sırası  $x(n)$  zamana bağlı olarak değişmez. AR (özbağlanım) modellemesini temel alan spektrum kestirim metodu spektral “sızıntı” olmaksızın daha iyi sonuçlar vermektedir [65, 66].


Bu parametrelerin kestirimi problemi, eşitlik setlerinin oluşturulması ve çözünürlüğünü kapsamaktadır. Bu da kolaylıkla çözümlenebilmektedir. Verilerin AR spektrali ile kestiriminde sıra değeri olan  $p$  aşağıdaki eşitlik ile bulunmaktadır [67].

$$P(f) = \frac{\sigma p^2 \Delta t}{\left| 1 + \sum_{i=1}^p a_{pi} e^{-j2\pi fi \Delta t} \right|^2} \quad (3.22)$$


Formülde  $a_{p0}=1$ 'dir. Bu sebeple EMG işaretlerinin spektral güç yoğunluklarının yargılanması sadece  $p$  sayısının  $a_{pi}$  parametrelerinin olmasıyla ve genlik oranlarını tanımlayan beyaz gürültü varyantları olan ve yeterli AR katsayıları olan  $\sigma p^2$  parametreleriyle mümkün olmaktadır. Şekil 3.2'de normal EMG işaretlerinin AR Burg spektrumu görülmektedir. Şekil 3.3'de Miyopatik EMG işaretlerinin AR Burg spektrumu, Şekil 3.4'de ise Nöropatik EMG işaretlerinin AR Burg spektrumu görüntülenmektedir.



Şekil 3.3. Sağlıklı kişiye ait EMG işareti için AR-Burg spektrumu



Şekil 3.4. Miyopatik kişiye ait EMG işareti için AR-Burg spektrumu



Şekil 3.5. Nörojenik kişiye ait EMG işareti için AR-Burg spektrumu

### 3.4. Özellik Çıkarımı ve EMG

Özellik çıkarımı (Feature Extraction) metodu ve verilerden çıkarılan bu özelliklerin kullanımı biyomedikal verilerin incelenmesinde başvurulan bir yöntemdir.

EKG gibi bazı biyomedikal işaretler periyodik ve şekli belli bir çıktı verirken, EMG gibi işaretlerde ise tam belli bir şekil veya periyodik tekrar eden formlar yoktur. Bu tip işaretlere rastgele işaretler denir, ve bunların incelenmesinde istatistiksel hesaplamalar da söz konusu olmaktadır [40].

İstatistiksel hesaplamalarda daha çok ortalama değer ve varyans kullanılmaktadır. Varyans kısaca “beklenen değerden sapma” olarak tanımlanabilir. Varyans ne kadar küçükse, sonuç da o kadar güvenilir olmaktadır. Örnek sayısı arttıkça, varyans düşer [40].

Özellikle zamanla düzensiz değişen işaretler olmak üzere, biyomedikal işaretler üzerinde istatistiksel incelemeler yapılmakta ve kullanılmaktadır. Ancak bu tip incelemeler bir sınıflandırma amacından daha çok, belli kurallar koyabilme veya bazı



değişkenlerin etkilerini inceleyebilmek için yapılmaktadır. Örneğin deneklerin belli bir uyarıcıya karşı tepki süreleri ölçülür. Bu ölçümler aynı denek için bir çok kez tekrarlanır. Daha sonra elde edilen verilerle oluşturulan veritabanında istatistiksel incelemelerle deneğe ait ortalama tepki süresi, standart sapması gibi bilgiler elde edilir. Sonrasında örneğin bir ilaç verilerek denek bu ilacı aldıktan sonraki tepki süreleri ölçülür ve bunların değerlendirilmesi de yine istatistiksel incelemelerle yapılır. Aynı şekilde başka deneklerle yapılan çalışmalardan elde edilen verilerle belli kurallar koymak mümkündür.

Sınıflandırma amaçlı ve yapay zeka ile birlikte uygulanan istatistiksel incelemelerde ise, basit istatistiksel özellikler yerine daha karmaşık ve hesap yükü ağır istatistiksel incelemeler söz konusudur [15]. Ayrıca bu tip çalışmalarda sadece elde edilen sayısal veriler değil, genellikle hastanın hikayesi, ailenin medikal geçmişi gibi bilgilerle birlikte değerlendirme yapılır [1]. Yapay zeka ile özellik çıkarımının beraber kullanımında özellik çıkartmanın önemli taraflarından biri de sınıflandırma evresinde kullanışlı olabilecek tüm olası değişkenlerin sıralanmasıdır. Eğer önemsiz olarak tanımlanmış özellikler de öğrenime dahil edilmişse, öğrenme aşamasında bunların ağırlıkları sıfıra yaklaşacaktır. Bu durumda gereksiz fazla veriyi (özellikleri) işleme dahil etmemek daha uygundur [1].

### **3.4.1. Yeni bir yaklaşım**

EMG işaretlerinin sınıflandırılması probleminde şimdiye kadar bir çok yöntem denenmiş ve çeşitli oranlarda başarılar elde edilmiştir [15, 27, 28, 29, 31, 32, 33, 34, 68,69]. Bu yöntemler özellikle dalgacık analizi ve yapay sinir ağları üzerinde yoğunlaşmıştır [15, 27, 28, 29, 32, 33]. Bu tez çalışmasında da uygulaması yapılan spektrum analizi ve yapay sinir ağları yöntemi de, az da olsa uygulanan yöntemlerdendir [32]. Bir çalışmada [33], dalgacık değerlerine ilişkin belirleyici özelliklerin kullanılmasına karşın, EMG datalarına ait belirleyici özellikler kullanılmamıştır.

Elektromiyogram işaretlerinin analizi, frekans uzayında ve zaman uzayında olmak üzere iki ana başlık altında toplanmıştır [38]. Bu analiz yöntemlerine Bölüm 2' de

değnilmiş, ayrıca bu bölümde modern spektrum analiz yöntemleri ayrıntılı olarak anlatılmıştır. 3.3.2 numaralı kısımda anlatılan çalışma da yine EMG işaretlerinin frekans uzayında analizi ile ilgilidir. Hızlı Fourier Dönüşümleri de frekans uzayında yapılan analizlere sıkça kullanılan başka bir örnektir. EMG işaretlerinde frekansa bağlı bu incelemeler haricinde, zamana bağlı incelemeler de yapılmaktadır. Zamana bağlı analizde, EMG işareti önce doğrultulmakta ve daha sonra doğrultulmuş bu işaret üzerinde alçak geçiren filtreleme, ortalama alma, entegrasyon, etkin değerinin ölçülmesi ve sıfır geçiş ve dönüşlerinin sayılması gibi işlemler uygulanmaktadır [40]. Bu işlemlerle ilgili açıklamalar Bölüm 2.4'te yapılmıştı. Ancak zaman uzayında yapılan bu işlemleri, yapay zeka teknikleri ile birlikte kullanan bir çalışmalar yaygın değildir. Bu çalışmada ortaya konan yeni yaklaşım, zaman uzayında yapılan incelemelerde kullanılan değerleri hesaplamak, bunlara işaretin belirleyici özelliklerini ortaya koyan yeni değerler katmak ve elde edilen bu değerler kümesini yapay zeka teknikleri ile EMG işaretlerinin sınıflandırılmasında kullanmaktır.

EMG işaretlerinin belirleyici özellikleri çıkartılırken, en fazla bilgi veren değer, sıfır geçiş sayısı olmuştur. Sıfır geçişlerinin sayılması yöntemi, zaman uzayında analizlerde kullanıldığı gibi, frekans uzayındaki analizlerde de kullanılmaktadır [40]. (Frekans uzayında ayrıca işaretin frekans ortalaması, medyan frekansı ve modu gibi bilgiler de kullanılabilir.)

EMG işaretlerinin analizinde genel olarak frekans uzayında incelemelerin tercih edilmesi yanında, Jiang ve arkadaşları tarafından yapılan bir çalışmada [33], EMG işaretlerinin sınıflandırılmasında işaretin dalgacık analizine ilişkin maksimum değer, minimum değer, ortalama değer ve mutlak değer gibi bilgiler kullanılmıştır. Ancak dalgacık değerlerinin maksimum, minimum, ortalama ve mutlaklığını gösteren bu değerler, doğrudan EMG işaretinden hesaplanan değerlerden elbette ki farklıdır.

Tüm bu bilgilerle birlikte, nörologlarla yapılan görüşmelerde, pratikte bir işaretin değerlendirilmesinde özellikle genlik ve frekans gibi bilgilerin ayırt edici olarak kullanıldığı öğrenilmiştir. İşaretin minimum ve maksimum değerleri, genliği ile doğrudan alakalı olduğu gibi, sıfır geçiş sayısı da işaretin frekansı ile ilgilidir.

EMG işaretlerinde, işarete ait sayısal değerlerden elde edilen belirleyici özelliklere ait değerler tek başlarına uzman elinde sınıflandırmaya yardımcı olurken, pekala yapay zeka yöntemleri ile de sınıflandırma yapılırken başarılı sonuçlar vermesi beklenebilir. Bu noktadan hareketle, bu çalışmada öncelikle EMG işaretlerine ait çeşitli özellik değerleri çıkartılmış, bu özellik değerleri ayrı ayrı ve beraber değerlendirmelerle amaca uygun özellikler belirlenmiştir. Eğitim verilerine ait belirleyici özellikler tespit edilip, bunlara ait değerler hesaplandıktan sonra, yapay sinir ağı bu değerler ile eğitime tabi tutulmuştur. Sonrasında test verileri için aynı değerler hesaplanmış ve eğitilen ağ bu verilerle test edilerek sistemin başarı performansı hesaplanmıştır. Tüm bu uygulamalar sonunda, ortaya konan yeni yaklaşımın önceki çalışmalarda izlenen yöntemlerle kıyaslandığında daha hızlı ve daha başarılı sonuç verdiği gözlemlenmiştir

### 3.4.2. Belirleyici özelliklerin seçilmesi

Öncelikle mevcut EMG verilerine ait çeşitli belirleyici özelliklerin değerleri hesaplanmıştır. Hesaplanan değerler, ortalama değer, karesel ortalama, sıfır geçiş sayısı, maksimum değer, minimum değer, standart sapma, medyan (sıralanmış dizinin orta elemanı), varyans ve moddur. Bu değerlerin tümü bir arada değerlendirilmiş, sonra kısım kısım bazıları çıkartılarak denemeler devam ettirilmiştir. Bu şekilde yapılan değerlendirmeler sonucunda, varyans ve mod değerlerinin sonuca pek etki etmedikleri görülmüştür. Diğer yedi değer ise, sistemin başarı performansını etkilemektedir. Bu işlem yapılarak her denek için 1024 adet değerden oluşan veri yerine, sadece 7 değerden oluşan bir veri elde edilir ve yapay sinir ağının eğitiminde ve testinde ilgili verilere ait bu değerler kullanılır. Böylece hem hesap olarak çok daha basit ve anlaşılır işlemlerle uğraşmakta, hem de büyük veri kümeleri göz önüne alındığında işlem yükü ve performans açısından daha verimli bir çalışma yapılmış olmaktadır. Bir deneğe ait verinin  $n$  adet değerden oluştuğu kabul edilirse, ilgili veriye ait özellik değerlerinin nasıl hesaplanacağı Tablo 3.1 de verilmiştir.

Tablo 3.1.  $n$  adet sayısal değerden oluşan veri için belirleyici özellikleri veren ifadeler

Özellik	İfade
Ortalama	$\frac{x_1 + x_2 + \dots + x_n}{n}$
Karesel Ortalama	$\sqrt{\frac{x_1^2 + x_2^2 + \dots + x_n^2}{n}}$
Sıfır geçiş sayısı	Veriyi oluşturan değerler içinde işaretin değiştiği noktaların sayısıdır. Hassasiyet ayarı yapmak gerekebilir.
Maksimum değer	$n$ adet değer içinde en yüksek değerlikli olanın değeridir.
Minimum değer	$n$ adet değer içinde en düşük değerlikli olanın değeridir.
Standart sapma	$\sqrt{\frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n - 1}}$
Medyan	Değerler büyüklük sırasına dizildiğinde, ortada kalan elemanın değeri
Varyans	Standart sapmanın karesidir
Mod	Değer dizisi içinde en çok tekrarlanan değer

Ortalama olarak alınan değer, veriyi oluşturan sayısal değerlerin aritmetik ortalamasıdır ve tüm değerlerin toplanarak eleman sayısına bölünmesi ile bulunur [70, 71]. Ortalama değer bize işaretin hangi bölgeye kaydığını, daha çok hangi bölgede değerler verdiğini gösterir.

Karesel ortalama ise değerlerin kareleri toplamının, değer sayısına bölümünün karekökünün alınması ile elde edilir [70]. Bir EMG işareti için veriyi oluşturan değerler, işaretin genlik değerleridir. Bu durumda sıfır eksenine göre simetrik giden işaretlerin aritmetik ortalaması, değerlerin işareti sebebiyle sıfıra yakın bir değer alır. Ayrıca genlik sıfır ekseninin iki tarafında birden büyük tepeler yapsa da, bunu ortalama değerden anlayabilmek mümkün değildir. Karesel ortalama ise veriyi oluşturan değerlerin kareleri alındığından, bir nevi tüm işaret pozitif alternansa taşınmış olur. Karesel ortalama bize veriyi oluşturan değerlerin hangi seviyede seyrettiğini vermesi açısından önemlidir.

Sıfır geçiş sayısı, işaretin sıfır ekseninden geçişlerinin sayılması ile elde edilir. Bu değer işaretin frekansı ile ilgili olarak bir yaklaşım yapılabilmesini sağlar. Sıfır geçiş

sayısı daha büyük olan işaret artı – eksi yönde daha fazla değişim göstermiş demektir. Sıfır geçişleri sayılırken teorik olarak veriyi oluşturan değer dizisinde değerlerin her polarite değiştirmesi +1 sayılarak sıfır geçiş sayısı bulunur. Ancak bu şekilde yapılan bir hesapta, sıfır noktası civarında oluşan bir parazit sıfır geçiş sayısını anormal büyüttüğünden bir hassasiyet ayarı yapmak gerekmektedir. Bu ayar, işaretin değiştiği noktada, iki değer arasındaki fark belli bir büyüklüğe ulaşmadan tekrar işaret değişiyorsa, bu değişimi saymamak şeklinde özetlenebilir.

Maksimum değer, veriyi oluşturan sayısal değerler dizisi içindeki en büyük değerlikli elemandır. Minimum değer de benzer şekilde negatif yönde en büyük değerlikli elemanı verir. Aritmetik ortalama işaretin hangi bölge yoğunluklu olduğunu, karesel ortalama ise işaretin genlik ortalamasını veriyordu. Buna karşılık maksimum ve minimum değerler, artı ve eksi yönlerde denekten alınan en büyük değerleri gösterirler. Bu da bir nevi işaretin genlik sınırı olarak kabul edilebilir.

Standart sapma, veriyi oluşturan değerler dizisindeki değerlerin, o diziyeye ait ortalama etrafındaki yoğunluklarını gösterir. Her değer için ayrı ayrı aritmetik ortalama ile farkları alınır. Bu farkların kareleri alınarak toplanır ve dizideki eleman sayısına bölünür. Çıkan bu değer varyanstır. Bu değer için karekökü ise standart sapmayı verir [70, 71].

Medyan, veriyi oluşturan değerler büyüklük sırasına dizildiklerinde, başa ve sona eşit uzaklıkta olan elemandır [70, 71]. Dizideki eleman sayısı çift ise, bu durumda başa ve sona eşit mesafede iki eleman olur, bu durumda medyan bu ikisinin ortalamasıdır. Dizi içinde bazı uç değerler varsa, medyan ortalamaya göre daha anlamlı bilgi verebilmektedir. Örneğin 5, 7, 8, 10, 13, 13, 16, 20, 52 dizisinin ortalaması 16 iken, medyan değeri 13'tür ve ortalamanın dizideki 52 elemanından kaynaklanan yükselmesi karşısında ortalamaya göre dizinin genel ağırlığı hakkında daha sağlıklı bir sonuç vermektedir.

Varyans standart sapma konusundan da anlaşılacağı gibi, standart sapmanın karesidir. Standart sapma ile aynı bilgiyi verdikleri için yapay sinir ağı eğitimine sokulan değerler içine dahil edilmemişlerdir.

Mod ise biz dizide en çok tekrarlanan elemandır [71]. Ancak bir EMG verisi içinde mod bilgisi bir anlam ifade etmemektedir. Yapılan denemelerde de mod bilgisinin sistmin performansına bir katkısı olmadığı saptandığından yapay sinir ağı eğitimine sokulan değerler içine dahil edilmemişlerdir.

## **BÖLÜM 4. YAPAY SINİR AĞLARI**

### **4.1. Giriş**

Yapay Sinir Ağları kendisine verilen örnekler sonrasında, olaylar arasındaki ilişkileri öğrenerek, daha sonra hiç görmediği örnekler hakkında daha önce öğrendiği bilgileri kullanarak karar veren sistemlerdir [72]. Yapay sinir ağları insandaki biyolojik sinir sisteminden ilham alınarak geliştirilmiş, öğrenmeye ve öğrendiğine göre karar vermeye dayalı bir matematiksel hesaplama yöntemidir. Bir yapay sinir ağında insan beynindeki sinirlerin çalışması model alınarak öğrenme, genelleme yapma ve sınıflama gibi yetenekler kazandırmak amaçlanır.

İnsan beyninin üstün yapısı ve insan gibi düşünebilen cihazlar yapabilme arzusu bilim adamlarının bu konu üzerinde çalışmalarına sebep olmuştur. Bu amaçla beynin nöro-fiziksel yapısından esinlenerek matematiksel modeli çıkarılmaya çalışılmıştır. Beyne ait tüm fonksiyonların modellenebilmesi için fiziksel bileşenlerinin doğru olarak modellenmesi gerektiği düşüncesiyle yapay hücre ve ağ modelleri geliştirilmiştir. Yapay Sinir Ağları (YSA) bu çalışmalar sonucu doğmuş ve gün geçtikçe popülaritesini arttırarak yapay zeka alanında ciddi bir yer edinmiştir.

McCulloch ve W.A. Pitts isimli iki araştırmacı, 1943 yılında yayınladıkları bir makale [73] ile Yapay Sinir Ağlarının temel aldığı matematiksel modelin ilk adımını atmışlardır. B.G. Farley ve W.A. Clark ise, 1954 yılında yaptıkları bir çalışmayla bilgisayar ortamında bir ağ içerisinde uyarılara tepki verebilen ve uyarılara adapte olabilen model oluşturmayı başarmıştır [74]. 1960'lı yıllarda ilk sinirsel bilgisayar ortaya konmuş, 1963 yılında ilk modellerin eksik yönleri belirtilmiş, 1970'li yıllarda ilk başarılı sonuçlar alınmıştır. YSA'nın teori ve dizaynında belirgin ilerlemeler son 20 yıl içerisinde olmuştur [75].

1972 yılında farklı branşlardaki iki araştırmacı adreslenebilir bellek ile ilgili olarak birbirine benzer çalışmalar yapmışlardır [76, 77]. Biri Elektrik Mühendisi olan Kohonen ve diğeri nöropsikolojist Anderson olan bu iki araştırmacının yaptıkları çalışmalar, öğreticisiz öğrenmenin temelini oluşturmuştur [72]. Daha sonra hızla gelişen Yapay Sinir Ağları için, 1970 sonrası kronolojik gelişmede önemli adımları veren tablo aşağıda görülmektedir: [72]

Tablo 4.1. 1970 sonrası YSA gelişimi

1969-1972	Doğrusal ilişkilendiricilerin geliştirilmesi	
1972	Korelasyon matris belleğinin geliştirilmesi	
1974	Geriye yayılım modelinin geliştirilmesi	
1978	ART modelinin geliştirilmesi	Öğreticisiz öğrenme
1982	Kohonen öğrenmesi ve SOM modelinin geliştirilmesi	
1982	Hopfield ağlarının geliştirilmesi	
1982	Çok katmanlı algılayıcıların geliştirilmesi	
1984	Boltzman makinesinin geliştirilmesi	
1985	Çok katmanlı algılayıcıların Delta öğrenme kuralıyla gerçekleştirilmesi	
1988	RBF modelinin geliştirilmesi	
1988	PNN modelinin geliştirilmesi	
1991	GRNN modelinin geliştirilmesi	

Yapay sinir ağlarının diğer yöntemlere göre avantaj ve dezavantajları vardır. Başlıca üstünlüklerine örnek olarak matematiksel modele ihtiyaç duymaması, kural tabanı kullanımı gerektirmemesi ve öğrenme yeteneği olması sayılabilir. Yapay sinir ağının paralel çalışması ve işlevin yapısal olarak dağıtılmış olması da bir avantajdır. YSA da bir çok nöron paralel olarak eşzamanlı çalışır ve her biri toplam işlevin küçük bir parçasını gerçekleştirir. Bu durumda herhangi bir nöron zaman içinde işlevini kaybetse de, toplam sistem performansı açısından bu durum ciddi bir bozulmaya yol açmayacaktır. Sistemin genelleme yeteneğinin olması, yani eğitim sırasında kullanılmayan girdiler için de anlamlı yanıtlar üretebilmesi, ağ fonksiyonunun doğrusal olmaması, ve YSA yaklaşımlarının tümdevre olarak gerçekleştirilebilir olması diğer artı özellikler olarak sayılabilir [78, 79, 80].



Öne çıkan dezavantajları ise sistemin içinde ne olduğunun bilinmemesi yani sistemin çalışmasının analiz edilememesi, bir çok ağ için kararlılık analizi yapılamaması ve farklı bir sisteme uyarlanmasının zor olması olarak sayılabilir [78].

Bir problemin Yapay Sinir Ağı kullanılarak çözümünde sinir ağını tasarlayan kişinin tasarım konusunda bazı kararlar vermesi gerekir. Bunlardan ilki öğrenme şeklinin nasıl olacağıdır. Öğreticili ve öğreticisiz olmak üzere iki temel öğrenme çeşidi vardır. Eğer öğrenme sırasında girişlere karşılık doğru çıkışlar veriliyorsa buna öğreticili öğrenme denir. Girişlere karşılık doğru çıkışlar verilmiyorsa, bu öğreticisiz öğrenmedir ve genelde büyük veri kümeleri için sistemin geçmişe yönelik istatistiksel bilgilerin çıkarılması amacıyla kullanılır. Gerçek hayattan örnek vermek gerekirse, öğreticili öğrenmeye, bir öğretmen karşısında bilgi edinen öğrenci örnek verilebilir. Öğreticisiz öğrenme için ise, deneme-yanılma yöntemi denen yöntemle öğrenme örnek verilebilir. Bu yöntemle en çok iki tekerlekli bisiklet sürmeyi öğrenen çocuk örneği verilmektedir. Çocuk her denemede daha önce yaptığı hatalardan birinden vazgeçer, doğru yaptıklarını tekrar eder ve en sonunda bisiklet üzerinde dengede kalmayı öğrenir [78, 80].

Tasarımcının vermesi gereken bir diğer karar ise Yapay Sinir Ağı'nın mimarisi ile alakalıdır. Temel olarak mimariler geri beslemeli ve ileri sürümlü olarak ikiye ayrılabilir. Bir diğer önemli tasarım kararı ise, öğrenme algoritmasının ne olacağıdır. Literatürde bir çok öğrenme algoritması vardır ve sistemin performansı bu algoritmalara göre değişmektedir. Bunlar haricinde nöron sayıları, katman sayıları, işlem zamanları vs gibi daha bir çok parametre vardır [78,80].

Bir YSA'da bağlantı, katman ve nöron sayıları ne kadar çok ise, bu sinir ağı'nın temsil edebileceği sistem de o kadar karmaşık olabilir. Diğer bir deyişle, sistemde ne kadar çok nöron varsa o kadar gelişmiş sistemler modellenebilir. YSA klasik algoritmik yöntemlerle çözülemeyen problemleri insan beyninin çalışma sistemini örnek alarak, öğrenme ve hatırlamaya dayalı olarak çözmektedir. Ancak bir YSA'nın

kesin doğrulukta çalışacağı, yani %100 verim vereceği söylenemez. Yapay sinir ağları günümüzde bir çok uygulama alanı bulmaktadır.


Yapay sinir ağlarının temel yapısı, beyne, sıradan bir bilgisayara oranla daha çok benzemektedir. Ancak yine de yapay sinir ağının birimleri gerçek nöronlar kadar karmaşık değildir ve ağların çoğunun yapısı, beyin kabuğundaki bağlantılarla karşılaştırıldığında aşırı derecede basit kalmaktadır. İnsan beyin kabuğunda 10 milyar nöron ve 60 trilyon bağlantı vardır [80]. Bu rakamlar göz önüne alındığında, insan beynine yaklaşan bir sinir ağının yapay olarak imal edilmesinin günümüz teknolojisi ile mümkün olmadığı açıkça görülebilir.

Yapay sinir ağları örüntü tanımadan tahmin ve kestirimlerde bulunmaya, karakter tanımadan sistemlerin modellenmesine, sınıflandırmadan kontrol sistemlerine kadar bir çok uygulama alanı bulmuştur. Bu çalışmada YSA sınıflandırma amaçlı olarak kullanılacaktır. YSA sınıflandırıcıları, tanınması istenen öznitelik vektörünü giriş olarak alan ve çıkış ünitelerinin birinde bu nesnenin sınıfını belirleyen bir cevap üreten, pek çok doğrusal olmayan hesaplama elemanlarının paralel işleyişinden meydana gelmiş bir yapıdır.

## 4.2. Yapay Sinir Ağlarının Temel Özellikleri


### 4.2.1. Yapay sinir ağlarının biyolojik kökeni

İnsan beyni, düşünme, hatırlama ve problem çözme yeteneklerine sahip karmaşık bir sistemdir. Beyin fonksiyonlarının bilgisayarla taklit edilmesine yönelik girişimlerin başarısı henüz kısmi olmaktan öteye gidememiştir.



Şekil 4.1. Biyolojik sinir sisteminin blok gösterimi

İnsan beynini oluşturan temel birim nörondur. Şekil.4.2’de gerçek sinir hücresinin yapısı ve nöronların birbirlerine bağlantısı gösterilmiştir. Şekilden de görülebileceği gibi, temel biyolojik sinir hücresi sinaps, soma, akson ve dendrit adı verilen bölümlerden oluşmaktadır. Nöron, dendritleri kullanarak sinyalleri alır ve aldığı bu sinyalleri birleştirir. Eğer bileşke sinyal yeterli ölçüde güçlü ise nöron ateşleme yapar. Bu durumda sinyal, akson boyunca yol alır ve akson diğer nöronların dendritleri ile bağlantılıdır. Bu bağlantılara sinaps adı verilir ve aslında bunlar fiziksel bağlar değil, elektriksel işaretin geçmesini sağlayan boşluklardır. Bu boşluklar elektriksel yükü değişken hızlarda ileten sıvı ile dolu çok küçük boşluklardır. Sinaptik bağlantının empedans veya kondüktans değerinin ayarlanması, bellek oluşumu ve öğrenmeyi sağladığından kritik önemdedir [1, 72, 78, 80].




Şekil 4.2. Gerçek sinir hücresinin (nöron) yapısı ve Nöronların birbirlerine bağlanması

#### 4.2.2. Yapay sinir hücresi

Biyolojik sinir ağlarındaki sinir hücrelerine karşılık, yapay sinir ağları da yapay sinir hücrelerine sahiptir. Bir yapay sinir hücresi birbirine paralel olarak çalışan basit elemanlardan oluşur. Bir yapay sinir hücresi, biyolojik sinir hücresinin bileşenlerine benzer bileşenlerle modellenir. Temel olarak 5 bileşenden oluşan yapay sinir hücresi, Şekil.4.3 de verilmiştir.

Girdi, Ağırlık, Toplama Fonksiyonu, Aktivasyon Fonksiyonu ve Çıktı olarak sıralanabilecek bu beş temel eleman da ayrıca şekilde belirtilmiştir.



Girişler      Ağırlıklar      Toplama      Aktivasyon Fonksiyonu      Çıktı  
ŞEKİL 4.3. Yapay Sinir Hücresi

Girdiler, yapay sinir ağına dış dünyadan sağlanan bilgilerdir. Ağın öğrenmesi beklenen veriler bunlardır. Yapay sinir hücresine bu bilgiler dış dünyadan gelebileceği gibi, farklı hücrelerden veya geri besleme ile kendisinden de gelebilir [1, 72, 78, 79, 80].

Gövdenin giriş birimi olan bağlantıların her birisi kendisine ait bir ağırlık çarpanına sahiptir. Bir girişin ağırlığı, hücreye o giriş ile gelen bilginin önemini gösterir. Bu çarpanın işareti pozitif veya negatif olabilir. Sıfır olan ağırlık, o girişin herhangi bir etkisinin olmadığını gösterir [1, 72, 78, 79, 80].

Girişler ağırlık değerleri ile çarpıldıktan sonra, toplama fonksiyonu ile toplanırlar. (Bu hesap için farklı fonksiyonlar kullanılmakla beraber, en yaygın kullanılan ağırlıklı toplamı bulmaktır). Toplama fonksiyonu hücreye gelen net girdiyi hesaplar. Eğer  $G$  ile girdiler,  $A$  ile ağırlıklar ve  $n$  ile de toplam girdi sayısı sembolize edilirse, toplama fonksiyonu şu şekilde olacaktır:

$$Net = \sum_i^n G_i A_i$$

En yaygın kullanılan yöntem bu olmakla beraber, literatürde farklı toplama fonksiyonlarına da örnekler bulmak mümkündür. Bir problem için en uygun toplama fonksiyonunu bulmak için belirlenmiş bir yöntem yoktur. Bu fonksiyon genellikle

deneme-yanılma yolu ile belirlenir. Bir ağı oluşturan farklı sinir hücrelerinin tümünde aynı toplama fonksiyonunun kullanılması da şart değildir [1, 72, 78, 79, 80].


Toplama fonksiyonu ile belirlenen değer, yapay sinir hücresi gövdesinin ikinci kısmını oluşturan aktivasyon fonksiyonunun girişi olur ve nöronun çıkışındaki genliği kısıtlamak için kullanılır. Genelde bir nöronun normalize edilmiş genliği [0,1] veya [-1,1] kapalı aralığında ifade edilir. Aktivasyon fonksiyonu, toplama fonksiyonu ile belirlenen net girdiyi işleyerek, hücrenin buna karşılık üreteceği çıktıyı belirler. Aktivasyon fonksiyonunda da, toplama fonksiyonunda olduğu gibi, farklı formüller kullanılabilir. Yine toplama fonksiyonunda olduğu gibi, ağın her hücresinde aynı aktivasyon fonksiyonunu kullanma şartı da yoktur. Çok katmanlı algılayıcı gibi bazı modeller, aktivasyon fonksiyonunun türevi alınabilir bir fonksiyon olmasını şart koşmaktadırlar [1, 72, 78, 79, 80].

Genel olarak Aktivasyon Fonksiyonu olarak Sigmoid Fonksiyonu kullanılmaktadır. Sigmoid fonksiyonu doğrusal ve doğrusal olmayan davranışlar arasında denge sağlayan sürekli artan bir fonksiyon olarak tanımlanır. Sigmoid fonksiyona bir örnek lojistik fonksiyondur ve Şekil.4.4'te gösterilmiştir. Toplama fonksiyonundan gelen değere Net dendiğinde, sigmoid fonksiyonu şu şekilde ifade edilir: [72, 78, 79, 80]


$$f(Net) = \frac{1}{1 + e^{-Net}}$$

Hiperbolik tanjant fonksiyonu da sigmoid fonksiyonunun bir başka örneğidir ve bu fonksiyon Şekil.4.5'te görülebilir. Toplama fonksiyonundan gelen değere Net dendiğinde, hiperbolik tanjant fonksiyonu şu şekilde ifade edilir: [1, 72, 78, 79, 80]

$$f(Net) = \frac{e^{Net} - e^{-Net}}{e^{Net} + e^{-Net}}$$




Şekil 4.4. Lojistik Sigmoid Fonksiyonu



Şekil 4.5. Hiperbolik tanjant fonksiyonu

Aktivasyon fonksiyonu olarak kullanılan bir diğer fonksiyon ise Eşik fonksiyonudur. Bu fonksiyon kullanılarak oluşturulmuş bir yapay sinir hücresi McCulloch-Pitts modeli olarak da adlandırılır. Fonksiyona ait grafik Şekil.4.6'da verilmiştir. Grafiklerden de görülebileceği gibi sigmoid fonksiyonu türevi alınabilir bir fonksiyon iken eşik fonksiyonunun türevi alınamaz [1, 72, 78, 79, 80].



Şekil 4.6. Eşik Fonksiyonu


Bunlar haricinde girişi aynen çıkışa veren doğrusal fonksiyon ( $f(Net) = Net$ ),

$$f(Net) = \begin{cases} 1 \Rightarrow Net \geq 1/2 \\ Net \Rightarrow 1/2 \geq Net \geq -1/2 \text{ formülü ile verilen kısmi doğrusal fonksiyon,} \\ 0 \Rightarrow Net \leq -1/2 \end{cases}$$

$f(Net) = \sin(Net)$  formülü ile verilen sinüs fonksiyonu, ve toplama fonksiyonundan gelen değeri belli bir eşik değere göre değerlendiren ve

$$f(Net) = \begin{cases} 1 \Rightarrow Net > \text{esik deger} \\ 0 \Rightarrow Net \leq \text{esik deger} \end{cases} \text{ formülü ile verilen step fonksiyonu gibi}$$

fonksiyonlar da aktivasyon fonksiyonu olarak kullanılmaktadırlar [72, 78, 79, 80]. Şekil.4.7'de kısmi doğrusal fonksiyon verilmiştir. Bu fonksiyon doğrusal olmayan bir genlik artımı sağlar.

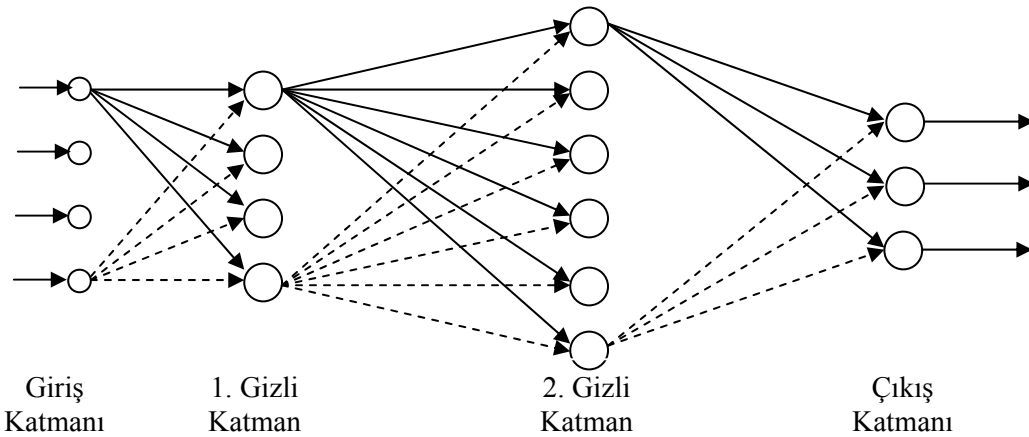


Şekil 4.7. Kısmi Doğrusal Fonksiyon

Bir yapay sinir hücresinin beşinci ve son bileşeni ise **çıkıttır**. Şekil.4.3'te de görülebileceği gibi, çıktı, aktivasyon fonksiyonunun bir sonucudur. Çıktı değeri dış dünyaya verilebileceği gibi, bir başka yapay sinir hücresine giriş olarak da kullanılabilir [72, 80].

### 4.3. Yapay Sinir Ağlarının Yapısı

Yapay Sinir Ağı, yapay sinir hücrelerinin veri işlemek amacıyla bir araya gelmesiyle oluşur. Bu yapı, yapay sinir hücreleri tarafından üç temel katman olarak ve her katmanda paralel şekilde bir araya gelerek oluşturulur. Bu üç temel katman Giriş katmanı, Ara katmanlar ve Çıkış katmanı olarak adlandırılır. Giriş katmanının görevi, dış dünyadan bilgileri alarak, ara katmanlara iletmektir. Genellikle giriş katmanında bilgi işleme durumu olmaz. Giriş katmanı ile ağ içine alınan bilgiler, ara katmanlarda işlenerek çıkış katmanı ile çıkışa gönderilir. Ara katmanlar birden fazla olabilir. Ara katmanlar çoğu zaman gizli katman olarak da adlandırılırlar. Çıkış katmanı ise, ara katmandan gelen bilgileri işleyerek, giriş katmanından gelen bilgilere göre çıkış üretir ve bu çıkış değerlerini dış dünyaya verirler. Şekil.4.8'de basit olarak bir yapay sinir ağının katman yapısı gösterilmektedir [1, 72, 79, 80].



Şekil 4.8. Yapay Sinir Ağının katman yapısı


### 4.4. Ağ Çeşitleri

Ağ yapıları tek katmanlı ileri beslemeli, çok katmanlı ileri beslemeli ve döngülü yapay sinir ağları olmak üzere üç temel başlıkta toplanabilir.



#### 4.4.1. Tek katmanlı-ileri beslemeli sinir ağları (FFNN)


Yapay Sinir Ağlarında en basit ağ yapısı, tek katmanlı ileri beslemeli yapay sinir ağıdır. Bu tip ağda, temel katmanlardan olan ara katmanlar yoktur. Ağ sadece bir giriş katmanı ve bir çıkış katmanından oluşur. Bu tip ağın yapısına bir örnek Şekil.4.9'da gösterilmiştir. İleri besleme denmesinin sebebi, bilginin girişten çıkışa doğru ilerlemesidir. Giriş katmanı giren bilgi üzerinde hiçbir işlem yapmadan veriyi çıkış katmanına iletir ve bu yüzden Tek katmanlı olarak isimlendirilir.



Şekil 4.9. Tek katmanlı yapay sinir ağı

#### 4.4.2. Çok katmanlı-ileri beslemeli sinir ağları (MLFFNN)

Çok katmanlı yapay sinir ağları, tek katmanlıdan farklı olarak, giriş ve çıkış katmanları arasında bir veya daha fazla gizli katman (ara katman) içerir. Bu ağın yapısına bir örnek Şekil.4.10'da verilmiştir. Gizli katmanlar giriş ve çıkış katmanları arasında yer alır ve bilgiyi işlemek adına işlemler yaparlar. Giriş katmanı geniş olduğunda gizli katmanlar sayesinde yüksek dereceli istatistiksel bilgi elde edilebilir. Çok katmanlı yapılarda bir katmanın çıkış işaretleri bir sonraki katmana giriş işareti olarak verilir. Eğer bir yapay sinir ağında giriş katmanında  $m$  adet giriş düğümü, ilk gizli katmanda  $h_1$  adet nöron, ikinci gizli katmanda  $h_2$  adet nöron ve çıkış katmanında ise  $q$  adet nöron var ise, bu çok katmanlı ileri besleme ağına  $m-h_1-h_2-q$  ağı denir. Eğer her katman için, bir katmanda bulunan nöronlar bir sonraki katmanın tüm nöronlarına bağlıysa bu tip ağa tam bağlantılı ağ denir. Tersisi durumda ise ağa kısmi bağlantılı ağ adı verilir.



Şekil 4.10. Çok katmanlı yapay sinir ağı

#### 4.4.3. Döngülü yapay sinir ağları (RNN)

İleri beslemeli ağlardan farklı olarak, döngülü yapay sinir ağlarında en az bir adet geri besleme çevrimi bulunmaktadır.

Bu sınıflandırmalarda, nöronlar arası bağlantıların simetrik veya asimetrik olması durumuna göre alt sınıflar ortaya çıkar.  $i$  nöronundan  $j$  nöronuna yönelik bir bağlantı varsa  $j$ 'den  $i$ 'ye yönelik de bir bağlantı vardır. Bu iki bağlantının ağırlıkları  $w_{ij}=w_{ji}$  birbirine eşitse bağlantı için simetrik bağlantı denir. Ağırlıkların eşit olmama durumunda ise, bağlantı asimetrik olur.

Farklı katmanlarda bulunan nöronların birbirleriyle bağlantısına, katmanlararası (interlayer) bağlantı denir. Aynı katmandaki nöronların birbirleri ile bağlantısına, katmaniçi (intralayer) bağlantı, komşu olmayan katmanlardaki nöronların birbirleri ile bağlantısına ise katmanlarötesi (supralayer) bağlantı denir. Bir nöron kendisiyle de bağlantılı olabilir. Bir katmana ait tüm nöronların komşu katmandaki tüm nöronlarla bağlantılı olduğu duruma ise tam-bağlantılılık denmektedir.


#### 4.4.4. Bileşik yapay sinir ağları (CNN)

Sınıflandırmaların doğru yapılabilmesi konusunda, yapay sinir ağları modellerinin birleştirilerek kullanılması, diğer modellerin tek başına kullanımından daha verimli sonuçlar vermektedir. Bu birleştirilmiş yapıya Bileşik Yapay Sinir Ağları (Combined Neural Networks, CNN) denmektedir. Bileşik Yapay Sinir Ağları yığın genellemesi

temeline dayanır. Alt düzey ölçümlerin, ele alınan modeli özlü olarak gösterememesi sebebiyle, verinin eğitilmesi aşamasında genellikle arama alanı içerisinde dağınıklık oluşur. Değişkenler arasındaki karmaşık ilişki, giriş-çıkışların ve gürültünün fazlalığı sebebiyle örneklerde uygulamalar için fiziksel olarak kullanılmaya uygun büyük miktarda verinin eğitimi kolay olmamaktadır. Öğrenme süreci, verinin daha uygun bir örneğe dönüştürülmesi ile daha kolay hale getirilebilir. Örneğin, genellikle belirleyici özellikler (features) olarak adlandırılan, daha az sayıda parametre kullanımı, üzerinde çalışılan işaretin karakterize edilebilmesinde özellikle tanıma ve sınıflandırma yapılabilmesi amacıyla önemlidir. Bu sebeple veri temsilindeki özelliklerin herhangi biri için, bu veriyi kullanarak temelde yatan öğrenme zorluğunun yaklaşık olarak hesaplanması zorunludur. Öğrenme sistemi örnekleri öğrenme için daha kolay bir hale dönüştürmelidir [82, 83, 84].

Yığın genelleme fikri henüz bu fikirler ortaya atılmadan Wolpert tarafından şekillendirilmiştir. Aynı zamanda Wolpert hedeflenmiş çıkış değerlerinin oluşturulmasından önce genelleştiricilerin bir kümesinden diğerine data beslemesine yönelik planlardan bahsetmiştir [85]. Yığın genellemenin en büyük katkısı, genelleyici ağının içine, orijinal öğrenme setinin farklı bölmelerinden veri beslemesi yapmasıdır. Yığın genelleme tasarısı, çapraz geçerlik denetiminin daha karmaşık bir şekli olarak düşünülebilir ve tek başına YSA kullanmanın tersine, YSA modellerinin genelleme yeteneğini etkin olarak arttırdığı deneysel olarak gösterilmiştir.

Bu çalışmada kullanılan Bileşik Sinir Ağı modeli Şekil.4.11'de gösterilmiştir. Bileşik sinir ağlarının gerçekleştirilmesinde birinci ve ikinci seviyelerde FEBANN (FeedForward Error Backpropagation Artificial Neural Networks, İleri beslemeli, Hata Geri Yayılımlı Yapay Sinir Ağı) kullanılmıştır. Bu yapılandırma, FEBANN'ın gerçekleştirme kolaylığı, hızlı çalışma, daha küçük eğitim setlerini gerektirmesi, öğrenme ve genelleme yapabilmesi gibi özelliklere sahip olduğu teorisinden doğmuştur. YSA'ların önemli karakteristiklerinden birisi de eğitim süresidir ki bu sayede bilginin temsili örnekleri ağa tekrarlamalı olarak sunulur böylece bu bilgi kendi yapısıyla bütünleşir.



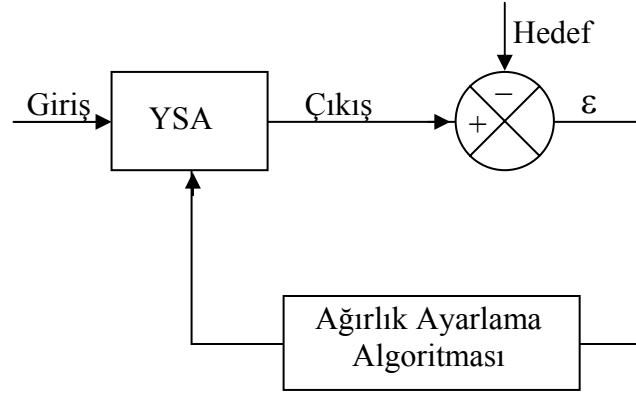
Şekil 4.11. MUAP sınıflandırması için kullanılan Bileşik Sinir Ağı topolojisi

#### 4.5. YSA'da Öğrenme ve Hatırlama

Yapay Sinir Ağları öğrenme ve hatırlama olmak üzere, iki temel fonksiyon gerçekleştirir. Öğrenme fonksiyonu, ağı ait ağırlık değerlerinin, bir giriş vektörüne karşılık istenen/hedeflenen çıkış vektörünü sağlamak üzere uyarlanmasıdır. Yapay sinir ağlarının bir girişe karşılık, ağırlık değerlerine uygun bir çıkış üretmesi işlemine ise hatırlama denmektedir.

Öğrenme sürecinde ağırlık değerleri belirlenir. Bu süreç öğreticili veya öğreticisiz olabilir. Öğreticili veya öğreticisiz olması arasındaki fark, bölüm 4.1'de de değinildiği gibi, eğitim verisinin sınıflandırmasını yapan herhangi bir denetim

mekanizmasının olup olmadığıdır. Öğreticisiz öğrenmede, öğrenme süreci boyunca, öğrenme işleminin yanında eğitim verisinin sınıflandırılması da başarılması gereken bir başka görevdir. Şekil.4.12’de bir yapay sinir ağının eğitim algoritması görülmektedir.



Şekil 4.12. YSA'nın eğitimi

Mühendislik uygulamalarında genellikle öğreticili öğrenme kullanılmaktadır. Bunun için eğitim sırasında sinir ağına hedeflenen amaca uygun örnek bilgiler verilir. Diğer bir deyişle, belli girişlere karşı, sinir ağının çıkışları denetim mekanizması tarafından sınıflandırılır. Daha sonra eğitilmiş ağdan, sonucu bilinmeyen girişler kullanıldığında, çıkışı sınıflandırması beklenir.

#### 4.5.1. Eğitim ve test verisi seçimi

Yapay sinir ağlarında eğitim için ve sonrasında eğitilmiş ağda test için kullanılacak verilerin iyi seçilmesi önemli bir adımdır. Bir yapay sinir ağının vereceği sonuçlar, kendisinin eğitim sırasında kullandığı örnek aralığında güvenli olacaktır. Diğer bir deyişle yapay sinir ağlarının ekstrapolasyon yeteneği kısıtlıdır. Bu yüzden eğitim sırasında kullanılacak eğitim verilerinin yer aldığı aralığın mümkün olduğunca geniş olması önemlidir. Ağ öncelikle bu verilerden bir kısmı ile eğitilir ve bir kısmı ile eğitilmiş ağ test edilir. Test sırasında başarısızlık olması durumunda, bu test verilerinin bir kısmı daha eğitim verisine dahil edilerek hedeflenen performans sağlanana kadar işlem tekrarlanır.

Bir yapay sinir ağının eğitiminde en sık karşılaşılan sorun ezberleme sorunudur. Ezberleme, sinir ağının girişlere karşılık çıkışlar arasındaki ilişkiyi öğrenmesi değil, bunun yerine belli girişlere karşılık belli çıkışları ezberlemesidir. Bu durumda girişler az miktarda değiştirildiğinde bile, sinir ağının performansı önemli ölçüde düşer. Eğer yapay sinir ağının test sırasındaki hata seviyesi, eğitim sırasındaki hata seviyesinden farklı şekilde büyükse, ezberleme durumu olduğu anlaşılır. Bu da tanımlanması istenen fonksiyonel ilişkiden daha çok eğitim verisindeki gürültü gibi istenmeyen bileşenlerin de öğrenildiği anlamına gelir. Ezberleme problemine karşı bazı önlemler alınabilir. Örneğin, eğitim verileri kümesi genişletilerek, istenmeyen bileşenlerin oranı düşürülür. Veya serbest parametre olan nöronların sayısı, optimum değer ile sınırlandırılabilir. Eğitimin, ezber başlamadan kesilmesi de ezberleme için bir önlemdir. Bu yöntem, çapraz değerlendirilmeli eğitim denir. Çapraz değerlendirilmeli eğitimde, bir yandan eğitim yapılırken, eşzamanlı olarak ezberleme kontrolü yapılır. Bunun için eğitim sırasında eğitim için ve kontrol için iki ayrı veri grubu kullanılır. Sürekli olarak eğitim ve kontrol gruplarına ait hatalar hesaplanır. Kontrol kümesinin hatasında değişim olmazken veya çok küçük olurken, eğitim kümesine ait hatanın hızla düştüğü nokta ezberlemenin başladığı noktadır. Bu farkın oluşmaya başladığı noktada eğitim kesilerek ezberlemenin önüne geçilmiş olur.

#### **4.6. Yapılan Uygulamada YSA Parametrelerinin Belirlenmesi ve Modelin Geliştirilmesi**

Bu uygulamadaki modelleme aşamasının amacı, girilen her giriş kombinasyonunun normal, miyopatik veya nörojenik sınıflarından hangisine ait olduğunu belirleyecek sınıflandırıcıların oluşturulmasıdır. Desen sınıflandırma probleminin çözümü için, bu çalışmada YSA geri yayımlı eğitim algoritması ile kullanılmıştır. Etkili bir eğitim algoritması olması ve sistemin davranışlarının kolay anlaşılması bu tür sinir ağlarının avantajlarındandır. YSA giriş parametrelerinin belirlenmesi ve sinir ağının performansının yüksek olması, Normal (NOR), miyopatik (MYO) ve nörojenik (NEU) deneklerin ayrımının yapılabilmesi için önemlidir.

Sinir ağları kullanırken, verilerin eğitim setlerine ve deneme setlerine nasıl ayrılacağına karar vermek gerekir. Bu çalışmada 27 denekten alınan verilerden 18 tanesi eğitim için geri kalanı ise test amaçlı kullanılmıştır. Daha iyi bir YSA

genellemesinin yapılabilmesi açısından 5 denekten alınan veriler karşılaştırma amaçlı kullanılmıştır. Sinir ağlarının çalışmalarının yeterliliği, eğitim setlerinin ve test setlerinin büyüklüğüne bağlıdır. Birinci seviye ve ikinci seviyenin her ikisinde de, eğitim için her sınıftan 300 adet olmak üzere 900 vektör, test için ise her sınıftan 100 adet olmak üzere 300 vektör kullanılmıştır. Eğitim ve test veri setlerindeki örneklerin sınıf dağılımları Tablo 4.2’de özetlenmiştir. Birleşik sinir ağının genelleme özelliğinin pratik olarak geliştirilmesinin bir yolu, eğitim ve test setlerini oluşturan verilerin farklı hastalardan alınmasıdır.

EMG işaretlerinin, bun işaretleri oluşturan MUAP sınıflarına ayrıştırılmasında kullanılan birleşik sinir ağları topolojisi Şekil 4.11’de verilmiştir.

Bu çalışmada üç teşhis sınıfı (NOR, MYO, NEU) olduğundan birinci sınıf modeller için üç set sinir ağı eğitilmiştir. Bu durumda bir MUAP çeşidinin diğer MUAP çeşitlerinden daha yüksek doğrulukta bir sonuç vermesi mümkündür. Her bir ağı giriş öznitelik vektörü sayısı kadar giriş nöronları bulunmaktadır. Öznitelik vektörleri farklı AR parametrik metodları ve altuzay tabanlı metodlar kullanılarak hesaplanmaktadır. Gizli nöron sayısı 80’dir ve çıkış katmanı normal, miyopatik ve nörojenik rahatsızlığı temsil eden üç düğümden oluşmuştur.

İşaretlerin çıkış kategorilerine göre sınıflandırılması için sınıflandırma şemalarından olan 1-C(1-of-C) kodlaması kullanılmıştır. Her tip EMG işareti için buna karşılık gelen çıkış sınıfı ilişkilendirilmiştir. Oluşturulacak olan x vektör seti YSA girişlerini ve buna karşılık gelen sınıfı, kodlandıktan sonra ise YSA çıkışlarını temsil eder. Sinir Ağı eğitiminin daha verimli olması için oluşturulacak olan giriş vektör setleri [0, 1.0] aralığında kalacak şekilde normalize edilir. Çıkış sınıflarının sayısı 3 olduğundan her bir sınıf için kod üreten YSA’nın da 3 çıkışı bulunmaktadır. Çıkışlar temel vektörler ile temsil edilmektedirler:

$$\begin{aligned} [1 \quad 0 \quad 0] &= \text{normal (NOR)} ; \\ [0 \quad 1 \quad 0] &= \text{miyopati (MYO)} ; \\ [0 \quad 0 \quad 1] &= \text{nöropati (NEU)} . \end{aligned}$$

İkinci seviye ağın girişlerini, birinci seviye ağın üç grupluk çıkışına karşılık gelen 9 değer oluşturmaktadır. İkinci seviye ağların hedefleriyle orijinal verinin hedefleri aynıdır.

Düzenlenmiş  $x_k$  giriş vektörü ile ilişkilendirilmiş Çıkış vektöründe  $k=1,2,\dots,K$  dir ve  $y_k$  olarak da kullanılmaktadır.  $K$  ise EMG işaretlerinin sayısıdır [26].

Başlangıç ağırlıkları rasgele verildiğinde YSA çıktıları istenilen sınıflandırmalardan çok farklı olmaktadır. YSA eğitildikçe, sistemden istenilen yanıt ile sistemin çıktılarının birbirine yakın olması için YSA ağırlıkları sürekli olarak düzenlenmektedir. Optimal ağın belirlenmesinde, hata varyasyonlarının gözlenmesi ve ağ gizli katman boyutunun her bir eğitim turu için genişletilmesi esnasındaki doğruluk parametreleri temel alınmıştır. İstenilen yanıt ve sistem çıktısı arasındaki farka hata denir ve farklı şekillerde ölçümünü yapmak mümkündür. En sık karşılaşılan ölçüm yöntemleri SSE (Sum of Square Error) ve MSE (Mean Square Error) dir. SSE, her çıkış değerinin ve istenilen değer farkının karelerinin toplamıdır. Bu çalışmada sinir ağının performansının ölçümü, hatanın karelerinin aritmetik ortalaması olan MSE ile değerlendirilmiştir. Çapraz geçerlilik denetimli (cross-validation) hatalar 2000 epoch mertebesinde artmaya başladığı için birinci ve ikinci seviye sinir ağlarının eğitilmesi 2000 epoch değerinde sonlandırılmıştır. 2000 epoch'ta ortalama karesel hata (MSE), sifıra çok yakın küçük bir değerde sabitlendiğinden sinir ağı eğitiminin başarılı olduğuna karar verilmiştir.

Bu çalışmadaki modelleme aşamasının amacı, herhangi bir giriş kombinasyonunun, normal, miyopatik veya nörojenik, sınıflarından hangisine ait olduğunun belirlenebilmesiydi. Yapay Sinir Ağı sınıflandırıcılarının geliştirilmesiyle 1200 örnek arasından 900 tanesi rasgele alınmış ve sinir ağının eğitilmesi için kullanılmıştır. Geriye kalan 300 örnek ise geliştirilen modellerin doğruluğunun test edilmesinde kullanılmıştır. Tablo 4.2'de eğitim ve test aşamalarındaki veri örneklerinin sınıf dağılımları özetlenmiştir.



Tablo 4.2. Eğitim ve test veri set örneklerindeki sınıf dağılımları

Sınıf	Eğitim Seti	Test Seti	Toplam
Normal	300	100	400
Miyopatik	300	100	400
Nöropatik	300	100	400
Toplam	900	300	1200

FEBANN, giriş katmanı içindeki EMG işaretinin AR spektrumu ile tasarlanmıştır. Çıkış katmanı, normal, miyopatik ve nörojenik hastalıkları temsil eden 3 düğümden oluşmaktadır.

YSA'nın başlangıç mimarisi üzerinde çalışılırken her katmanında gizli düğüm değişkenleri olan bir ve iki gizli katman kullanılmış, eldeki problemin çözümü için bir gizli katmanın yeterli olduğu kanısına varılmıştır. Bu durumda bu çalışma için gerekli olan sinir ağının 3 katmandan oluşması gerekmektedir. Eğitim aşaması gizli katman içindeki gizli düğümden başlamıştır. Bunu takiben, eğitim verisi (900 veri seti) ve doğruluğun kıyaslanması için oluşturulan test verileri (300 veri seti) üzerinde sinir ağının tahmin performansı, geliştirme aşamasında hiç kullanılmamış denekler ile deneyerek sinir ağı sınanmıştır. Sinir ağının gizli katmanına birer birer düğüm eklenerek sinir ağı genişletilmiş, en iyi mimari ve en iyi ağ bağlantı ağırlık setleri elde edilene kadar sinir ağının oluşturulmasında uygulanan adımlar tekrarlanmıştır. Eğitim için düzenlenmiş hata-geri\_yayımlı (backpropagation) algoritması kullanılarak farklı topolojilere sahip bir eğitim ağının en uygun eğitim oranının 0.001 ve momentum katsayısının 0.95 olduğu tespit edilmiştir. En uygun sinir ağı seçimi ise sinir ağının gizli katmanlarının ebatlarının ve her bir eğitim turunun genişletilme aşamasında oluşan hataların varyasyonları ve bazı netlik parametrelerinin gözlemlenmesiyle gerçekleştirilmiştir.

## **BÖLÜM 5. DENEYSEL EMG VERİLERİNİN SINIFLANDIRILMASI VE PERFORMANS KRİTERLERİ**

EMG güç spektrumları gücün frekansla dağılımını göstermektedir. Sonuç olarak, EMG işaretleri için mevcut spektral kestirim metotlarından hangisinin daha uygun olduğuna karar vermek önemlidir. EMG güç spektrumları farklı kestirim metotları kullanılarak elde edilmiştir. AR parametrik metotlarında, sinyal genelleme için model, gözlemlenen veriden kestirimi yapılabilecek birkaç parametreden oluşturulabilir. PSD, modelden ve tahmin edilen parametrelerden hesaplanabilir. Modelleme yaklaşımı, pencere fonksiyonlarına olan ihtiyacı ve pencere dışında öz ilinti (otokorelasyon) sırasının sıfır olacağı zannını ortadan kaldırmaktadır. AR PSD kestirim metotları tepe noktası az olan spektralleri modelleyebilir. AR işaret modellerindeki parametrelerin kestirimi doğruluğu kanıtlanmış bir konudur. Değerlendirmeler sistemin lineer denklemlerinin çözülmesiyle bulunurlar. Buna karşın AR metotlarının birkaç dezavantajının da olduğu bilinmektedir. Birincisi, yüksek İşaret/Gürültü oranlarında (SNR) spektral hat bölünmeleri gösterirler. Hat (satur) bölünmesi,  $x(n)$  'e ait spektrumun tek bir keskin tepe noktası olabilir. Bu metot, yüksek düzeyli modeller için de sahte tepe notaları ortaya çıkartmaktadır. Bunun yanında, gürültü içindeki sinüsoidal işaretler için, AR metotları, özellikle kısa veri kayıtlarında bir sinüs dalgasının başlangıç aşamasına hassasiyet göstermektedirler. Bu hassasiyet sonucunda faza bağımlı olan bir frekans sapması ile sonuçlanan bir frekans ötelemesi görülmektedir [16, 17, 18, 21, 24, 26, 65]. (Normal, miyopatik ve nörojenik deneklerin PSD'leri için Şekil 3.3, 3.4 ve 3.5'e ve EMG işaretleri ile bunların frekans spektrumları için Şekil 3.1'e bakılabilir).

Keskin tepe noktalı ve derin boşluklu spektrumlar AR metodu tarafından daha iyi modellenmektedirler [50].

Gerçek EMG işaretlerinin MUAP bileşenlerine ait benzer şekillerin bir araya gruplandırılarak sınıflandırılmaları, tipik bir denetimli (öğreticili) desen sınıflandırmayı öğrenme problemidir. EMG işaretlerini oluşturan MUAP sınıflarının sayısı, sınıf başına düşen MUAP'lerin sayısı ve MUAP'lerin dalga formlarının şekilleri bilinmeyenlerdir. MUAP dalga formlarının değişken olması, tek bir fiberin stresli olabilme potansiyeli ve MUAP'lerin süperpozisyonları problemi daha da karmaşık kılmaktadır. EMG analizi için geliştirilmiş herhangi bir bilgisayarlı metodun harici herhangi bir operatöre ihtiyaç duymaması, hızlı, sağlam ve güvenilir olması ve klinik kullanım için yüksek başarı oranına sahip olması gerekir.

Bu çalışmada 27 denekten toplanan EMG verileri FEBANN ve CNN kullanılarak analiz edilmiştir. Verilerden 7'si normal (NOR), 7'si miyopatik (MYO) ve 13 tanesi de nörojenik (NEU) rahatsızlığı bulunan deneklerden alınmıştır. Teşhis kriterleri olarak, klinik görüş, biyokimya sonuçları veya kas biyopsisi temel alınmıştır. Sadece herhangi bir nöromasküler rahatsızlık geçmişi veya belirtileri olmayan denekler normal olarak nitelendirilmiştir.

Uygulamalarda CNN'nin ve FEBANN'in test performansı aşağıdaki parametrelerin hesaplanmasıyla belirlenmiştir:

Kesinlik (Specificity): doğru sınıflandırılmış sağlıklı deneklerin sayısının, toplam sağlıklı denek sayısına oranı.  $(D_{NOR}/T_{NOR})$

Hassasiyet (miyopatik): doğru sınıflandırılmış miyopatik deneklerin sayısının, toplam miyopatik denek sayısına oranı.  $(D_{MYO}/T_{MYO})$

Hassasiyet (nöropatik): doğru sınıflandırılmış nöropatik deneklerin sayısının, toplam nöropatik denek sayısına oranı.  $(D_{NEU}/T_{NEU})$

Toplam sınıflandırma doğruluğu: üç sınıftaki toplam doğru sınıflandırılmış denek sayısının, üç sınıftaki toplam denek sayısına oranı.  $(\frac{D_{NOR}+D_{MYO}+D_{NEU}}{T_{NOR}+T_{MYO}+T_{NEU}})$

### 5.1. Sınıflandırma Deneylerinin Sonuçları

Hesaplanmış AR spektrumları, CNN mimarisinde görevli FEBANN'in girişlerinde kullanılmaktadır. Her bir EMG işaret grubu için (1024 örnek), AR spektral güç

yoğunluğu hesaplanmaktadır. Bu uygulamada sağlıklı, miyopatik ve nöropatik olarak üç sınıf bulunmaktadır.

EMG işaret sınıflandırması için YSA modelinin doğruluğunu belirlemek amacıyla, YSA 900 eğitim verisi ile eğitildikten sonra, eğitim verilerinden farklı 300 test verisi ile sınanmıştır. Sınıflandırmada amaç, sınıf üyeliği olasılığını temsil etmeleri açısından, giriş desenlerini genellikle 0 – 1 aralığı ile sınırlı birkaç sınıftan birine atamaktır. Sınıflandırmanın taşınması esnasında, belirlenen bir desen bunun için seçilen karakteristik özelliklere göre bir sınıfa atanır.

FEBANN için istatistiksel parametrelerin değerleri Tablo.5.1’de verilmiştir. FEBANN’ın AR-Yule ile hassasiyet değeri miyopati için %88, nörojenik hastalıklar için %80’dir. FEBANN’ın AR-Yule ile kesinlik değeri %94, toplam sınıflandırma doğruluğu ise %87,3’tür. FEBANN’ın AR-Burg ile hassasiyet değeri miyopati için %88, nörojenik hastalıklar için %81’dir. FEBANN’ın AR-Burg ile kesinlik değeri %95, toplam sınıflandırma doğruluğu ise %88’dir. FEBANN’ın AR-Kovaryans ile hassasiyet değeri miyopati için %89, nörojenik hastalıklar için %85’tir. FEBANN’ın AR-Kovaryans ile kesinlik değeri %96, toplam sınıflandırma doğruluğu ise %90’dır. FEBANN’ın AR-iyileştirilmiş\_kovaryans ile hassasiyet değeri miyopati için %90, nörojenik hastalıklar için %86’dır. FEBANN’ın AR- iyileştirilmiş\_kovaryans ile kesinlik değeri %97, toplam sınıflandırma doğruluğu ise %91’dir. FEBANN ile işaretin belirleyici özellikleri (bkz. Bölüm 3.4) kullanılarak yapılan sınıflandırmada ise hassasiyet değeri miyopati için %88, nöropati için %89’dur. Bu yöntemde kesinlik değeri % 97 ve toplam sınıflandırma doğruluğu ise %91,3 çıkmaktadır.

Tablo 5.1. EMG İşaret sınıflandırması için farklı özellik çıkarım yöntemlerinin FEBANN kullanılarak karşılaştırılması

İstatistiksel Parametreler	AR Yule	AR Burg	AR Kov.	AR İ.Kov.	Belir. Özl.
Kesinlik (NOR)	94	95	96	97	97
Hassasiyet (MYO)	88	88	89	90	88
Hassasiyet (NEU)	80	81	85	86	89
Toplam Sınıf. Doğruluğu	87,3	88	90	91	91,3

CNN için istatistiksel parametrelerin değerleri Tablo.5.2’de verilmiştir. CNN’in AR-Yule ile hassasiyet değeri miyopati için %89, nörojenik hastalıklar için %82’dir. CNN’in AR-Yule ile kesinlik değeri %94, toplam sınıflandırma doğruluğu ise %88,3’tür. CNN’in AR-Burg ile hassasiyet değeri miyopati için %89, nörojenik hastalıklar için %83’tür. CNN’in AR-Burg ile kesinlik değeri %95, toplam sınıflandırma doğruluğu ise %89’dur. CNN’in AR-Kovaryans ile hassasiyet değeri miyopati için %90, nörojenik hastalıklar için %85’tir. CNN’in AR-Kovaryans ile kesinlik değeri %97, toplam sınıflandırma doğruluğu ise %90,6’dır. CNN’in AR-iyileştirilmiş\_kovaryans ile hassasiyet değeri miyopati için %90, nörojenik hastalıklar için %87’dir. CNN’in AR-iyileştirilmiş\_kovaryans ile kesinlik değeri %97, toplam sınıflandırma doğruluğu ise %91,3’tür. FEBANN ile işaretin belirleyici özellikleri kullanılarak yapılan sınıflandırmada ise hassasiyet değeri miyopati için %89, nöropati için %90’dır. Bu yöntemde kesinlik değeri % 97 ve toplam sınıflandırma doğruluğu ise %92 çıkmaktadır.

Tablo 5.2. EMG İşaret sınıflandırması için farklı özellik çıkarım yöntemlerinin CNN kullanılarak karşılaştırılması

İstatistiksel Parametreler	AR Yule	AR Burg	AR Kov.	AR İ.Kov.	Belir. Özel.
Kesinlik (NOR)	94	95	97	97	97
Hassasiyet (MYO)	89	89	90	90	89
Hassasiyet (NEU)	82	83	85	87	90
Toplam Sınıf. Doğruluğu	88,3	89	90,6	91,3	92

Elde edilen veriler, bu çalışma için, CNN’in doğruluk oranlarının FEBANN’a göre daha yüksek olduğunu göstermektedir. Ayrıca her iki ağ yapısında da işarete ait belirleyici özelliklerin dahil edildiği sınıflandırma toplam sınıflandırma doğruluğunda en başarılı sonucu vermiştir. Elde edilen değerler incelendiğinde, belirleyici özelliklerin başarı oranlarının hassasiyet değerlerinde diğerlerinden ayrıldığı ve miyopatik deneklerin ayrılmasında kısmi olarak daha düşük başarı elde edilirken, nörojenik deneklerde belirli olarak daha iyi bir performans alındığı görülmektedir.

Tablo 5.3. FEBANN – AR Yule

	<b>NOR</b>	<b>MYO</b>	<b>NEU</b>
NOR	<b>94</b>	3	3
MYO	12	<b>88</b>	0
NEU	19	1	<b>80</b>

Tablo 5.4. FEBANN – AR Burg

	<b>NOR</b>	<b>MYO</b>	<b>NEU</b>
NOR	<b>95</b>	2	3
MYO	12	<b>88</b>	0
NEU	18	1	<b>81</b>

Tablo 5.5. FEBANN – Kovaryans

	<b>NOR</b>	<b>MYO</b>	<b>NEU</b>
NOR	<b>96</b>	2	2
MYO	11	<b>89</b>	0
NEU	14	1	<b>85</b>

Tablo 5.6. FEBANN – İyileştirilmiş. Kov.

	<b>NOR</b>	<b>MYO</b>	<b>NEU</b>
NOR	<b>97</b>	2	1
MYO	10	<b>90</b>	0
NEU	13	1	<b>86</b>

Tablo 5.7. FEBANN – Belirleyici Özellikler

	<b>NOR</b>	<b>MYO</b>	<b>NEU</b>
NOR	<b>97</b>	2	1
MYO	11	<b>88</b>	1
NEU	11	0	<b>89</b>

Tablo 5.8. CNN – AR Yule

	<b>NOR</b>	<b>MYO</b>	<b>NEU</b>
NOR	<b>94</b>	3	3
MYO	10	<b>89</b>	1
NEU	17	1	<b>82</b>

Tablo 5.9. CNN – AR Burg

	<b>NOR</b>	<b>MYO</b>	<b>NEU</b>
NOR	<b>95</b>	2	3
MYO	11	<b>89</b>	0
NEU	16	1	<b>83</b>

Tablo 5.10. CNN – Kovaryans

	<b>NOR</b>	<b>MYO</b>	<b>NEU</b>
NOR	<b>97</b>	2	1
MYO	9	<b>90</b>	1
NEU	13	2	<b>85</b>

Tablo 5.11. CNN – İyileştirilmiş Kov.

	<b>NOR</b>	<b>MYO</b>	<b>NEU</b>
NOR	<b>97</b>	1	2
MYO	10	<b>90</b>	0
NEU	12	1	<b>87</b>

Tablo 5.12. CNN – Belirleyici Özellikler

	<b>NOR</b>	<b>MYO</b>	<b>NEU</b>
NOR	<b>97</b>	1	2
MYO	11	<b>89</b>	0
NEU	10	0	<b>90</b>

Tablo 5.13. Uygulanan tüm yöntemlere ilişkin başarımlar

	AR Yule Walker			AR Burg			Kovaryans			İyileştirilmiş Kovaryans			Belirleyici Özellikler		
	NOR	MYO	NEU	NOR	MYO	NEU	NOR	MYO	NEU	NOR	MYO	NEU	NOR	MYO	NEU
NOR	94	3	3	95	2	3	96	2	2	97	2	1	97	2	1
MYO	12	88	0	12	88	0	11	89	0	10	90	0	11	88	1
NEU	19	1	80	18	1	81	14	1	85	13	1	86	11	0	89
NOR	94	3	3	95	2	3	97	2	1	97	1	2	97	1	2
MYO	10	89	1	11	89	0	9	90	1	10	90	0	11	89	0
NEU	17	1	82	16	1	83	13	2	85	12	1	87	10	0	90

EMG kayıtlarından alınan 300 MUAP'nin FEBANN için Tablo 5.3'te AR Yule, Tablo 5.4'te AR Burg, Tablo 5.5'te Kovaryans, Tablo 5.6'da İyileştirilmiş Kovaryans ve Tablo 5.7'de belirleyici özellikler kullanılarak elde edilen sınıflandırma başarı oranları gösterilmektedir. Her satırda o sınıflandırma birimine ait (normal, miyopatik veya nörojenik) 100 denegin sınıflandırma sonrasında nasıl değerlendirildiğinin dağılımı yer almaktadır. Yani Tablolardaki satırlar deneklerin gerçek durumlarını, sütunlar ise sistemin nasıl değerlendirdiğini göstermektedir. Doğru değerlendirmeyi gösteren sayılar koyu (bold) olarak yazılmıştır. Her grupta toplam 100 denek olduğundan, bu sayılar aynı zamanda başarı yüzdesini de vermektedir.

Benzer şekilde aynı 300 MUAP'nin CNN için başarı oranları AR Yule için Tablo 5.8'de, AR Burg için Tablo 5.9'da, Kovaryans için Tablo 5.10'da, İyileştirilmiş Kovaryans için Tablo 5.11'de ve belirleyici özellikler için Tablo 5.12'de verilmiştir. Ayrıca Tablo 5.13'te tüm başarı oranları bir arada gösterilmiştir.

Sınıflandırma başarı oranı, doğru olarak teşhis edilmiş MUAP sınıflarının, sınıflandırıcılar ve uzman bir nörofizyolojist tarafından teşhis edilmiş işaret içinde bulunan doğru MUAP sınıflarının sayısına oranı olarak tanımlanmıştır.

Yapay Sinir Ağı teşhis sisteminin performansı, deneme aşamasından sonra yeterli bulunmuş ve yapılacak çalışmalarla geliştirilerek klinik çalışmalar için kullanılabilir hale getirilebileceği kanısına varılmıştır.



## BÖLÜM 6. SONUÇLAR VE ÖNERİLER

### 6.1. Sonuçlar

EMG işaretlerinin açılımı ve sınıflandırmasını içeren bu çalışma ile, eşzamanlı alınan EMG işaretlerinden kullanışlı klinik veriler çıkartılabileceği gösterilmiştir. Değerlendirme için kullanılan bir EMG işaretler seti temel alındığında, Bileşik Sinir Ağlarının (CNN), denekleri, yeterli doğruluk ve klinik olarak kullanışlı parametre değerlerini hızlı bir şekilde elde etmesine göre sınıflandırdığı görülmüştür. Burada “klinik olarak kullanışlı” tanımı ile, bir kasın motor birimlerinin yapısı ve çalışmasına dair her yönüyle detaylı yapısını içerecek, kullanışlı parametre değerlerine sahip olması kastedilmektedir.

Sınıflandırmada kullanılan FEBANN, spektral analiz yöntemlerinden AR Yule ile, sağlıklı kişi için %94, miyopati hastası için %88 ve nöropati hastası için %80 başarımlar göstermiştir. Aynı değerler AR Burg ile sağlıklı kişi için %95, miyopati hastası için %88, nöropati hastası için %81; Kovaryans ile sağlıklı kişi için %96, miyopati hastası için %89, nöropati hastası için %85, İyileştirilmiş Kovaryans ile sağlıklı kişi için %97, miyopati hastası için %90, nöropati hastası için %86 ve belirleyici özelliklerin kullanılması ile sağlıklı kişi için %97, miyopati hastası için %88, nöropati hastası için %89 olarak elde edilmiştir.

Kullanılan diğer sınıflandırma yöntemi olan CNN, spektral analiz yöntemlerinden AR Yule ile, sağlıklı kişi için %94, miyopati hastası için %89 ve nöropati hastası için %82 başarımlar göstermiştir. Aynı değerler AR Burg ile sağlıklı kişi için %95, miyopati hastası için %89, nöropati hastası için %83; Kovaryans ile sağlıklı kişi için %97, miyopati hastası için %90, nöropati hastası için %85, İyileştirilmiş Kovaryans ile sağlıklı kişi için %97, miyopati hastası için %90, nöropati hastası için %87 ve

belirleyici özelliklerin kullanılması ile sağlıklı kişi için %97, miyopati hastası için %89, nöropati hastası için %90 olarak elde edilmiştir.

Her bir sınıf için sınıflandırma başarı oranı incelendiğinde, sağlıklı denekler grubu için en yüksek, nörojenik denekler grubu için ise en düşük başarı oranlarının yakalanmış olduğu görülmüştür. Bu durum uygulanan tüm önleme yöntemleri ve YSA yöntemleri için de geçerlidir. En düşük başarı oranına sahip nörojenik denekler grubuna en karmaşık ve değişken dalga formu şekiller atanmıştır. Buna ek olarak Tablo 5.13'den de görüldüğü üzere, CNN, FEBANN'a kıyasla tüm gruplarda başarı oranını ya korumuş veya arttırmıştır. Belirleyici özelliklerin kullanımı, özellikle başarı oranının düşük olduğu nörojenik denekler grubu için başarı oranını arttırmıştır. Genel olarak, her iki sınıflandırma metodunun da başarılı olarak sınıflandıramadığı küçük yüzdeli MUAP sınıflarında dalga formu değişkenliği -tutarsızlığı-gözlemlenmiştir.

## 6.2. Öneriler

Hastaları nöromasküler rahatsızlığı olan veya olmayan şekilde ayırabilen bir yapay sinir ağı, doktorlar için teşhis ve karar aşamasında büyük bir yardımcıdır. Bu çalışmada, tam spektrumlu EMG kayıtlarındaki nöromasküler rahatsızlıkların sınıflandırılabilmesi için bir CNN geliştirilmiştir. Bu metod, EMG nin AR spektrumunu CNN'a giriş, üç ayrı değer olan normal, miyopatik, nöropatik değerlerini ise çıkış olarak alır.

Bu uygulama, EMG işaretlerinin değerlendirilmesine bir objektiflik getirmiş ve otomatik bir sistem olarak tasarlanmış olması ile ilerideki klinik kullanımlarında büyük kolaylıklar sağlama yolunu açmıştır. Bunun yanında, uzman teşhis sisteminin gerçek-zamanlı kullanımının mümkün olması sayesinde parametrelerin sayısı ve çeşitliliği artırılarak teşhislerin daha doğru koyulabilmesi sağlanabilir. Bu çalışma sonucunda ortaya çıkarılabilecek bir "kara kutu" cihazı, nörofizyolojistlerin kullanımı için, EMG işaretlerini gerçek zamanlı olarak değerlendirerek EMG işaretlerinin hızlı ve doğru bir şekilde sınıflandırmasını yapabilir.

Sonuç olarak, bu çalışmada bahsedilen desen sınıflandırma teknikleri, EMG işaretlerinin tam otomatik olarak, kolayca, hızlı ve klinik ortamlarda kullanımına olanak sağlayacak güvenilirlikte doğru analizini mümkün kılacak bir sistemin geliştirilmesine ışık tutmaktadır. Gelecekte yapılacak çalışmalarda, bu çalışmada geliştirilen algoritmalar değerlendirilerek daha üst düzeydeki, EMG, kas biyopsisi, biyokimya ve moleküler gen bulgularının ve klinik verilerin birleştirilerek değerlendirildiği YSA temelli bir nöromasküler rahatsızlık teşhis sistemine adapte edilebilir.

## KAYNAKLAR

- [1] HUDSON D.L., COHEN M.E., "Neural Networks and Artificial Intelligence for Biomedical Engineering", IEEE Pres, 2000
- [2] DOMBAL F.T., LEAPER D., STANILAND J., MCCANN A., HORROCKS A., "Computer-aided diagnosis of Acute Abdominal Pain", British Medical Journal, 9-13, 1972
- [3] PATRICK E., STELMOCK F., SHEN L., "Review of Pattern Recognition in Medical Diagnosis and Consulting Relative to a New System Model", IEEE Trans. Syst. Man Cybern., SMC-4(1), 1-16, 1974
- [4] RAESIDE D.E., CHU W., "An Application of Pattern Recognition to Echocardiography", IEEE Trans. Syst. Man Cyber, SMC-8, 81-86, 1978
- [5] KULIKOWSKI C.A., "Pattern Recognition Approach to Medical Diagnosis", IEEE Trans. Sys. Sci. Cyber SS6(3), 173-178, 1979
- [6] COHEN M.E., HUDSON D.L., DEEDWANIA P.C., "Pattern Recognition Analysis of Coronary Artery Disease", American Association for Medical Systems and Informatics, 262-266, 1985
- [7] GORRY G.A., "Computer-assisted Clinical Decision-making", Methods of Information in Medicine, 12:45-51, 1973
- [8] JACKSON P.C., "Introduction to Artificial Intelligence, 2nd Enl. Ed.", Dover Publications, 1985
- [9] <http://th.informatik.uni-mannheim.de/people/tatli/resources/pdf/expertsystems.pdf>, (Kasım 2007)
- [10] GREENES R.A., PAPPALARDO A.N., NARBLE C.W., BARNETT G., "Design and Implementation of a Clinical Data Management System", Computers and Biomedical Research 2:469-485, 1969
- [11] SCHULTZ J.R., "PROMIS, Problem Oriented Medical Information System", Proc 3rd Illinois Conference on Medical Information Systems, 1-14, 1976
- [12] WARNER H.R., RUTHERFORD B., HOUTCHENS B., "A Sequential Approach to History Taking and Diagnosis", Comput. Biomed. Res., 5:256-262, 1972

- [13] BEN-BASSAT M., CARLSON R.W., PURI V.K., DAVENPORT M.D., SCHRIEVER J.A., LATIF M., SMITH R., PROTIGAL L., LIPNICK E., WEIL M., “Pattern-based Interactive Diagnosis of Multiple Disorders: The MEDUS System”, IEEE Trans. PAMI, PAMI-2:148-160, 1980
- [14] KANDEL A., LANGHOLZ G., “Hybrid Architectures for Intelligent Systems”, CRC Pres, 1992
- [15] CHRISTODOULOU C.I., PATTICHIS C.S., “Unsupervised pattern recognition for the classification of EMG signals”, IEEE Trans Biomed Eng 1999, 46(2):169–78
- [16] PATTICHIS C.S., PATTICHIS M.S., “Time-scale analysis of motor unit action potentials”, IEEE Trans Biomed Eng 1999, 46(11):1320–9.
- [17] STALBERG E., ANDREASSEN S., FALCK B., LANG H., ROSENFALCK A., TROJABORG W., “Quantitative analysis of individual motor unit potentials: a proposition for standardized terminology and criteria for measurement”, J Clin Neurophysiol 1986;3(4):313–48
- [18] PATTICHIS C.S., ELIA A.G., “Autoregressive and cepstral analyses of motor unit action potentials”, Med Eng Phys 1999;21:405–19
- [19] PFEIFFER G., KUNZE K., “Frequency analysis and duration of motor unit potentials: reliability and diagnostic usefulness”, Elect Clin Neurophysiol 1993;89:365–74.
- [20] DE MICHELE G., SELLO S., CARBONCINI M.C., ROSSI B., STRAMBI S., “Cross-correlation time–frequency analysis for multiple EMG signals in Parkinson’s disease: a wavelet approach”, Med Eng Phys 2003;25:361–9
- [21] PATTICHIS C.S., SCHIZAS C.N., MITTLETON L.T., “Neural network models in EMG diagnosis”, IEEE Trans Biomed Eng 1995;42:486–96
- [22] LOUDON G.H., JONES N.B., SEHMI A.S., “New signal processing techniques for the decomposition of EMG signals”, Med Biol Eng Comput 1992;Nov:591–9
- [23] HASSOUN M.H., WANG C., SPITZER A.R., “NNERVE: neural network extraction of repetitive vectors for electromyography—Part I: algorithm”, IEEE Trans Biomed Eng 1994, 41:1039–52
- [24] HASSOUN M.H., WANG C., SPITZER A.R., “NNERVE: neural network extraction of repetitive vectors for electromyography—Part II: performance analysis”, IEEE Trans Biomed Eng 1994, 41:1053–61
- [25] SCHIZAS C.N., PATTICHIS C.S., “Learning systems in biosignal analysis”, BioSystems 1997, 41:105–25.
- [26] A. SUBASI, M. YILMAZ AND H. R. OZCALIK, “Classification of EMG signals using wavelet neural network”, Journal of Neuroscience Methods, 156 (2006) 360–367.

- [27] GUO X., YANG P., CHEN L., WANG X., LI L., “Study of the Control Mechanism of Robot-Prosthesis Based-on the EMG Processed”, World Congress on INtelligent Control and Automation, 2006
- [28] DIAB O.M., MARQUE C., KHALIL M.A., “Unsupervised Classification in Uterine Electromyograph Signal: Toward The Detection of Preterm Birth”, Engineering in Medicine and Biology 27th Annual Conference, 2005
- [29] SALVADOR J., BRUIN H., “The Use of the Wavelet Transform in EMG M-Wave Pattern Classification”, EMBS Annual International Conference, 2006
- [30] CHU J.U., MOON I., MUN M.S., “A Real-Time EMG Pattern Recognition System Based on Linear-Nonlinear Feature Projection for a Multifunction Myoelectric Hand”, IEEE Trans. on Biomedical Eng., 11: 2232-2239, 2006
- [31] SU Y., FISHER M.H., WOLCZOWSKI A., BELL G.D., BRN D.J., GAO R.X., “Towards an EMG-Controlled Prosthetic Hand Using a 3-D Electromagnetic Positioning System”, IEEE Trans. on Instrument. and Masurement, 1:178-186, 2007
- [32] WANG J.Z., WANG R.C., LI F., JIANG M.W., JIN D.W., “EMG Signal Classification for Myoelectric Teleoperating a Dexterous Robot Hand”, Engineering in Medicine and Biology 27th Annual Conference, 2005
- [33] 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 27th Annual Conference, 2005
- [34] CAI L., WANG Z., ZHANG H., “An EMG Classification Method Based on Wavelet Transform”, Serving Humanity Advancing Technology, 1999
- [35] BRONZINO J.D., “The Biomedical Engineering Handbook, Second Edition, Volume I”, Boca Raton: FL., CRC Pres LLC, 2000
- [36] BRONZINO J.D., “Biomedical Engineering Fundamentals”, Boca Raton: FL., CRC Press, 2006
- [37] <http://www.tip2000.com/doktorlar/emg.html>, (Kasım 2007)
- [38] WEBSTER J.G., “Medical Instrumentation, 3rd Ed.”, Jonh Wiley & Sons, 1998
- [39] CARR J.J., BROWN J.M., “Introduction to Biomedical Equipment Technology, 4th Ed.”, Prentice Hall, New Jersey, 2000.
- [40] YAZGAN E., KORÜREK M., “Tıp Elektroniği”, İTÜ Rektörlüğü Yayınları, İstanbul, 1996.
- [41] JARMEY C., “The Concise Book of Muscles”, Lotus Publishing, Berkeley:CA, 2003
- [42] SÖYLEMEZOĞLU F., “Patolojisi Ders Notları”, Hacettepe Üniversitesi, Tıp Fakültesi.

- [43] USLU T., “Periferik Nöropatiler”,  
[http://romatizmatürk.com/jl/index.php?option=com\\_content&task=view&id=251&Itemid=45](http://romatizmatürk.com/jl/index.php?option=com_content&task=view&id=251&Itemid=45), (Kasım 2007)
- [44] [http://www.hastaokulu.org/HASTAOKULU/diyabet\\_sinir.asp](http://www.hastaokulu.org/HASTAOKULU/diyabet_sinir.asp), (Kasım 2007)
- [45] ÇELİKER A., “Periferik Nöropati”,  
<http://www.farma.hacettepe.edu.tr/hizbim/perifnoro.shtml>, (Kasım 2007)
- [46] HUGHES R.A.C., “Peripheral neuropathy”, 324: 466-69, BMJ. 2002.
- [47] <http://www.neuropathy.org/>, (Kasım 2007)
- [48] MUMENTHALER M., MATTLE H., “Neurology”, Thieme Medical Publishers, 2002.
- [49] HAYES M.H., “Statistical Digital Signal Processing and Modelling”, New York: John Wiley and Sons, 1996
- [50] SEMMLOW J.L., “Biosignal and Biomedical Image Processing, MATLAB-Based Applications”, New Jersey, CRC Pres, 2004.
- [51] PROAKIS J.G., DIMITRIS G.M., “Digital Signal Processing, Principles, Algorithms, and Applications, 3rd Ed.”, New Jersey: Prentice Hall, 1996
- [52] MITRA S.K., KAISER J.F., “Handbook for Digital Signal Processing”, New York: John Wiley and Sons, 1993
- [53] BRACEWELL R.N., “The Fourier Transform and Its Applications, 3rd Ed.”, New York: McGraw-Hill, 1999
- [54] BRIGHAM, E. O., “The Fast Fourier Transform and Application”, Englewood Cliffs, NJ: Prentice Hall, 1988
- [55] <http://mathworld.wolfram.com/FastFourierTransform.html>, (Kasım 2007)
- [56] JACKSON L.B., “Digital Filters and Signal Processing, 3rd Ed.”, Norwell MA: Kluwer Academic Publishers, 1996
- [57] <http://en.wikipedia.org/wiki/Periodogram>, (Kasım 2007)
- [58] LYNN A.P., FUERST W., “Introductory Digital Signal Processing with Computer Applications, 2nd Ed.”, England: John Wiley and Sons, 2004
- [59] AKIN M., KIYMIK M.K., “Application of Periodogram and AR Spectral Analysis to EEG Signals”, Journal of Medical Systems, 24(4):247–256 , 2000
- [60] ÜBEYLİ E.D., GÜLER İ., “Atardamarlardaki Daralma ve Tıkanıklığın Maksimum Olabilirlik Kestiriminin Kullanıldığı AR Metodu ile İncelenmesi”, G.Ü. Fen Bil. Derg.,16(2):375-385, 2003

- [61] FODOR I.K., BERRYMAN J.G., STARK P.B., “Comparison of autoregressive and multitaper spectral analysis for long time series”, Stanford Exploration Project Report 95, pp. 331-356, 1997.
- [62] AKAIKE H., “A new look at the statistical model identification”, IEEE Trans Autom Control, AC-19:716–23, 1974
- [63] TSENG S.Y., CHEN R.C., CHONG F.C., KUO T.S., “Evaluation of parametric methods in EEG signal analysis”, Med Eng Phys, 17:71–8, 1995
- [64] PARDEY J., ROBERTS S., TARASSENKO L., “A review of parametric modelling techniques for EEG analysis”, Med Eng Phys, 18(1):2–11, 1996.
- [65] MUTHUSWAMY J., THAKOR N.V., “Spectral analysis methods for neurological signals”, J Neurosci Meth, 83:1–14, 1998
- [66] KAY S.M., MARPLE S.L., “Spectrum analysis – a modern perspective”, Proc IEEE, 69:1380–419, 1981
- [67] ISAKSSON A., WENNERBERG A., ZETTERBERG L.H., “Computer analysis of EEG signals with 4 parametric models”, Proc IEEE, 69(4):451–61, 1981
- [68] NAZARPOUR K., “Surface EMG Signals Pattern Recognition Utilizing an Adaptive Crosstalk Suppression Preprocessor”, IEEE , 2005 ICSC Congress, 2005
- [69] CHAN F.H.Y., YANG Y.S., LAM F.K., ZHANG Y.T., PARKER P.A., “Fuzzy EMG Classification for Prosthesis Control”, IEEE Trans. Rehab. Eng., 8:395–311, 2000
- [70] SERPER Ö., “Uygulamalı İstatistik I”, Ezgi Kitabevi, Bursa, 2000
- [71] KÖKSAL B.A., “İstatistik Analiz Metodları”, Çağlayan Kitabevi, İstanbul, 1995
- [72] ÖZTEMEL E., “Yapay Sinir Ağları”, Papatya Yayıncılık, İstanbul, 2003.
- [73] MCCULLOCH W.S., PITTS W.A., “A Logical Calculus Of The Ideas Immanent In Nervous Activity”, Bulletin Of Mathematics And Biophysics, 5, 115-133, 1943.
- [74] FARLEY B.G., CLARK W.A., “Simulation of Self Organising Systems By Digital Computers”, IEE Transaction of Professional Group of Information Theory, PGIT-4, 76-84, 1954.
- [75] PANKAJ M.W., BENJAMIN W., “Artificial Neural Networks Concepts and Theory”, IEEE Computer Society Press, Washington, 1992.
- [76] KOHONEN T., “Correlation Matrix Memories”, IEEE Transaction on Comp., C-21(4), 353-359, 1972



- [77] ANDERSON J.A., “A Simple Neural Network Generating on Interactive Memory”, *Mathematical Biosciences*, 14, 197-220, 1972
- [78] EFE Ö., KAYNAK O., “Yapay Sinir Ağları ve Uygulamaları”, Boğaziçi Üniversitesi Yayınevi, İstanbul, 2000
- [79] ELMAS Ç., “Yapay Sinir Ağları”, Seçkin Yayıncılık, İstanbul, 2003
- [80] HAYKIN S., “Neural Networks, a Comprehensive foundation”, Prentice Hall, New Jersey, 1999
- [81] BOZKURT M.R., SUBASI A., KOKLUKAYA E., “Classification of EMG Signals by Using Ar Spectral Estimation Methods”, *WorldComp – ICAI 2007*, V.I, 369 – 372, 2007
- [82] HANSEN J.V., NELSON R.D., “Data mining of time series using stacked generalizers”, *Neurocomputing* 43 (2002), pp. 173–184.
- [83] TING K.M., WITTEN I.H., “Issues in stacked generalization”, *J. Artif. Intell. Res.* 10 (1999), pp.271–289.
- [84] SRIDHAR D.V., BARTLETT E.B., SEAGRAVE R.C., “An information theoretic approach for combining neural network process models”, *Neural Networks* 12 (1999) (6), pp. 915–926.
- [85] WOLPERT D.H., “Stacked generalization”, *Neural Networks* 5 (1992), pp. 241–259.

## **EKLER**

### **EK.A. NÖROPATİ VE MİYOPATİ**

#### **EK.A.1. Nöropati**

Nöropati, en genel anlamda, sinirlerin zedelenmesi sonucunda oluşan işlev bozukluklarıdır. Nöropatinin bir çok çeşidi vardır. Temelde periferik ve santral (çevresel ve merkezi) olmak üzere ikiye ayrılır. Bu çalışmada ilgilenilen nöropati çeşidi, periferik olanıdır. Periferik nöropati Söylemezoğlu tarafından kendi içinde yedi alt sınıfa ayrılmıştır. Periferik nöropatiler etiyolojik olarak; Otoimmün, Metabolik, Nutrisyonel, İskemik, Toksik, Paraneoplastik, Kalıtsal nöropatiler olarak sınıflandırılır. Bu alt sınıflar da kendi içinde ayrıca sınıflandırılmıştır [42].

Periferik sinir sistemi vücuttaki tüm hareketleri ve duyumları denetlemekle görevlidir. Motor sinirleri kullanarak hareketleri ve duyu sinirlerini kullanarak duyumları denetler. Sinir sistemine beyin sapından ve omurilik üzerinde birçok noktadan bağlı olan bu sinir sistemi vücudun en uç noktalarına ulaşan bir sinir şebekesidir. Periferik nöropatinin semptomları:

- El ve ayaklarda karıncalanma hissi
- El ve ayaklarda uyuşma
- Denge kaybı veya koordinasyon bozukluğu
- El ve ayaklarda zayıflık ve ağrı

olarak özetlenebilir [43, 44].

Periferik sinir sistemi, beynin, vücudun diğer kısımları ile (organlar, kaslar , damarlar ve deri) iletişimini sağlar. Bu iletişimde beynin emirleri ilgili bölgelere motor sinirleri ile iletilir ve gerekli bilgi duyum sinirleri ile beyne ulaştırılır.

Periferik sinirlerden birinin zedelenmesi vücudun o bölgesi ile beyin arasındaki iletişimi olumsuz yönde etkiler. İşte beyini ve omuriliği etkilemeden, periferik sinirlerin zedelenmesi ile oluşan nöropatiye periferik nöropati denir [43].

### **EK.A.1.1. Nöropati terminolojisi**

Periferik nöropati daha önce de belirtildiği gibi periferik sinirlerin zarar görmesi ile oluşan bozukluklardır. Bu bozuklukların kaynağı sadece periferik sinirleri etkileyen hastalık veya durumlar olabileceği gibi, vücudun diğer bölümlerini etkileyen hastalık veya durumlar da olabilir [45].

Eğer hastalığa sebep olan bozukluk sadece bir periferik sinirden kaynaklanıyorsa, buna mononöropati denir. Bu tip bozukluklara genellikle travma, sıkışma veya enflamasyon (yangı) neden olur. En bilinen örnekleri arasında Carpal Tunnel sendromu (bilek ve eli etkiler) veya yüz felci (Bell's Palsy) sayılabilir [46].

Eğer bozukluk farklı bölgelerdeki birden daha fazla sinir gövdesinden kaynaklanıyorsa ve bu bozukluk diyabet gibi yaygın bir hastalığa bağlı olarak oluşmuşsa buna mononöritis multipleks denir [45].

Eğer bozukluk çok sayıda periferik nöropatiyi kapsıyorsa ve bu bozukluk yaygın ve simetrik ise bu duruma Polinöropati adı verilir. Bozukluktan etkilenen sinirler Motor ve duyu sinirleri ise sensorimotor nöropati denir. Bu nöropati genellikle vücudun uç kısımları olan el ve ayaklarda başlar.

Enfeksiyon veya bağışıklık sistemi nedeniyle sinirlerde enflamasyon oluşmasına nörit denir. Bir çok sinirden oluşan yapıya pleksus denir. Eğer bu yapıda bir enflamasyon oluşursa, buna da pleksit adı verilir [45].

### **EK.A.1.2. Periferik nöropati**

İnsan vücudunda sinir sistemi iki temel alt sistemden oluşur. Bunların birincisi beyin ve omurilikten oluşan Merkezi Sinir Sistemidir. İkincisi ise merkezi sinir sistemini

vücuda (kaslara, iç organlara ve cilde) bağlayan sinirlerden oluşan Çevresel (Periferik) Sinir Sistemidir.

Periferik sinir sisteminin en küçük parçası sinir hücresidir. Sinir hücresine "nöron" adı verilir. Görevi, elektriksel olarak vücut üzerinde bilgi akışını sağlamaktır. Nöronlar gövde ve "akson" adı verilen bir kuyruk olmak üzere iki ana bölümden oluşur. Aksonlar, nöronun gövdesi ile kaslar, cilt ve iç organlardaki "reseptör" (alıcı) denenen sinir terminalleri arasında elektrik uyarımlarını aktarırlar.

Aksonlar demetler şeklinde görev yaparlar ve bu demetler motor (hareket), sensoryel (duyusal) ve otonomik olmak üzere üçe ayrılır. İstemli hareketlerle ilgili olan motor sinirlerinde hücrelerin gövdesi omurilik içinde bulunur ve omurilikten gelen elektriksel uyarımları iskelet kaslarındaki özel reseptörlere iletirler. Dış dünyadaki cisimlerin özelliklerinin ve şekillerinin anlaşılmasını sağlayan, boşlukta organların yerlerinin bilinmesini sağlayan ve ağrıyı hisseden duyu sinirlerinde ise hücre gövdeleri duyu gangliyonları denilen yapılar içinde bulunur. Bu sinirler vücuttaki duyu reseptörlerinden aldıkları elektriksel uyarımları merkezi sinir sistemine iletirler. İnsan bilinci dışında çalışan ve solunum, kalp atımı, kan basıncı, sindirim sistemi ve cinsel işlevler gibi istem dışı görevleri kontrol eden otonomik sinirlerin hücrelerinin gövdeleri tüm vücuda yayılmıştır [45, 46].

### **EK.A.1.3. Periferik nöropatinin belirtileri**

Nöropatiler aniden ortaya çıkabilecekleri gibi, gelişimleri yıllara da yayılabilir. Nöropatinin çeşidine göre hastalık belirtileri değişmekle birlikte ilk ve en temel belirtiler güçsüzlük, uyuşukluk veya ağrıdır [43, 44, 45, 46].

- Kol veya bacaklarda güçsüzlük: Motor sinirlerdeki bozulmalara bağlı olan bu belirtide yürüme veya koşmada zorluk, hareketlerde ağırlaşma, çabuk yorulma, kas krampları görülebilir. Kol ve ellere bağlı olarak paket taşımada, kavanoz açmada, kapı tokmaklarını çevirmede veya saç taramada problemlerle karşılaşılabilir.

- Uyuşukluk, acıma-yanma, ağrı: Duyu sinirlerinin bozulmasına bağlı gelişen bu belirtiler uyuşukluk, acı ve yanma hissi, soğuk, çimdikleme duyumu, batma hissi, elektrik şoku veya vızıltı gibi kendini gösterebilir. Genellikle geceleri şiddetli olur.
- Pozisyon duyumunun kaybı: Bu durumda hasta ayaklarının konumundan emin olamadığı için yürüme ve denge sorunları görülür.
- "Eldiven-çorap duyumu": Hasta elleri ve ayakları tümüyle çıplak olduğu halde, duyu sinirlerinin tahribatı sonucu, çorap, terlik ya da eldiven giymiş gibi hisseder.
- Otonomik bozukluk belirtileri: Kabızlık, ishal, cinsel işlev bozukluğu, ciltte incelme, kolayca yaralanma, yaraların zor iyileşmesi gibi belirtiler gözlenir. Ayaktayken baş dönmesi olabilir.

#### **EK.A.1.4. Periferik nöropatinin teşhisi**

Periferik nöropatinin Söylemezoğlu tarafından yedi ayrı alt sınıfa ayrıldığından bahsedilmiştir. Bu türler çok genel olarak “kazanılmış” ya da “kalıtsal” olarak sınıflandırılabilir. Kalıtsal olan genler vasıtasıyla kişinin ailesinden aldığı rahatsızlıklardır. Kazanılmış nöropatiler ise nedenlerine ve belirtilerine göre sınıflandırılır. Bazı nöropatilerin nedeni belirlenememiştir, bazılarında da henüz tam bir tanım yapılamamıştır, bu tip nöropatilere “idiyopatik nöropati” adı verilir [45].

Nörolog tanı koyabilmek için öncelikle hastanın öyküsünü dikkatli bir şekilde alır ve nörolojik muayeneler yapar. Bu aşamada çeşitli laboratuvar testlerine de ihtiyaç duyabilir. Üç aşamalı araştırma yapılır. Birinci aşama araştırma olarak, idrar tahlili, tam kan sayımı, eritrosit sedimentasyon hızı, açlık kan şekeri, böbrek-karaciğer-tiroid fonksiyonları incelenmesi gibi tetkikler yapılır.

Hastaya birinci aşama testlerle tanı konulamamışsa ikinci aşamaya geçilir. Bu testler içinde en önemlisi nörofizyolojik testler, diğer bir deyişle EMG ölçümüdür. İkinci aşama testlerde EMG ölçümü haricinde biyokimya tetkikleri ve akciğer filmi istenebilir. Üçüncü aşamada ise beyin omurilik sıvısı incelemesi ve moleküler genetik testler yapılır [46].

Sinirin elektriksel özelliklerinin belirlenebilmesi için elektromiyografi (EMG) ve sinir iletim çalışmaları yapılması gerekir. Bu sayede anormal sinirlerin dağılımı belirlenebilir, sorunun aksonla mı miyelin kılıfı ile ilgili olduğu anlaşılabilir. Bunlar haricinde sinir ve kas biyopsisi de nöropatinin türü ve nedeni hakkında çok değerli bilgiler sağlar. Ayrıca omurilikte de testler yapılarak enfeksiyon veya enflamasyon ayırt edilebilir [45].

#### **EK.A.1.5. Periferik nöropati'nin tedavisi**

Nöropatilerde, bir çok diğer hastalıkta olduğu gibi, hastanın da kendi tedavisinde etkin bir şekilde rol alması gereklidir. Konuyla ilgili olarak doğru kaynaklardan bilgiler edinilmeli ve benzer durumdaki hastalarla iletişim kurularak bilgi paylaşımı sağlanmalıdır. Genellikle çoğu kişi bu hastalığın farkına varamadığından bu hastalığa sessiz hastalık da denmektedir [45, 47].

Tedavide temel hedef hastalığın nedenini ortadan kaldırmak ve hastalık belirtilerini iyileştirmektir. Nöropatiyi oluşturan nedene bağlı olarak, tedavi nöropatiyi yavaşlatabileceği gibi, durdurması veya geriletmesi de mümkündür. Örneğin, vitamin eksikliğine bağlı durumlarda ağızdan veya enjeksiyon yöntemi ile ek vitamin desteği sağlanarak hastalığın kötüye gitmesi engellenebilir. Enfeksiyonlara bağlı durumlarda ise antibiyotik veya antiviral ilaçlarla rahatsızlığın tamamen tedavi edilebilmesi mümkündür [45].

Nöropatinin en temel belirtilerinden olan ağrının giderilmesi için çeşitli ağrı kesici ilaçlardan, güçsüzlük probleminin giderilmesinde ise fizik tedavi yöntemleri ve protez tipi araçlardan yararlanır.

Hastalığın ilerlemesi durdurulduktan sonra sinirlerin yeniden canlanması mümkündür. Sinirlerdeki hasar ne kadar azsa iyileşme de o derece iyi olacaktır. Bu yüzden nöropatilerde teşhisin mümkün olduğunca erken konulup, tedaviye de mümkün olan en kısa sürede başlanması çok önemlidir. Bir çok nöropati çeşidinin ilerlemesi yıllara yayılmış olarak yavaş bir seyirde gerçekleşmesi sebebiyle ilk

zamanlarda hasta bir rahatsızlık hissetmeyebilir. Ancak hasta kendisini rahatsız hissetmese de tedavi arayışına girmeli ve rahatsızlığının tedavisi için geç kalmamalıdır. Başlangıçta hafif ve geri döndürülebilir olan sinir hasarı, tedavi edilmediği takdirde yayılıp ciddi ve geri dönülmez hasarlara dönüşebilir [44, 45, 47].

Ağrının tedavisi zordur. Burada amaç ağrıyı dayanılabilecek seviyeye indirmektir. Nöropatinin nedeni belirlendikten sonra en uygun tedavi seçenekleri geliştirilebilecektir.

İlaçlı tedavi: İlaçlı tedavi konusunda bir fikir birliği yoktur. Bir ilacın ne kadar etkin olduğunun belirlenmesinde kaç hastaya uygulandığı ve uygulanan doz miktarı bilgileri çok önemlidir. Genel kanı olarak en yararlı görülen ilaçlar trisiklik antidepresanlar ve antikonvülsanlardır (epilepsi ilaçları) [45, 46].

Antidepresan kullanımı ağrıyı ve depresif belirtileri azaltır. Diğer bir avantajı da sersemlik hali oluşturarak hastanın uyumasını sağlamasıdır.

Nöropatik ağrıda ortaya çıkan nöronların aşırı uyarılabilir hassasiyete gelmesi hali, moleküler değişikliklerle de uyumlu olarak, epilepsi hastalığıyla benzer özelliklere sahip olduğu için, bu tür ağrıların tedavisinde epilepsi ilaçları (antikonvülsan) da yaygın olarak tercih edilmektedir.

Bunlar haricinde diğer ilaçlarla tedaviye cevap alınmadığında opioid kullanımı, bazı nöropatilerde cilde sürülen ağrı kesicilerin tercih edilmesi, incinmeye bağlı nöropatilerde kortikosteroid kullanımı tercih edilebilen ilaç çeşitleridir [45, 46].

Eğer hasta ilaç tedavisine ve fizik tedaviye cevap vermiyorsa, bu gibi durumlarda bölgesel anestezi uygulanabilir. Bölgesel anestezi kullanımında amaç ağrıyı gidermek ve tedaviyi kolaylaştırmaktır [45, 47].

Başka bir tedavi şekli ise Nöromodülasyon olarak adlandırılır. Bu yöntemde Merkezi sinir aksisine elektriksel veya kimyasal bir uyarı verilerek, merkezi ağrı yollarının etkilenmesi veya değiştirilmesi hedeflenir. Bu yöntem umut verici olmakla birlikte, çok zor bir uygulama olduğundan diğer tekniklerin başarılı olmadığı durumlarda tercih edilmektedirler [45, 46].

## **EK.A.2. Myopati**

Myopatiler primer kas hastalıklarıdır. Klinik belirtileri içinde kas güçsüzlüğü, atrofi, psödohipertrofi, refleks kaybı, hipotoni, bazen de kontraktür, kas spazmları veya myotonik reaksiyonlar sayılabilir. Myopatilerde en önemli tanı testleri serum kas enzim konsantrasyonları ölçümleri, elektromyografi (EMG), elektronörografi, kas biyopsisi ve genom analizleridir. Myopatinin etiyolojisi distrofik, enfeksiyöz, enflamatuar, metabolik veya myotonik olabilir. Ayrıca sistemik hastalıklar, ilaçlar, dışarıdan alınan maddeler veya vücudun herhangi bir yerinden kaynaklanan tümoral süreçler de myopati sebebi olabilir. Nöromüsküler ileti bozuklukları da – en yaygını myastenia gravis hastalığıdır- myopati tipleri arasında değerlendirilir. Myopatiler sebebine göre tedavi edilir [48].

Myopatilerin primer kas hastalıkları olduğu belirtilmişti. Her ne kadar bazı myopatilerin diğer organ sistemlerinde de ilave belirtileri olsa da myopatilerin en önde gelen özelliği kas tutulumudur [48].

### **EK.A.2.1. Klinik belirtiler ve fiziksel bulgular**

**Kas güçsüzlüğü:** Myopatideki kas güçsüzlüğü genellikle simetrik, kök kaslarını uç kaslardan daha çok etkiler ve yüz, ense ve boyun kaslarını da tutabilir. Nadiren asimetrik bazı kas grupları veya uç kaslar da etkilenebilir. Güçsüzlük, duruş anormalliklerine neden olabilir. Merdiven çıkmak, sandalye üzerine çıkmak, oturur ya da yatar pozisyonda iken ayağa kalkmak, bir nesneyi kaldırmak, kolları uzatıp beklemek veya saç taramak bu kişiler için zor olabilir. Ciddi güçsüzlük durumlarında hasta, başkalarının yardımına bağımlı olarak yaşamını sürdürmek durumundadır. Myopatilerin birçok tipinde kas güçsüzlüğü sürekli, bazı myopatilerde ise ataklar şeklinde gelen, egzersizle ortaya çıkabilen veya gün içinde aktiviteye bağlı olarak ağırlaşabilen kas güçsüzlükleri görülebilir. Ayırıcı tanıda kas güçsüzlüğünün başlangıç yaşı ve ilerleme hızı önemlidir [48].



Kas atrofi: Kas hacminde azalma, kasın hacimce zayıflaması anlamına gelir. Myopatilerde çoğu zaman kas atrofi vardır. Eğer kasın kaybettiği hacmi yağ doku veya bağ doku doldurduysa kas atrofi fark edilemeyebilir.

Psödohipertrofi: Yalancı hacim artışı demektir. Kas hacminin artmış gibi görünmesi anlamına gelir. Besleme yetersizliğine bağlı kas dejenerasyonlarında kaybedilen kasların yerini fazladan yağ ve bağ dokunun alması ile olur. Daha çok omuz ve baldır kaslarında görülür.

Gerçek kas hipertrofi: Kas liflerinin kendiliğinden sürekli aktivitesi ile giden myopatilerde görülür.

Kas tonusu: Kasın kasılma gerginliği demektir. Myopatilerde normal veya azalmış olabilir.

Refleksler: Kas güçsüzlüğü ile paralel olarak refleksler azalmış veya tamamen kaybedilmiş olabilir.

Ağrı: Sadece birkaç myopati tipinde ağrı görülür. Bunlar enfeksiyöz, iskemik veya metabolik kaynaklı ağrılar olabilir.

Myotonik reaksiyon: Myotonilerin birçok formunda vardır. İskelet kaslarının bir kasılma sonrasında hemen gevşeyememesi şeklinde tarif edilebilir.

Kontraktür: Bir kasın kısalması demektir. Eklem hastalıklarına benzer. Pasif hareketi sınırlar. Kontrakte olmuş kas elektromyografik aktivite göstermez.

Kas spazmları: Bir veya daha fazla kasınağrılıkasılmasıdır. Kendiliğinden veya hareket sırasında oluşabilir. Elektromyografide çok sayıda kas lifinde yüksek frekanslı deşarjlar görülür. Kas spazmları myopatilere spesifik değildir [48].

### **EK.A.2.2. Myopati tanısında yardımcı testler**

Myopati gösterilebilmesi ve nörolojik bozukluklardan ayırt edilebilmesi için aşağıdaki yardımcı teslerden yararlanılabilir:

Elektromyografi (EMG) ve elektronörografi (ENG): Myopati ve diğer nörolojik bozuklukları atırt etmede en faydalı yardımcıdır. Bu işlemler, primer kas hastalıklarını göstermede kullanılan, noninvazif veya minimal invazif yollardır. Myotoni ve nöromusküler ileti bozukluklarının tanısında da önemlidirler [48].

Kas biyopsisi: Myojen veya nörojen süreçlerin ayırdedilmesinde ve spesifik tanıların konulmasında yardımcıdır.

Bunların yanında

- Serum kas enzimleri
- Serum immün çalışmaları
- Dolaşımdaki antikorların gösterilmesi
- Serum elektrolitleri
- Beyin omurilik sıvısı çalışmaları
- Bilgisayarlı tomografi ve manyetik rezonans görüntüleme
- Genetik analiz

tetkikleri de tanıda kullanılan yardımcı testler içindedir [48].

### **EK.A.2.3. Myopatilerin sınıflandırılması**

- Musküler distrofiler
- Spinal müsküler atrofi ve diğer motor nöron hastalıkları
- Myotoniler ve periodik paraliziler
- Metabolik myopatiler
- Mitokondrial myopatiler ve ensefalomyopatiler
- Konjenital myopatiler
- Enflamatuar myopatiler
- Endokrin hastalıklarda görülen myopatiler

- Toksik ve ilaca baęlı ortaya ıkan myopatiler
- Nöromüsküler ileti bozuklukları
- Tümörler
- Travma
- İskemi

#### **EK.A.2.4. Myopatilerin tedavileri**

Myopatiler geniş bir hastalık grubu olup her bir sınıf içinde çok sayıda ayrı hastalık bulunmaktadır. Tedaviler hastalıklara göre deęişir. Asıl tedaviler nedeni ortadan kaldırmaya yöneliktir. Metabolik bozukluklara baęlı miyopatilerde metabolizmayı düzeltmek, endokrin problemlerde altta yatan endokrin hastalığın tedavisini sağlamak, tümöre baęlı miyopatilerde tümörle mücadele etmek buna örnek olarak gösterilebilir. Nedenin ortadan kaldırılması mümkün olmayan durumlarda ise hedef; hastalığın ilerlemesini yavaşlatmak, hastanın daha az zarar görmesini sağlamak, daha uzun süre başkasının yardımına muhta olmadan yaşamasını sağlamaktır.

Bunun için:


- İla tedavileri
- Fizik tedavi
- Egzersizler
- Ortopedik araçlar
- Cerrahi düzeltme operasyonlar

Gibi tedavi yöntemleri uygulanabilir [48].

Kök hücre transferi ve gen tedavileri de halen araştırma safhasında olan tedavi yöntemleri arasındadır [48].

## EK.B. EMG Ölçümünde Kullanılan Elektrotlar

Biyolojik işaretlerin vücuttan ilk alınmaları sırasında ve vücut dokularına ölçüm amaçlı elektrik akımı verilirken vücut ile ölçme düzeni arasında iletişimi sağlamak amacıyla kullanılan arabirim elemanlarına elektrot denmektedir. Elektrotlar, iyon akımını elektron akımına veya tersi şekilde elektron akımını iyon akımına dönüştürerek bu işlemi gerçekleştirirler. Bu dönüştürme işlemi, elektrot metali ile elektrolitin temasta bulunduğu ara yüzeyde gerçekleşir. Bu ara yüzeyin elektrot tarafında akım taşıyıcı olarak elektronlar ve elektrolit tarafında ise katyon ( $C^+$ ) ve anyonlar ( $A^-$ ) bulunur. Bahsi geçen bu arayüzeyde iki çeşit olay ile karşılaşılır. Ya elektrot atomları elektronlarını kaybederek elektrolit içinde katyon yani pozitif iyon durumuna gelirler veya aksi olarak elektrolit içindeki elektrot malzemesinden olan katyonlar, elektrottan elektron çalarak elektrot yüzeyine birikirler. Elektrottan akım çekilmediği sürece, birer kimyasal reaksiyon olan bu iki işlem, birbirlerini dengeleyecek şekilde sürüp gider ve buna termodinamik denge denir [38, 39]. Bu durum Şekil EK.B.1.' de gösterilmiştir.



Şekil EK.B.1. Elektrot-Elektrolit arayüzeyi ve akımın elektrottan elektrolite doğru olduğu durum için iyon hareketleri

Ölçüm cihazları ne kadar iyi olursa olsun, vücuttan alacağı işareti elektrot vasıtasıyla elde eder. Elektrottan kaynaklanan bir bozulma veya işaretin yanlış alınması yanlış veya yetersiz ölçümlere sebep olabilir. Bu yüzden ölçümler için kullanılacak elektrotların çeşidi, fiziksel ölçüsü, bağlanacağı yer ve arada kullanılan jel gibi etkenler en iyi ve doğru şekilde seçilmelidir. Bunlar haricinde elektrot seçiminde elektrodun üretildiği materyalin kimyasal yapısı, elektriksel iletkenliği ve mekanik dayanıklılığı da önemli etkenlerdir. Elektrotlarda, kimyasal tepkimeye girmemeleri, zehirli bileşenleri olmaması, iyi birer iletken olmaları sebebiyle altın, platin, gümüş,

tungsten, tantal ve alüminyum gibi metaller en çok tercih edilen metallerdir. Bakır iyi bir iletken olmasına karşın, vücutla tepkimeye girdiği ve zehirli atık verebildiği için elektrotlarda kullanılmaz [35, 36, 40].

EMG ölçümlerinde temel olarak yüzey elektrotları ve iğne elektrotlar olmak üzere iki tip elektrot kullanılır. Yüzey elektrotları daha çok deri yüzeyine yakın kaslar için kullanılırken, iğne elektrotlar daha hassas ölçümler için ve deri yüzeyinden uzakta kalan kaslar için kullanılırlar [39, 40].

### **EK.B.1. Yüzey Elektrotları**

EMG işaretlerinin deri yüzeyinden alınmasında bu tip elektrotlar kullanılırlar. Elektrot uygulanmadan önce, uygulanacak alan kir, yağ ve mümkünse kıllardan arındırılmalı, ayrıca iletkenliği artırmak amacıyla ilgili bölgeye elektrolit olarak jel uygulanmalıdır.

Yüzey elektrotlarının da kendi içinde bir çok alt grubu olmakla beraber EMG ölçümleri için en çok kullanılanı “Metal plaka elektrodu” olarak isimlendirilmiş olanıdır. Bu elektrotların adından da anlaşılacağı gibi metal bir yüzeyleri vardır ve deri üzerine tutturularak uygulanırlar. Bu tutturma işlemi kimi zaman yapışkan bantlarla kimi zaman da esnek kayışlarla olabilir. Bu tip elektrotlarda metal olarak genellikle Ni-Ag (nikel-gümüş) alaşımı kullanılır. Bu elektrotların temas yüzeyleri geniş olduğu için empedansları küçüktür [40].




Şekil EK.B.2. EMG Yüzey elektrotları

Yüzey elektrotlarına diğer örnekler emici düzenli elektrotlar, gezici elektrotlar, tek kullanımlık elektrotlar, esnek elektrotlar ve kuru elektrotlardır. Ancak sayılan bu elektrotlar EMG ölçümlerinde çok tercih edilmezler. Şekil EK.B.2.'de bir çift yüzey elektrot gösterilmiştir.

### EK.B.2. İğne Elektrotlar


EMG ölçümlerinde kullanılan bir diğer elektrot çeşidi iğne elektrottur. Sınıflandırma olarak “dahili elektrotlar” sınıfında olan iğne elektrotlar, kaslara batırılmak suretiyle uygulanır. Diğer bir deyişle, işaretleri vücudun yüzeyinden değil, bizzat kasın içinden alırlar. Bu yüzden elektrolit amaçlı jel kullanımına ihtiyaçları yoktur. Elektrolit görevini hücre sıvısı görür. Dahili elektrotlar ile çok daha kararlı işaretler alınabilmesine karşın, kullanımı hastayı rahatsız ettiğinden yüzey elektrotlarının yetersiz kaldığı durumlarda kullanılırlar. Şekil EK.B.3.'te bir çift iğne elektrot görülmektedir.



Şekil EK.B.3. EMG iğne elektrotları

### EK.B.3. Elektrotların Elektriksel Karakteristikleri

Şekil EK.B.4.'de örnek olarak bir yüzey elektrodun elektriksel eşdeğer devre modeli verilmiştir.



Şekil EK.B.4. Yüzey elektrodun elektriksel eşdeğer devre modeli

Burada,  $C_d$  elektrot-elektrolit ara yüzündeki yük birikiminin sebep olduğu kapasite,  $R_d$  bu kapasitenin kaçak direnci,  $E_{he}$  elektrotun yarı hücre potansiyeline karşılık gelen gerilim kaynağı,  $R_s$  ise elektrolit direncidir.

## ÖZGEÇMİŞ

Mehmet Recep Bozkurt 1976 yılında İstanbul / Fatih'te doğdu. İlk ve orta öğrenimini aynı ilçede tamamladıktan sonra 1993 senesinde İstanbul Şehremini Lisesinden mezun oldu. Aynı yıl Sakarya Üniversitesi Mühendislik Fakültesi, Elektrik – Elektronik Mühendisliği Bölümünde lisans eğitimine başladı. 1998 yılı Şubat ayında bu bölümden mezun oldu. İstanbul'da bir bilgisayar firmasında mezun olmadan bir yıl önce yarı-zamanlı olarak başladığı teknik servis sorumluluğu görevini, mezun olduktan sonra teknik servis müdürü olarak bir buçuk sene daha devam ettirdi. 1998 yılında Sakarya Üniversitesi Fen Bilimleri Enstitüsü Elektrik – Elektronik Ana Bilim Dalında yüksek lisansa başladı. 1999 yılında İstanbul'da özel sektördeki işinden istifa ederek Sakarya Üniversitesi Mühendislik Fakültesinde Araştırma Görevlisi olarak görev yapmaya başladı. 2001 senesinde yine aynı üniversite, enstitü ve ana bilim dalında doktora yapmaya başlayan yazar, evli ve iki çocuk babasıdır.