

**BAŞKENT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
BİYOMEDİKAL MÜHENDİSLİĞİ ANABİLİMDALI
BİYOMEDİKAL MÜHENDİSLİĞİ TEZLİ YÜKSEK LİSANS
PROGRAMI**

**ELEKTROMİYOGRAFİ SİNYALLERİNDEN MİYOPATİ,
NÖROPATİ VE SAĞLIKLI GRUPLARIN SINIFLANDIRILMASI**

YÜKSEK LİSANS TEZİ

HAZIRLAYAN

ATAKAN IŞIK

ANKARA-2020

**BAŞKENT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
BİYOMEDİKAL MÜHENDİSLİĞİ ANABİLİM DALI
BİYOMEDİKAL MÜHENDİSLİĞİ TEZLİ YÜKSEK LİSANS
PROGRAMI**

**ELEKTROMİYOGRAFİ SİNYALLERİNDEN MİYOPATİ,
NÖROPATİ VE SAĞLIKLI GRUPLARIN SINIFLANDIRILMASI**

YÜKSEK LİSANS TEZİ

HAZIRLAYAN

ATAKAN IŞIK

TEZ DANIŞMANI

DR. ÖĞR. ÜYESİ MEHMET FEYZİ AKŞAHİN

ANKARA-2020

BAŞKENT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Biyomedikal Mühendisliği Anabilim Dalı Biyomedikal Mühendisliği Tezli Yüksek Lisans Programı çerçevesinde Atakan Işık tarafından hazırlanan bu çalışma, aşağıdaki jüri tarafından Yüksek Lisans Tezi olarak kabul edilmiştir.

Tez Savunma Tarihi: 13/01/2020


Tez Adı: Elektromiyografi Sinyallerinden Miyopati, Nöropati ve Sağlıklı Grupların Sınıflandırılması

Tez Jüri Üyeleri (Unvanı, Adı - Soyadı, Kurumu)

Prof. Dr. İbrahim Erkutlu
Gaziantep Üniversitesi

Dr. Öğr. Üyesi Mehmet Feyzi Akşahin
Başkent Üniversitesi

Dr. Öğr. Üyesi Tansel Uyar
Başkent Üniversitesi

İmza


ONAY

Prof. Dr. Ömer Faruk Elaldı
Fen Bilimleri Enstitüsü Müdürü

Tarih:

BAŞKENT ÜNİVERSİTESİ
FEN BİLİMLER ENSTİTÜSÜ
YÜKSEK LİSANS TEZ ÇALIŞMASI ORJİNALLİK RAPORU

Tarih: 27 / 01 / 2020

Öğrencinin Adı, Soyadı : Atakan IŞIK

Öğrencinin Numarası : 21710317

Anabilim Dalı : Biyomedikal Mühendisliği

Programı : Tezli Yüksek Lisans Programı

Danışmanın Unvanı/Adı, Soyadı : Dr. Öğr. Üyesi Mehmet Feyzi AKŞAHİN

Tez Başlığı : Elektromiyografi Sinyallerinden, Miyopati, Nöropati ve Sağlıklı Grupların Sınıflandırılması

Yukarıda başlığı belirtilen Yüksek Lisans tez çalışmamın; Giriş, Ana Bölümler ve Sonuç Bölümünden oluşan, toplam 68 sayfalık kısmına ilişkin, 08/01 / 2020 tarihinde şahsım/tez danışmanım tarafından "Turnitin" adlı intihal tespit programından aşağıda belirtilen filtrelemeler uygulanarak alınmış olan orijinallik raporuna göre, tezimin benzerlik oranı 84 dir.

Uygulanan filtrelemeler:

1. Kaynakça hariç
2. Alıntılar hariç
3. Beş (5) kelimeden daha az örtüşme içeren metin kısımları hariç

"Başkent Üniversitesi Enstitüleri Tez Çalışması Orijinallik Raporu Alınması ve Kullanılması Usul ve Esaslarını" inceledim ve bu uygulama esaslarında belirtilen azami benzerlik oranlarına tez çalışmamın herhangi bir intihal içermediğini; aksinin tespit edileceği muhtemel durumda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi ve yukarıda vermiş olduğum bilgilerin doğru olduğunu beyan ederim.

Öğrenci İmzası: 

Onay

27 / 01 / 2020

Dr. Öğr. Üyesi, Mehmet Feyzi AKŞAHİN



TEŐEKKÖR

Yüksek lisans eğitimim ve tez çalışma sürecim boyunca kıymetli bilgi, birikim, ve tecrübeleri ile bana yol gösteren ve destek olan değerli danışman hocam Dr. Öğr. Üyesi Mehmet Feyzi AKŐAHİN'E,

Bu süreçte desteklerini esirgemeyen saygıdeğer hocalarıma,

Maddi ve manevi her anlamda yanımda olan sevgili aileme,

Zor zamanlarda beni diri tutan Başkent Üniversitesi Mühendislik Fakültesi C-408/C Ofisinde çalışan arkadaşlarıma,

İhtiyacım olduğunda yardımlarını esirgemeyen çalışma arkadaşlarıma,

Her daim beni destekleyen Asena Karaduman'a,

En içten teşekkürlerimi sunarım.

ÖZET

Atakan IŞIK

EMG SİNYALLERİNDEN SAĞLIKLI, MİYOPATİ, NÖROPATİ GRUPLARININ SINIFLANDIRILMASI

Başkent Üniversitesi Fen Bilimleri Enstitüsü

Biyomedikal Mühendisliği Anabilim Dalı

2020

Elektromiyografi(EMG) kasların elektriksel aktivitelerini incelemek amacıyla kullanılan bir tekniktir. Özellikle vücutta bulunan çizgili kas veya iskelet kası olarak isimlendirilmiş kas dokusunun fizyolojik durumunu incelemekte kullanılmaktadır.

EMG sinyali elde edilirken temelde 2 farklı elektrot kullanılır. Bunlardan biri yüzey elektrotlar iken diğer ise iğne elektrot diye adlandırılan invaziv uygulanan bir elektrot çeşididir. Tıbbi olarak en sık kullanılan iğne elektrottur. EMG sinyali kasların her bir iğciğinde oluşan sinirsel aksiyon potansiyellerinin toplanmasıyla oluşmaktadır. Bu sinyal miyopati(kas hastalığı) ve nöropati(sinir hastalığı) bulguları olan hastalarda sağlıklı bir bireye göre değişiklik göstermektedir.

Bu çalışmada EMGLAB adlı veri tabanından alınan skorlanmış klinik EMG verilerinin zaman ve Frekans düzlemindeki analizleri ile miyopati ve nöropati skorlaması yapabilen bir karar destek sistemi oluşturulmaya çalışılmıştır. Zaman düzleminde ortalama mutlak değer, sıfır geçiş oranı ve willison genliği analizleri yapılmıştır. Frekans düzleminde güç spektral yoğunluğu için analizler yapılmıştır. Bunun yanı sıra ayırık dalgacık dönüşümü yöntemi ile EMG sinyali alt bantlarına ayrılmış ve 2. yaklaşık alt bantın frekans analizi welch yöntemiyle güç spektral yoğunluğu hesaplamak olmuş ve bu güç spektral yoğunluğunda çeşitli öznitelikler çıkarılmıştır. Bu öznitelikler kullanılarak eğitilen farklı makine öğrenme yöntemleri ile başarılı sınıflandırma sonuçları elde edilmiştir.

ANAHTAR KELİMELEER: Biyomedikal İşaret İşleme, Biyosinyal, Miyopati, Elektromiyografi, Nöropati.

ABSTRACT

Atakan IŞIK

CLASSIFICATION OF HEALTHY, MYOPATHY, NEUROPATHY GROUPS FROM EMG SIGNALS

Başkent University Institute of Science and Engineering

The Department of Biomedical Engineering

2020

Electromyography (EMG) is a technique used to analyse the electrical activities of muscles. It is especially used to examine the physiological state of muscle tissue called striated muscle or skeletal muscle in the body.

Two different electrodes can be used to obtain the EMG signal. One of them is surface electrodes and the other is an invasive electrode type called needle electrode. The most common medical use is the needle electrode. The EMG signal is the sum of the nerve action potentials that occur in each spindle of the muscles. This signal varies according to a healthy individual in patients with signs of myopathy (muscle disease) and neuropathy (nerve disease).

In this study, a decision support system capable of scoring myopathy and neuropathy with time and frequency analysis of the clinical EMG data obtained from the EMGLAB database was attempted. Mean absolute value, zero crossing rate and willison amplitude analyzes were performed in time plane. Analyzes were made for power spectral density on the frequency plane. In addition, the EMG signal is separated into sub-bands by discrete wavelet transform method and the frequency analysis of the second approximate subband is to calculate the power spectral density by the welch method and various attributes are extracted from this power spectral density. Successful classification results were obtained with different machine learning methods trained using these attributes.

KEY WORDS: Biomedical Signal Processing, Biosignal, Myopathy, Electromyography, Neuropathy.

İÇİNDEKİLER

Sayfa

ÖZET.....	i
ABSTRACT.....	ii
İÇİNDEKİLER.....	iii
ÇİZELGELER LİSTESİ.....	vi
ŞEKİLLER LİSTESİ.....	vii
SİMGELER VE KISALTMALAR LİSTESİ.....	x
1. GİRİŞ.....	1
1.1. Tezin Amacı.....	1
1.2. Tezin Hedefi.....	1
1.3. Literatür Özeti.....	1
1.4. Tezin Organizasyonu.....	3
2. GENEL BİLGİLER.....	4
2.1 Kaslar ve Çeşitleri.....	4
2.1.1. Düz kaslar.....	4
2.1.2. Çizgili kaslar.....	4
2.1.3. Kalp kası.....	5
2.2. Kas Dokusunun Yapısı.....	5
2.3. Kas Kasılması.....	6
2.4. Kasılma Çeşitleri.....	8
2.4.1. Konsantrik kasılma.....	8
2.4.2. Eksantrik kasılma.....	8
2.4.3. İzometrik kasılma.....	8
2.5. Elektromiyografi(EMG).....	9
2.5.1. EMG yöntemleri.....	10

2.5.1.1. Yüzey EMG.....	10
2.5.1.2. İğne EMG.....	10
2.5.2. Elektrot çeşitleri.....	10
2.5.2.1. Monopolar elektrot.....	10
2.5.2.2. Bipolar elektrot.....	10
2.5.2.3. Konsentrik elektrot.....	11
2.6. Miyopati Ve Nöropati.....	11
2.6.1. Miyopati.....	12
2.6.2. Nöropati.....	13
2.7. Miyopati Ve Nöropatinin EMG Sinyalindeki Etkisi.....	14
3.MATERYAL VE METOD.....	16
3.1. Verilerin Elde Edilmesi.....	17
3.2. Filtreleme İşlemi.....	17
3.3. Zaman Bölgesi Analizi.....	19
3.3.1. Karelerin ortalamasının karekökü(RMS).....	19
3.3.2. Ortalama mutlak değer(MAV).....	20
3.3.3. Sıfır geçiş oranı (ZCR).....	20
3.3.4. Willison genliği(WA).....	21
3.3.5. Varyans(VAR).....	21
3.4. Frekans Bölgesi Analizi.....	21
3.4.1. Foruier dönüşümü.....	22
3.4.1.1. Sürekli-zamanlı foruier dönüşümü.....	22
3.4.1.2. Ayrık-zamanlı foruier dönüşümü.....	22
3.4.2. Güç spektral yoğunluğu.....	23
3.4.2.1. Parametrik olmayan yöntemler.....	24
3.4.3. Ortalama ve medyan frekans.....	25

3.5. Dalgacık Dönüşümü.....	26
3.5.1. Ayrık dalgacık dönüşümü(ADD).....	26
3.6. Sınıflandırıcılar.....	28
3.6.1. K-en yakın komşuluk (K-NN).....	28
3.6.2. Destek vektör makinesi(SVM).....	30
3.6.3. Karar ağaçları.....	32
3.6.4. Sınıflandırıcı istatistikleri.....	33
3.6.5. K-kat validasyon.....	35
4.BULGULAR.....	36
4.1. Sinyallerin Ön işleme.....	36
4.1.1. EMG sinyallerinin frekans tayfları.....	36
4.1.2. Filtreleme işlemi.....	38
4.2. Sinyallerin MAV Analizi.....	39
4.3. Sinyallerin Sıfır Geçiş Oranı Analizi.....	40
4.4. Sinyallerin Willison Genliği Analizi.....	41
4.5. Sinyallerin GSY Analizi.....	42
4.6. Ayrık Dalgacık Dönüşümü Analizi.....	45
4.7. Öznitelik Çıkarımı.....	48
5.SINIFLANDIRICI SONUÇLARI.....	50
5.1. Sınıflandırıcıların Eğitim ve Test Sonuçları.....	50
6.SONUÇ VE ÖNERİLER	66
KAYNAKLAR.....	68

ÇİZELGELER LİSTESİ

Sayfa

Çizelge 5.1.	90 sinyal verisiyle eğitilen Fine KNN sınıflandırıcı eğitim sonucu karmaşıklık matrisi istatistikleri.....	51
Çizelge 5.2.	90 sinyal verisiyle eğitilen Bagged Tree sınıflandırıcı eğitim sonucu karmaşıklık matrisi istatistikler.....	52
Çizelge 5.3.	Bagged Tree Sınıflandırıcının Eğitim Sonucu Normal ve Miyopatik Sınıflandırmasının İstatistikleri.....	53
Çizelge 5.4.	Bagged Tree Sınıflandırıcının Test Sonucu Normal ve Miyopatik Sınıflandırmasının İstatistiksel Hesaplamaları.....	54
Çizelge 5.5.	Cubic SVM Sınıflandırıcının Eğitim Sonucu Normal ve Nöropatik Sınıflandırmasının İstatistiksel Hesaplamaları.....	55
Çizelge 5.6.	Cubic SVM Sınıflandırıcının Test Sonucu Normal ve Nöropatik Sınıflandırmasının İstatistiksel Hesaplamaları.....	56
Çizelge 5.7.	Linear SVM ve Fine KNN sınıflandırıcıların eğitimi sonucu miyopatik ve nöropatik sınıflandırmasının istatistiksel hesaplaması.....	57
Çizelge 5.8.	Linear SVM ve Fine KNN sınıflandırıcıların test sonucu miyopatik ve nöropatik sınıflandırmasının istatistiksel hesaplaması.....	58
Çizelge 5.9.	Fine KNN sınıflandırıcının eğitim sonucu normal, miyopatik ve nöropatik sınıflandırmasının istatistiksel hesaplaması.....	59
Çizelge 5.10.	Linear SVM sınıflandırıcının eğitim sonucu normal, miyopatik ve nöropatik sınıflandırmasının istatistiksel hesaplaması.....	60
Çizelge 5.11.	Fine KNN sınıflandırıcının test sonucu normal, miyopatik ve nöropatik sınıflandırmasının istatistiksel hesaplaması.....	61
Çizelge 5.12.	Linear SVM sınıflandırıcının test sonucu normal, miyopatik ve nöropatik sınıflandırmasının istatistiksel hesaplaması.....	62
Çizelge 5.13.	Tüm Sınıflandırıcı İstatistikleri.....	64

ŞEKİLLER LİSTESİ

Sayfa

Şekil 2.1.	a)Düz kasın şematik gösterimi b)mikroskop altında bir düz kas görünümü....	4
Şekil 2.2.	Bir iskelet kası hücresinin yapısı.....	5
Şekil 2.3.	Çizgili kasın mikroskop altında görüntüsü.....	6
Şekil2.4.	Sinir-Kas kavşağı gösterimi.....	7
Şekil 2.5.	Bir kas fiberi ve bantları.....	7
Şekil 2.6.	Kasılma Şekillerinin Şematik Gösterimi.....	9
Şekil 2.7.	Bir EMG sistemi şematik görüntüsü.....	9
Şekil 2.8.	Elektrotların Şematik Gösterimleri A)Tekli Fiber İğne, B) Konsentrik İğne,C)Monopolar İğne, D) Makro İğne, E) Bipolar Yüzey Elektrot.....	11
Şekil 2.9.	Sağlıklı, Miyopatik ve Nöropatik EMG sinyallerinin 0.5 sn lik görüntüleri.	15
Şekil 3.1.	Yapılan işlemlerin şematik gösterimi (kırmızı çerçeve EMG sinyalinin A2 alt bandından mor çerçeve EMG sinyalinin kendisinden bulunan öznitelikleri göstermektedir.).....	16
Şekil 3.2.	Oluşturulan Filtrenin Genlik Cevabı.....	18
Şekil 3.3.	Oluşturulan Filtrenin Faz Cevabı.....	19
Şekil 3.4.	Bir ADD ayrışım ağacı.....	27
Şekil 3.5.	Çalışmada yapılan ADD ayrışım ağacı.....	28
Şekil 3.6.	Öznitelik Uzayında Yeni Bir Veri(Yeşil).....	29
Şekil 3.7.	K=3 değeri için belirlenen yeni verinin komşu verileri.....	29
Şekil 3.8.	Komşu sayısına göre yeni sınıflandırılan veri.....	30
Şekil 3.9.	Öznitelik Uzayında Destek Vektörlerinin Görüntüsü.....	31
Şekil 3.10.	Optimal Aşırı Düzlemin Bulunması.....	31
Şekil 3.11.	Kernel Hilesi Sonucu Veri Seti Görüntüsü.....	32
Şekil 3.12.	Basit Bir Karar Ağacı.....	33
Şekil 3.13.	Karmaşıklık Matris.....	34
Şekil 3.14.	K=5 değeri için K-kat validasyon veri ayırımı görüntüsü.....	35
Şekil 4.1.	Normal bir EMG sinyalinin Frekans Tayfı.....	37
Şekil 4.2.	Miyopatik bir EMG sinyalinin Frekans Tayfı.....	37
Şekil 4.3.	Nöropatik bir EMG sinyalinin frekans tayfı.....	38
Şekil 4.4.	Nöropatik bir EMG sinyalinin filtre uygulanmadan önce(kırmızı) ve	

	sonraki(mavi) görüntüsü.....	39
Şekil 4.5.	90 EMG sinyalinden elde edilen MAV Verilerinin Dağılımı.....	40
Şekil 4.6.	90 EMG sinyalinden elde edilen ZCR Verilerinin Dağılımı.....	41
Şekil 4.7.	90 EMG sinyalinden elde edilen WA Verilerinin Dağılımı.....	42
Şekil 4.8.	Sağlıklı bir EMG sinyalinin Welch Yöntemiyle Hesaplanmış GSY görüntüsü.....	43
Şekil 4.9.	Miyopatik bir EMG sinyalinin Welch Yöntemiyle Hesaplanmış GSY görüntüsü.....	44
Şekil 4.10.	Nöropatik bir EMG sinyalinin Welch Yöntemiyle Hesaplanmış GSY görüntüsü.....	44
Şekil 4.11.	Sağlıklı Bir EMG Sinyalinin 2. Yaklaşık (A2) alt bandının Görüntüsü.....	45
Şekil 4.12.	Miyopatik Bir EMG sinyalinin 2. Yaklaşık (A2) alt bandının görüntüsü.....	46
Şekil 4.13.	Nöropatik Bir EMG Sinyalinin 2. Yaklaşık (A2) Alt Bandının Görüntüsü...	46
Şekil 4.14.	Sağlıklı Bir EMG Sinyalinin A2 alt bandının GSY görüntüsü.....	47
Şekil 4.15.	Miyopatik bir EMG Sinyalinin A2 alt bandının GSY görüntüsü.....	47
Şekil 4.16.	Nöropatik bir EMG sinyalinin A2 alt bandının GSY görüntüsü.....	48
Şekil 4.17.	Öznitelik çıkarımının şematik gösterimi.....	49
Şekil 5.1.	90 EMG sinyalinden elde edilen öznitelik verileriyle eğitilen Fine KNN sınıflandırıcının eğitim sonucu karmaşıklık matrisi.....	51
Şekil 5.2.	90 EMG sinyalinden elde edilen öznitelik verileriyle eğitilen Bagged Tree sınıflandırıcının eğitim sonucu karmaşıklık matrisi.....	52
Şekil 5.3.	Normal ve Miyopati sınıfları için eğitilen bagged tree sınıflandırıcının karmaşıklık matrisi.....	53
Şekil 5.4.	Bagged tree algoritmasının test sonucu karmaşıklık matrisi.....	54
Şekil 5.5.	Normal ve nöropati sınıfları için eğitilen Cubic SVM sınıflandırıcının karmaşıklık matrisi.....	55
Şekil 5.6.	Cubic SVM algoritmasının test sonucu karmaşıklık matrisi.....	56
Şekil 5.7.	Miyopati ve Nöropati sınıfları için eğitilen Linear SVM ve Fine KNN algoritmalarının karmaşıklık matrisi.....	57
Şekil 5.8.	Linear SVM ve Fine K-NN algoritmalarının test sonucu karmaşıklık matrisi.....	58
Şekil 5.9.	Eğitim sonucu Fine K-NN algoritmasının karmaşıklık matrisi.....	59
Şekil 5.10.	Eğitimi sonucu Linear SVM algoritmasını karmaşıklık matrisi.....	60

Şekil 5.11.	Fine-KNN algoritmasının 27 sinyalden elde edilen özniteliklerle test karmaşıklık matrisi.....	61
Şekil 5.12.	Linear SVM algoritmasının 27 sinyalden elde edilen özniteliklerle test karmaşıklık matrisi.....	62



SİMGELER VE KISALTMALAR LİSTESİ

A	Yaklaşık Alt Bant
A_n	Spektrum sinyalinin n. Örnekteki Genlik Değeri
a	Dalgacık Değişim Değeri
ACh	Asetilkolin
ADD	Ayrık Dalgacık Dönüşümü
ALS	Amiyotrofik Lateral Skleroz
b	Dalgacık Ölçeklendirme Değeri
D	Detaylı Alt Bant
DN	Doğru Negatif
DP	Doğru Pozitif
DTFT	Ayrık Zamanlı Foruier Dönüşümü
EMG	Elektromiyografi
e	Euler Sayısı
$f(x)$	Sürekli Sinyal Gösterimi
$f(t)$	Sürekli Zamanlı Sinyal
$F(\omega)$	Sürekli Sinyalin Foruier Dönüşümü
f_n	Spektrum sinyalinin n. Örnekteki Frekans Değeri
FFT	Hızlı Foruier Dönüşümü
GSY	Güç Spektral Yoğunluğu
K-NN	En Yakın K Komuşuluğu
MAV	Ortalama Mutlak Değer
N	Negatif
N	Toplam Örnek Sayısı
n	Örnek Numarası
RMS	Karelerin Ortalamasının Karekökü
P	Pozitif
R_{xx}	Sinyalin Özilinti Fonksiyonu
SDD	Sürekli Dalgacık Dönüşümü
SVM	Destek Vektör Makinesi
VAR	Varyans
WA	Willison Genliği
YP	Yanlış Pozitif
YN	Yanlış Negatif
ZCR	Sıfır Geçiş Oranı
ϕ^*	Dalgacık Fonksiyonunun Konjugesi

1. GİRİŞ

Tezin giriş kısmında çalışmanın genel amacından bahsedilecek literatürde daha önce benzer çalışmalara değinilecek ve tezin organizasyonu söylenecektir.

1.1 .Tezin Amacı

Vücuttaki kasların kasılıp gevşemeleri sonucu bir takım elektriksel aktivite meydana gelmektedir. Bu elektriksel aktivite elektrotlar aracılığıyla kaydedilir ve oluşan sinyale Elektromiyografi(EMG) sinyali denir. EMG sinyali sağlıklı, miyopatik, nöropatik kaslar için değişkenlik göstermektedir. Bu tez kapsamında yapılan çalışmalarla sağlıklı, miyopatik ve nöropatik kasların EMG sinyallerinden bulunan öznelilikler kullanılarak; sınıflandırıcı algoritmaları yardımıyla ayırt edilmesi amaçlanmıştır. Bu sayede teşhisi zor ve subjektiflik gerektiren miyopati ve nöropati hastalıklarının saptanmasında kolaylık sağlayacak bir karar destek algoritması geliştirmek bu çalışmanın ana motivasyonudur.

1.2. Tezin Hedefi

Tez çalışmasında miyopati ve nöropati rahatsızlıklarının EMG sinyalinde oluşturduğu farklılıkları bulmak hedeflerden bir tanesidir. EMG sinyallerindeki bu farklılıkları kullanarak miyopati ve nöropati hastalıklarını sınıflandırmak amaçlanmaktadır.

1.3. Literatür Özeti

EMG sinyallerinden miyopati ve/veya nöropati sınıflandırması için literatürde yapılmış bazı çalışmalar şunlardır;

Nikolic et. al. doktora tezi çalışmasında EMG sinyallerini aksiyon potansiyellerine ayırıştırarak miyopati ve als hastalarının bu tez içerisinde de daha sonra bahsedilecek olan motor ünite aksiyon potansiyelleri ve ateşleme paternlerinin farklılıklarını ortaya koymuş ve EMG sinyallerinin miyopati ve ALS hastaları için farklılık gösterdiğini söylemiştir.

Bhoi et.al. ve arkadaşları yaptıkları çalışmada sağlıklı ve miyopatiye sahip EMG sinyallerini incelemiş ve bu sinyallerin frekans düzleminde farklılıklar gösterdiğini söylemişlerdir. Yapılan çalışmada Güç Spektral Yoğunluklarının miyopatik ve sağlıklı EMG sinyalleri için ayır edici olabileceği söylenmiştir.

Paganoni et. al. yaptığı çalışmada miyopati hastalığına sahip kasların elektrodagnostik olarak incelemiş ve miyopati hastalığı için EMG sinyalindeki

farklılıkları her bir miyopati sınıfı için incelemiştir. Yapılan araştırma sonucunda EMG sinyallerindeki motor ünite aksiyon potansiyellerinin sağlıklı kaslara göre farklılık gösterdiği sonucuna varılsa da bu sonuç her miyopati türü için geçerli olmadığı kanısına varılmıştır.

Archana et. al. ve arkadaşları yaptıkları çalışmada sağlıklı, miyopatik, nöropatik EMG sinyalleri hem zaman hem de frekans düzleminde analiz edilmiş yapılan çalışma sonucunda 8 adet istatistiki veri öznitelik olarak bulmuşlardır. Çalışma EMG sinyallerinin her 3 tip sinyal içinde ayırt edici olabileceğini söylemiştir.

Subasi et. al. ve arkadaşları yaptıkları çalışmada sağlıklı, miyopati, nöropatik EMG sinyalleri ayrık dalgacık dönüşümü kullanarak analiz etmiş ve EMG sinyalinin 2 kademeli ayrık dalgacık dönüşümü sonucu ortaya çıkan, yüksek frekans bileşenlerini içeren 2. detaylı alt bandından öznitelikler çıkarmışlardır. Bu öznitelikler bir optimizasyon algoritmasıyla desteklenen sınıflandırıcılar ile sınıflandırılmıştır. Çalışma sonucunda k-NN(k-nearest neighbor) ve SVM sınıflandırma algoritmaları kullanılarak sırasıyla %95.17 ve %97.41 doğrulukla sınıflandırma yapılmıştır.

Belkhou et. al. ve arkadaşları yaptıkları çalışmada sağlıklı ve miyopatik EMG sinyalleri sürekli dalgacık dönüşümü yöntemiyle analiz etmiş ve buldukları öznitelikler ile k-NN ve SVM algoritmaları ile sınıflandırılmıştır. K-NN algoritmasında %91.11 doğruluk elde ederken SVM algoritması ile %91.01 doğruluk elde edilmiştir.

Küçük vd. Doktora tezi çalışmasında sağlıklı, miyopati ve ALS hastalarından elde edilen EMG sinyallerini aksiyon potansiyellerine ayırtmış ve bu aksiyon potansiyellerinin zaman ve frekans düzleminden elde ettiği öznitelik verileri ile Destek Vektör makineleri, K-en yakın komşuluk, Diskriminant analizi sınıflandırma algoritmaları ile sınıflandırmıştır.

Bu çalışmadan literatürden farklı olarak EMG sinyallerinin GSY sini parçalara bölerek altta kalan alanlar öznitelik olarak kullanılmıştır. Bunu yanı sıra hem EMG nin kendisinden hem de ayrık dalgacık dönüşümü ile 2. yaklaşık alt bandından öznitelikler bulunmuştur. Bu zaman kadar yapılan benzer çalışmalar arasında hem zaman düzleminde hem frekans düzleminde hem de ayrık dalgacık dönüşümüyle elde edilen alt bantların zaman ve frekans analizleriyle elde edilen özniteliklerin kullanıldığı orijinal bir çalışma olma başarısını gösterebilmektedir.

1.4. Tezin Organizasyonu

Tez içerisinde 2. bölümde kasların yapıları, kasılma çeşitleri, ve kas fizyolojisi hakkında bilgiler verilmiş daha sonra EMG sinyalinin nasıl oluştuğuna ve elde edilme yöntemlerine değinilmiştir. Sonrasında miyopati ve nöropati hakkında bilgiler verilecek ve bu hastalıkların EMG sinyallerindeki etkilerinden bahsedilmiştir. 3. bölümde ise kullanılan EMG sinyallerinin özelliklerinden bahsedilecek daha sonra bu sinyallerin analizinde kullanılan yöntemlerden söz edilmiştir. Bölüm 4'te bu yöntemler kullanılarak yapılan analizlerin sonuçlarından ve sinyallerden çıkarılan zaman ve frekans düzleminde özniteliklerden bahsedilmiştir. Yine bu bölümde kullanılan sınıflandırma yöntemleri anlatılmıştır. 5. bölümde kullanılan sınıflandırıcı algoritmalarının sonuçlarına değinilmiş ve 6. bölümde yapılan çalışmanın tartışması yapılmıştır.


2. GENEL BİLGİLER

2.1. Kaslar ve Çeşitleri

Kaslar vücudumuzu mekanik hareketi sağlayan dokulardır. Kemiklerle birlikte vücuda şekil verirler. Bir kas kasılma ve gevşeme özelliğine sahip hücrelerden oluşmaktadır. Bu hücreler uyarıyı alır ve kasılma şeklinde yanıt verir. Kaslar uzayabilir veya kısalabilirler. Temel olarak bunu hücre içi kimyasal enerjiyi mekanik enerjiye çevirerek yaparlar. Yapı ve çalışma şekillerine göre vücudumuzda temel olarak 3 çeşit kas bulunmaktadır[1]. Bunlar iç organlarımızda bulunan ve otonom olarak kontrol edilen düz kaslar, iskeletimize bağlı olan ve vücudun hareketini sağlayan çizgili kaslar ve özel bir kas dokusu olan kalp kasıdır.

2.1.1. Düz kaslar

Düz Kaslar otonom yani istemsiz sinir sisteminin yönetiminde olduklarından istemli kasılamazlar. Bu nedenle istemsiz kaslarda denilmektedir. Yavaş kasılır geç yorulurlar. Hücre çekirdekleri büyük ve 1 veya 2 tanedir. Lifleri kısadır. Otonom sinir sisteminin sempatik ve parasempatik alt sistemlerine bağlı çalışırlar [2]. Vücutta damarlar, mide, mesane, bağırsak gibi daha çok iç organların yapısında bulunmaktadır.



Şekil 2.1.a) Düz kasın şematik gösterimi b) mikroskop altında bir düz kas görünümü [3].

2.1.2. Çizgili kaslar

Çizgili kaslar vücut iskelet sistemiyle birlikte hareket etmesini sağlayan kas dokularıdır. Bu sebeple iskelet kası olarak da bilinmektedirler. Somatik yani istemli sinir sistemi tarafından kontrol edilir. İstemli veya istemsiz kasılabilirler. Hızlı kasılır çabuk

yorulurlar. Çekirdekleri küçük ve çok sayıdadır. Glikojen depolayabilirler. Çok fazla enerjiye ihtiyaç duyarlar [4].


2.1.3. Kalp kası

Vücutta yalnızca kalpte bulunan bir kas türüdür. Fizyolojik olarak çizgili kaslara daha çok benzemektedir fakat otonom sinir sistemi tarafından kontrol edilir. Ritmiktir rastgele veya geliş güzel kasılamaz. Çabuk kasılır fakat hiç yorulmaz. Çekirdekleri çok sayıda ve küçüktür [1].


Bu çalışmada çizgili kasların kasılmaları sonucu oluşan elektriksel aktiviteler incelenmiştir.

2.2. Kas Dokusunun Yapısı

Kas dokusu bir çok kas hücresinin bir araya gelmesiyle oluşur. Kas dokusunda hücreler arası madde bulunmaz ve kas hücrelerine ait yapıların özel isimleri bulunmaktadır. Örneğin bir kas hücresinin stoplazmasının sarkoplazma, zarına sarkolemma, endoplazmik retikulumuna sarkoplazmik retikulum denilmektedir [5]. Bir kas hücresi bir çok miyofibrilden oluşmaktadır. Miyofibriller kasılıp gevşemeyi sağlayan protein iplikçikleridir [4]. Bu iplikçikler iskelet ve kalp kasında düzenli bir dizilime sahip olduğundan mikroskop altında çizgili bir yapı şeklinde görünürler. Bu miyofibrillerin etrafı bağ doku ile sarılıdır ve bu bağ doku aktin ve miyozinden oluşmaktadır. Bunlara miyoflament denilir. Miyoflamentler tekrarlı bir şekilde miyofibril boyunca bulunurlar. Bu alt birimlere sarkomer denir.



Şekil 2.2. Bir iskelet kası hücresinin yapısı [4].




Şekil 2.3.Çizgili kasın mikroskop altında görüntüsü [1].

2.3. Kas Kasılması

Kas hücreleri sinir hücrelerinin uyarımları ile kasılır. Her bir kas hücresine gelen bir sinir bulunmaktadır. Bu sinir kas hücresine geldiğinde kas dokusu üzerine dağılan bir kavşak oluşturmaktadır. Bu kavşak sayesinde uyarım kas hücrelerine iletilir. Bu kavşağa sinir-kas kavşağı denmektedir. Sinir-kas kavşağında sinir ile kas arasındaki bölgeye motor son plaka denir. Bu yapı eğer uyarı almamaya başlarsa ortalama 1 sene içerisinde geri dönülmez olarak işlevini kaybetmektedir. Uyarıyı alan kas hücresi kasılmayı gerçekleştirmektedir. Kasılma beyinden gelen uyarım ile başlar ve uyarı sinir-kas kavşağına ulaştığında sinirin uç kısmındaki zarda bulunan voltaj kapılı kalsiyum kanalları açılarak hücre içine kalsiyum girişini sağlar. Kalsiyum asetilkolin(ACh) keseciklerini hareketlendirerek asetilkolin(ACh) salınımına sebep olur. ACh kas hücresindeki ACh reseptörlerine tutunarak bu reseptörleri aktive eder. Bu reseptörler aynı zamanda bir katyon kanalı olduğundan bu esnada hücreye sodyum(Na) girişi olurken bir miktar potasyum(K) hücreden dışarı çıkar. Bu iyon değişimi kas hücresinin depolarize olmasını sağlar. Depolarizasyon hücre zarı boyunca yayılarak komşu hücrelerdeki sodyum kanallarının açılmasını sağlar. Bunun sonucunda bir aksiyon potansiyeli oluşur ve bu aksiyon potansiyeli kasılmayı gerçekleştirmek üzere zar boyunca ilerler [12].

Uyarılma-Kasılma Eşleşmesi-Sinir Kas Kavşağı



Şekil2.4. Sinir-Kas kavşağı gösterimi [6].


Kasılma esnasından miyofibriller aktin ve miyozinden oluşan yapıları sayesinde birbirini üzerinde kayarak kasılmayı sağlarlar. Bu olaya kayan filamentler mekanizması denmektedir. Kasılma esnasında aktin ve miyozinlerin gözlenen geometrik yapılarında bir takım değişiklikler meydana gelmektedir. Bunlar:

-H bandının kaybolması

-Z çizgilerinin birbirine yaklaşması

-I bandının daralması

-Kasın boyunun kısalması ve eninin genişlemesi gibi durumlardır [10].



Şekil 2.5. Bir kas fibri ve bantları [4].

2.4. Kasılma Çeşitleri

Daha önce bahsedildiği üzere kas hücreleri aktin ve miyozinlerin birbiri üstünde kayarak hareket etmesiyle kasılmayı sağlarlar. Bu olay esnasında kasın boyu değişebilir veya değişmeyebilir. Her ne kadar kasılma ifadesi kasın boyunun kısaldığını ifade etse bile bu her zaman geçerli değildir [7]. Kasılmanın birkaç çeşidi bulunmaktadır ve bu çeşitlerin kasılma esnasında kas dokusunun gösterdiği değişimle ilintilendirilmiştir. Konsantrik kasılma, eksantrik kasılma ve izometrik kasılma en temel 3 kasılma çeşididir. Konsantrik ve eksantrik kasılma literatürde izotonik kasılma olarak da geçmektedir.

2.4.1. Konsantrik kasılma

Kasılma gerçekleşirken kasın boyunun kısaldığı kasılma türüne konsantrik kasılma denir. Bu olay kayan filamentler mekanizmasıyla kas boyunca gerçekleşmektedir. Bu tarz kasılmalar aynı zamanda kasın bağlı olduğu eklemin açısını değiştirmektedir. Örnek vermek gerekirse biceps kasının konsantrik bir kasılma gerçekleştirmesi kasın boyunun kısılmasına ve ön kol bölgesinin dirsek ekleminde omuza yaklaşmasına sebep olmaktadır[7].


2.4.2. Eksantrik kasılma

Kas boyunun uzamasıyla meydana gelen kasılmaya eksantrik kasılma denmektedir. Sağlıklı bir birey için konsantrik hareketin aksine gönüllü veya gönülsüz gerçekleşebilmektedir. Eksantrik kasılma esnasında kas üstünde bulunan yükten daha fazla bir güç uygulamak suretiyle boyu uzar [7]. Örnek vermek gerekirse biceps kasının eksantrik bir şekilde kasılması önkol bölgesini omuzdan uzaklaştıracaktır. Bu hareket istemsiz de gerçekleşebilir. Örneğin kasın üzerinde yük kaldırabileceği bir seviyeyi geçtikten sonra kas istemsiz bir şekilde eksantrik kasılma gerçekleştirip üzerindeki yükü serbest bırakmak isteyecektir.

2.4.3. İzometrik kasılma

İzotonik kasılmaların aksine izometrik kasılma esnasında kas bir güç uygulamakta ama boyunda değişim olmamaktadır. El ve ön kol kasları bu kasılmayı gerçekleştiren tipik kaslara en iyi örnektir [7]. Kasılma esnasında güç uygulansa da eklemlerde bir hareket değişimi gözlenmez. Kısa bir deyişle kasılma olur fakat eklem açıları değişmez.


Bu kasılmalar sonucu oluşan elektriksel aktiviteye elektromyogram bu elektriksel aktiviteyi kaydetmeye yarayan cihaz elektromiyografi cihazı denir.



Şekil 2.6. Kasılma Şekillerinin Şematik Gösterimi[8]

2.5. Elektromiyografi(EMG)

Elektromiyografi belirli bir kasın kasılması esnasında o kasın elektriksel aktivitesini incelemek için kullanılan yöntemdir. Daha önce de bahsedildiği üzere kas kasılması esnasında kas hücresinde bir depolarizasyon olur ve bu depolarizasyon aksiyon potansiyelinin oluşumuna sebep olmaktadır. EMG yöntemi hücrelerde oluşan bu elektriksel aktiviteyi kaydeder ve kasın çalışması hakkında bilgi verir.



Şekil 2.7. Bir EMG sistemi şematik görüntüsü[9]

2.5.1. EMG yöntemleri

EMG 2 farklı çeşit yöntemle yapılabilir. Bunlardan biri yüzey-EMG olarak adlandırılan deri üstünden bir elektrot ile gerçekleştirilen yöntemdir. Diğerisi ise klinikte daha çok tercih edilen ve invaziv(vücut içi) bir metot olan iğne elektrotlar ile gerçekleştirilen yöntemdir.

2.5.1.1. Yüzey EMG

Yüzey-EMG yönteminde kasılma esnasında elektriksel aktiviteyi kaydetmek için kullanılan elektrotla deri üstüne yerleştirilmektedir. Elektrotun yeri son derece önemlidir. Zira kasın elektriksel aktivitesinin tam anlamıyla incelenebilmesi için elektrot motor-kas kavşağı ile tendonun kas ile birleştiği bölümün arasına yerleştirilmelidir [10].

2.5.1.2. İğne EMG

İğne EMG metotunda kasların elektriksel aktivitesi kas dokusuna temas eden ve vücut içine batırılan bir iğne elektrot yardımıyla gerçekleşmektedir. Yüzey-EMG metodunda olduğu gibi bu yöntemde de elektrotun konumu önem arz etmektedir. İğne EMG yüzey-EMG ile yakalanamayan elektriksel aktiviteleri görmeyi sağlar. Bu yöntem ile kasların çalışma durumu hakkında daha fazla bilgiye erişilmiş olur [16].

2.5.2. Elektrot çeşitleri

Temelde 2 farklı EMG yöntemi olmasına rağmen her iki yöntem içinde elektriksel olarak farklı ölçüm metotları bulunmaktadır. Bu metotlar farklı kas tipleri için daha doğru veri alınmasını sağlar. Temelde elektriksel farklılıklar elektrotların çeşitlerinden kaynaklanmaktadır[2].

2.5.2.1. Monopolar elektrot

Bir EMG ölçümünde tek bir yerden ölçüm alan ve kas grubunun dışında bir referans elektrota ihtiyaç duyan elektrotlara monopolar elektrot denmektedir. Monopolar elektrotlar EMG esnasında yalnızca bulunduğu yerde veri alır [8].

2.5.2.2. Bipolar elektrot


Tek bir elektrotun içinde 2 farklı yerden çıkış veren ve 2 farklı yerden veri alan elektrot tipi olarak bilinir. Monopolar elektrotta olduğu gibi bir referansa ihtiyaç

duymaktadır. Farklı yerlerden ver aldığı için daha detaylı bir EMG sinyali oluşturmaktadır [8].

2.5.2.3. Konsentrik elektrot

İçerisinde hem referans hem de elektrot kısmını aynı anda bulunduran elektrotlardır dışarıda referansa ihtiyaç duymazlar. İğne- EMG yönteminde en çok kullanılan elektrot türüdür. Monopolar veya bipolar olabilir. Kullanımının kolay olması kendinden referans bölümü olması ve sinyal analizi için uygun veri vermesi yaygınlığının sebeplerindendir [8].

Kasların elektriksel aktivitesinin gözlemlenmesi ile çeşitli kas hastalıkları belirlenebilir. Bunlar miyopati ve nöropatidir.



Şekil 2.8. Elektrotların Şematik Gösterimleri A) Tekli Fiber İğne, B) Konsentrik İğne, C) Monopolar İğne, D) Makro İğne, E) Bipolar Yüzey Elektrot[11]

EMG sinyali kaydedilirken elektrot yerleşimi büyük önem teşkil eder. Özellikle monopolar ve bipolar gibi referans elektroda ihtiyaç duyan iğnelerin yerleşiminde referans noktası önemlidir. İğne ölçüm alınmak istenen kasa yerleştirildikten sonra referans elektrot minimum hatta sıfır sinyal noktasına yerleştirilmelidir. Bu nokta EMG için ilgili kasın kemiğe bağlı olduğu tendon noktasıdır.

2.6. Miyopati Ve Nöropati

Bu çalışmada tez çalışması sonunda başarılı sınıflandırılması hedeflenen miyopati ve nöropati rahatsızlıkları incelenmiştir.

2.6.1. Miyopati

Miyopati kısaca kas hastalığı kas fiberlerinin doğru çalışmamasından kaynaklanan nöromüsküler bir hastalıktır [12]. En belirgin belirtisi kaslarda zayıflamadır. Proximal zayıflama olarak adlandırılan bu belirtide üst bacak ve kollardaki zayıflama eller ve ayaklardakinden çok daha fazla kendini belli etmektedir. İleri safhalarda solunum kaslarını dahi etkilemekte ve hayatı zorlaştırmaktadır. Çeşitli sebeplerden dolayı ortaya çıkabilen miyopati hastalığı bu sebeplere göre sınıflandırılmaktadır. Miyopati hastalığı genel olarak 4 kategoride sınıflandırılabilir. Bunlar irsi miyopatiler, iltihaplı miyopatiler, endokrin miyopatiler ve toksik miyopatilerdir.

Irsi miyopatiler genetik sebeplerden kaynaklanmaktadır. Miyopati hastalığı en çok irsi sebeplerden dolayı meydana gelmektedir ve en sık görüleni Duchenne and Becker distrofisidir [12].

İltihaplı miyopatiler otoimmün hastalık olarak tanımlanmaktadır. Vücut immün sistemi olağan dışı bir şekilde kas dokusuna saldırır ve kas dokusuna hasar vermektedir [12]. Polimiyozit, dermatomiyozit gibi miyopati türleri bu türün altında yer almaktadır.

Endokrin miyopatiler vücuttaki hormonların az yada gereğinden fazla salgılanmasından dolayı oluşur. Vücuttaki hormon bezlerinden kaynaklanabileceği gibi hormon salgılayan tümörlerde miyopatiye sebep olabilmektedir.

Toksik miyopatiler dışarıdan vücuda alınan bir maddenin zehir etkeniyle gerçekleşir. Aşırı alkol tüketimi, narkotik ve anestezi ilaçları vb gibi başka diğer maddeler miyopatiye sebep olabilir.

Birden fazla çeşidi olmasına rağmen genel olarak miyopati hastalarının gösterdiği semptomlar benzer ve belirlidir. Halsizlik ve zayıflık en belirgin semptom olmakla birlikte kramplar, ağrı kaslarda gerginlik ve hassasiyet miyopati hastalarının şikayet ettiği diğer sorunlardır.

Miyopati hastalığı kas dokusunun kendisinde görülen bir sorundur. Fakat kaslarda oluşan halsizlik ağrı veya başka sorunlar mutlak suretle kas dokusundaki bir bozukluktan kaynaklanmayabilir. Daha önce de bahsedildiği gibi kas dokuları kendilerine gelen motor nöronlar tarafından uyarılır ve bu uyarımlara tepki vererek kasılmayı gerçekleştirirler. En çok görülen türü olan iltihaplı miyopatinin dünya çapında insidansı 1.6-19/milyon/sene dir. Yani her sene 1 milyon kişiden en az 1 an çok 19 una iltihaplı miyopati teşhisi konmaktadır. Bu zaman kadar olan tüm vakalar her yüz bin kişiden en az 3 en çok ise 34 ünün iltihaplı miyopati hastalığına yakalandığını göstermektedir. Kas dokusu

rahatsızlanabileceği gibi bu motor nöronlarda veya kas hücrelerine uzanan uzantılarında da problemler gözlemlenebilir. Bu tip durumlarda hastalığa miyopati değil nöropati denmektedir.

2.6.2. Nöropati

Nöropati kısaca sinir hastalığı anlamına gelmektedir. Vücutta bir veya daha fazla sinirin hasarı veya fonksiyonunu kaybetmesi sonucu ortaya çıkar. Genel olarak hissizlik, karıncalanma kaslarda zayıflık ve ağrı gibi belirtileri vardır [13]. Tıpkı miyopatide olduğu gibi çeşitli sebeplerden dolayı ve çeşitli bölgelerde ortaya çıkabilir ve bu sebeplere ve bölgelere göre sınıflandırılmaktadır. Bunlardan bazıları periferik nöropati, proximal nöropati, kranyal nöropati, otonomik nöropati ve fokal nöropatidir.

Periferik yani yüzeysel sinir sistemini oluşturan sinirlerin zarar görmesi veya fonksiyonunu kaybetmesiyle oluşan nöropati çeşidine periferik nöropati denir. En sık görülen nöropati çeşididir. Semptomlar sıklıkla el, ayak ve bu uzuvların parmaklarında görülmektedir [14].

Proksimal nöropati aslında yine bir periferik nöropatidir fakat yeri itibarı ile farklı adlandırılmıştır. Bu tip nöropati bacak, baldır ve kalça bölgesinde görülmektedir [14].

Kranyal nöropati doğrudan beyinden çıkan 12 kranyal sinirden herhangi birinin veya birçoğunun hasarıyla meydana gelir [14]. En çok görülen tipleri optik nöropati ve işitsel nöropatidir. Optik nöropati görme işitsel nöropati ise duyma bozukluklarına sebep olmaktadır.

Otonom yani istemsiz sinir sisteminde meydana gelen nöropati çeşidine otonomik nöropati denmektedir [14]. Otonom sinir sisteminin kontrol ettiği her bölgede meydana gelebilir. Örneğin mesane, genital organlar, boşaltım sistemi elemanları otonomik nöropatinin görülebileceği yerler arasındadır.

Fokal nöropati en az görülen nöropati çeşididir. Sadece tek bir sinirin hasar gördüğü veya fonksiyonunu kaybettiği nöropati çeşididir. Genellikle bilekteki sinirde görülmektedir.

Bu tezde kullanılan nöropati sinyalleri Amiyotropik Lateral Skleroz(ALS) hastalarına aittir. ALS derneği hastalığının insidansının her 2/100.000 olarak tahmin etmektedir. Bu her yıl 6400 insanın ALS hastalığına yakalandığını göstermektedir. Dernek dünyada her 20.000 kişiden birinin ALS hastası olduğunu söylemektedir. Derneğin tahminlerine göre 2040 yılına kadar ALS hastalarının sayısının %69 artacağını söylemektedir. Literatürde her ne kadar ALS ve bazı nöropati hastalıklarının karıştırılmaması gerektiği söylenece de ALS en nihayetinde bir motor nöron hastalığıdır ve kaslara giden motor nöronların yetersiz


alışmasından kaynaklanmaktadır. Bu neden alışma bazına bakıldığında ALS hastaları nropatiye sahip bireyler olarak deęerlendirilebilir.

2.7. Miyopati Ve Nropatinin EMG Sinyalindeki Etkisi

Daha nce bahsedildięi zere EMG kas hcrelerinde meydana gelen elektriksel aktiviteyi yani kas dokusunda oluřan ok sayıda aksiyon potansiyelini kaydeden bir yntemdir. Gerek kas hcrelerindeki rahatsızlıklar gerekse bu hcreleri uyaran sinir hcrelerindeki rahatsızlıklar belirli semptomlar yarattıęı gibi EMG sinyalinde de deęişiklikler yapmaktadır.

Miyopati veya nropati rahatsızlıęına sahip bir hastanın EMG kaydında gzlemlenmesi beklenen en belirgin zellik interferans yapılarıdır. İnterferans yapıları ięne elektrot kasa girdikten hemen sonra oluřur ve eřitli yapılara sahiplerdir. Saęlıklı bir kasta ięnenin batırılmasından hemen sonra kas dinlenme haline geecek ve sinyal sessizleřecektir.[15] Bařka bir deyiřle sinyal kaydında dz bir izgi gzkmesi gerekmektedir. İnterferans sinyalleri ok eřitli olabilir. Kas hakkında bir hastalıęın belirtisi olsada hangi hastalıęın belirtisi olduęunu sylemesi tek bařına yeterli deęildir. Zira interferans sinyali tek bařına hem miyopati hem de nropati olabilmektedir. Bu nedenle EMG sinyalinin kendisi de incelenmelidir.


Miyopati veya nropati EMG sinyalinin iinde kendini belli etmesi beklenir. Genel olarak řekil2.9. da ki gibi morfolojide olması beklenir. Yine de durum her zaman byle deęildir. Kas yapılarının kiřiden kiřiye deęiřmesi, hastalıęın derecesi, hatta ve hatta saęlıklı bir EMG sinyali gibi davranan miyopati veya nropatilerin varlıęı tanıyı zorlařtırmaktadır.



Şekil 2.9. Sağlıklı, Miyopatik ve Nöropatik EMG sinyallerinin 0.5 sn lik görüntüleri

3.MATERYAL VE METOD

Bu çalışmada sağlıklı, miyopati ve nöropati hastalarının EMG kayıtları incelenmiştir. Veriler ve analiz yöntemleri aşağıda anlatılmıştır. Aşağıda çalışmanın blok şeması görülmektedir.



Şekil 3.1. Yapılan işlemlerin şematik gösterimi (kırmızı çerçeve EMG sinyalinin A2 alt bandından mor çerçeve EMG sinyalinin kendisinden bulunan öznelikleri göstermektedir.)

3.1. Verilerin Elde Edilmesi

Veriler EMGLAB.net internet sitesinin sağladığı ücretsiz veri tabanından alınmıştır. Bu veri tabanındaki klinik veriler başlığı adı altında sunulan verilen kullanılmıştır. Bu çalışmada kullanılan EMG sinyalleri daha önce[16] nolu çalışmadan elde edilmiştir. Veriler 10 sağlıklı 7 miyopati hastası ve 8 als yani nöropati hastasından EMG kayıtları alınmıştır Sağlıklı kişilerin 4 kadın 6 erkekten oluşmaktadır. Bu kişiler 21-37 yaş aralığındadır. Miyopati hastalığına sahip olan kişiler 2 kadın 5 erkekten oluşmakta ve 19-63 yaş aralığındadır. ALS yani nöropati grubunda 4 kadın 4 erkek bulunmaktadır. Bu kişilerin yaşları 35-67 aralığındadır. Ölçüm alınan ALS hastaları ölçümleri takiben bir kaç sene içinde ölmüştür. Veri tabanında çeşitli kaslardan ölçümler bulunsa da bu çalışmada homojenite sağlaması açısından sadece. Brachial biceps kasından alınan ölçümler kullanılmıştır.. Ölçümler esnasında konsentrik iğne elektrot kullanılmış ve emg kayıt cihazının alçak ve yüksek geçiren filtre kesim frekansları 2Hz-10Khz aralığına ayarlanmıştır. Sağlıklı kişilerden toplam 300 EMG kaydı alınmıştır ve hepsi brachial biceps kasının uzun başından alınmıştır. Veri tabanında bu kas grubundan alınan ölçüm sayısı miyopati grubu için 53 tür. Nöropati grubu için veri tabanında brachial biceps kasının hangi bölgesinden ölçüm alındığına dair bir bilgi verilmemiştir fakat nöropati grubu için brachial biceps kasından alınan ölçüm sayısı 98 dir. Veriler düşük sabit gönüllü kasılma eşliğinde kaydedilmiş örnekleme frekansı 23438Hz olarak ayarlanmıştır.


Bu çalışmada her bir gruptan 30 adet olmak üzere toplam 90 EMG kaydı ile çalışılmıştır. Verilerin analizi, öznitelik çıkarımı ve sınıflandırması MatLab ortamında yapılmıştır. Kullanılan MatLab ortamının versiyonu “R2018a”dır. MatLab ortamında “Signal Processing Toolbox” ve “Deep Learning Toolbox” araç kitlerinin altında bulunan hazır komutlardan faydalanılmıştır.

3.2. Filtreleme İşlemi


Filtreler sinyallerin analizinden önce ön işleme aşamasında kullanılan ve sinyalleri analiz için uygun hale getiren özel tasarlanmış yapılardır. Filtreler bir sinyaldeki istenmeyen gürültüleri veya analizi zorlaştıracak yapıları ortadan kaldırmak için tasarlanırlar. Bu işlemi sinyalin frekans düzlemindeki komponentleri kaldırarak yaparlar. Alçak-geçiren, yüksek-geçiren, bant-geçiren, bant-durduran tipleri vardır. Bu filtre tipleri tam olarak isimlerine uygun çalışırlar. Örneğin alçak geçiren bir filtre sinyalin içindeki alçak frekans bileşenlerini geçirirken yüksek frekans bileşenlerini bastırmaktadır.

Böylelikle eğer sinyalin içerisinde yüksek frekans bandında istenmeyen olgular var ise filtreleme işlemi sayesinde kaldırılmış olur ve sinyal analiz için uygun hale getirilir. Bu tez çalışmasında da bulgular kısmında detaylı anlatılmış olan bir alçak frekans gürültüsü olan taban hattı kaymasını yok etmek için bir filtre tasarlanmıştır. Filtrenin alt kesim frekansı 15Hz, üst kesim frekansı ise 2000Hz seçilmiştir. Bu seçimlerin sebebi bulgular bölümünde detaylı olarak anlatılmıştır.

Filtrenin tipi chebyshev tip 1 olarak seçilmiştir. Bunun sebebi bu tip filtrenin daha önce [40] nolu çalışmada uygulanmış ve başarılı olmuş olmasıdır. Matlab ortamında chebyshev tip1 filtre oluşturmak için cheby1 komutu kullanılmıştır. Filtrenin faz ve genlik cevapları aşağıdaki şekillerde gösterilmiştir.



Şekil 3.2. Oluşturulan Filtrenin Genlik Cevabı



Şekil 3.3. Oluşturulan Filtrenin Faz Cevabı

Tasarlanan filtrenin transfer fonksiyonu (3.1) deki eşitlikle ifade edilmektedir.

$$H(z) = \frac{0.003466 * z^8 - 0.01386 * z^6 + 0.0208 * z^4 - 0.1386 * z^2 + 0.003466}{z^8 - 6.674 * z^7 + 19.67 * z^6 - 33.51 * z^5 + 36.16 * z^4 - 25.33 * z^3 + 11.25 * z^2 - 2.899 * z + 0.3313} \quad (3.1)$$

3.3. Zaman Bölgesi Analizi

Sinyallerin zaman bölgesindeki gösterimindeki genlikleri üzerinden yapılan analize zaman bölgesinde analiz denir. Bu çalışmada kullanılan yöntemler aşağıda anlatılmıştır.

3.3.1. Karelerin ortalamasının karekökü(RMS)

RMS(root mean square) karekök ortalama anlamına gelmektedir. Kuadratik ortalama da denmektedir. Bir sinyaldeki değişen miktarların ölçülmesinde kullanılır [31].Biyosinyallerde ani ve keskin değişimlerin artı veya eksi yönde olduğu durumlarda faydalı bir istatistiki veridir [17] nolu çalışmaya göre EMG sinyallerinin RMS değerleri sağlıklı ve miyopatik durumlarda değişkenlik göstermektedir. RMS değeri elektrikte ac bir sinyalin etkin enerjisi anlamına gelmektedir. Biyosinyallerde elektriksel sinyaller olduğundan aslında RMS değerini bir biyosinyalin etkin gücü olarak değerlendirebiliriz. Aşağıdaki eşitlik RMS değerinin nasıl bulunacağını göstermektedir.

$$\sqrt{\frac{1}{N} \sum_{n=1}^N x_n^2} \quad (3.2)$$

Bu formülde n sinyalin örnek numarasını N ise toplam örnek sayısını ifade etmektedir. [18] nolu çalışmada RMS değeri EMG sinyali için ayırt edici bir değer olarak belirtilmiştir. Fakat bu ayırt edicilik nöromusküler hastalıklar için değil vücut uzuvlarının farklı hareketlerini belirlemek için kullanılmıştır. RMS değeri bir sinyalin etkin gücü olduğunu göz önünde bulundurduğumuzda miyopati hastaları için bu değer sağlıklı kişilere göre daha düşük olması beklenmelidir. Çünkü tıpkı vücudun farklı hareketlerindeki EMG sinyalinin RMS değerinin değişmesi gibi miyopati hastalığına sahip kişilerde de kaslarda zayıflama meydana gelmektedir bu nedenle RMS değeri değişiklik gösterebilme eğilimindedir.

RMS değeri sinyallerin zaman düzleminde genliklerinden elde edilen bir değerdir. Yine de frekans düzlemi için kullanılamaz diye bir şey söz konusu değildir.

3.3.2. Ortalama mutlak değer(MAV)

Ortalama mutlak değer bir sinyalin bölütlerindeki mutlak değerlerin ortalamasıdır. EMG sinyali için kasın kasılma gücü hakkında bilgi vermektedir. Aşağıdaki formül ile hesaplanmaktadır.

$$MAV = \frac{1}{n} \sum_{n=1}^N |x_n| \quad (3.3)$$

Ortalama mutlak değer tıpkı RMS gibi kasların farklı kasılmalarında değişkenlik göstermektedir. Bu nedenle [19] nolu çalışmada elin farklı hareketlerini EMG sinyallerinden test etmek için öznel olarak kullanılmıştır. Nöromusküler hastalıklar için tıpkı RMS gibi değişkenlik gösterme eğilimindedir.

3.3.3. Sıfır geçiş oranı (ZCR)

Sıfır geçiş oranı bir sinyalin sıfır eksenini kaç kere kestiğini söyleyen istatistiksel bir değerdir. Biyosinyallerde sıklıkla karmaşıklık analizi için kullanılmaktadır. Aşağıdaki eşitlik ile hesaplanmaktadır.

$$ZCR = \sum_{n=1}^{N-1} \left[\text{sgn} (x_n \cdot x_{n+1}) \cap |x_n - x_{n+1}| \right] \geq esik$$

$$\text{sgn} (x) = \begin{cases} 1, & x \geq esik \\ 0, & \text{diğer} \end{cases} \quad (3.4)$$

Düşük voltaj sızıntıları veya arka plan gürültülerinin hesaplamaya etkilerinin minimize etmek için mutlak sıfır değeri yerine bir eşik değeri belirlenip hesaplama yapılabilir [18]. ZCR değeri yüzey EMG uygulamalarında sıklıkla bir öznitelik olarak kullanılmaktadır. Bu değer EMG sinyalinin zaman düzlemindeki bir frekans değeridir de denilebilir [18]. Kasılma gücü hakkında değişkenlik gösteren bir öznitelik olarak kabul edilir.

3.3.4. Willison genliği(WA)

Willison genliği tıpkı ZCR gibi EMG sinyalinin zaman düzlemindeki analizinden elde edilen frekans bilgisidir [18]. Belirli bir eşiği aşan 2 komşu segment arasındaki farkın belirli bir eşiği aşıp aşmadığı kontrol edilerek hesaplanır.

$$WAMP = \sum_{n=1}^{N-1} f(|x_n - x_{n-1}|)$$

$$f(x) = \begin{cases} 1, & x \geq esik \\ 0, & diger \end{cases} \quad (3.5)$$

Motor unite aksiyon potansiyeli ve kasın kasılma gücüyle doğrudan ilgisi vardır[18]. Bu nedenle nöromusküler hastalıklar için de bir öznitelik olabilme özelliği taşır.

3.3.5. Varyans(VAR)

Varyans genel olarak değerlerin karesinin ortalaması olarak tanımlanmaktadır. Biyosinyallerde varyansın çok yüksek olması beklenmez . Bu nedenle varyansın yüksek olması veya ani değişimleri varyansı bir öznitelik adayı yapmaktadır. Aşağıdaki formül ile hesaplanabilir.

$$VAR = \frac{1}{N-1} \sum_{n=1}^N x_n^2 \quad (3.6)$$

EMG sinyali için varyans bir güç belirtecidir. Gelen genliklerin değerleri kasılma gücünü ifade ettiğinden varyans da bu değeri belirten istatistiki bir değerdir.

3.4. Frekans Bölgesi Analizi

Sinyaller zaman bölgesinde bulundurdıkları genlikler dışında frekans adı verilen sinyalin bir saniyede kaç kere tekrarlandığını gösteren bir bileşende bulundurulur. İşte bu

bileşenler genliklerden bağımsız olabilmektedir. Bu bileşenlerin analizine frekans bölgesi analizi denir

3.4.1. Foruier dönüşümü

Bir sinyalin frekans düzleminde analizini yapabilmek için öncelikle o sinyalin frekans tayfına bakılması ve buna göre analiz yapılması gerekmektedir. Bir sinyalin frekans tayfı Foruier dönüşümü sayesinde ortaya çıkarılabilmektedir.

Foruier dönüşümü bir sinyalin içindeki bilgilerin elde edilmesinde kullanılan önemli bir yöntemdir. Bu dönüşüm yöntemiyle bir sinyal farklı genlik, frekans ve fazlardan oluşan sinüs ve kosinüs sinyalleri ile ifade edilebilir [20]. Foruier dönüşümü her bir frekanstaki genliği ve fazı ifade eden bir fonksiyondur. Böylelikle Foruier dönüşümü uygulanmış bir sinyal uygun eksen değerleriyle birlikte çizdirildiğinde ortaya sinyalin frekans tayfı çıkmaktadır. Foruier dönüşümü sürekli(analog) ve kesikli(dijital) sinyallere uygulanabilir fakat yöntemleri farklıdır.

3.4.1.1. Sürekli-zamanlı foruier dönüşümü

Daha önce de bahsedildiği gibi Foruier dönüşümü dijital ve analog sinyaller için farklı matematiksel yöntemlerle uygulanmaktadır. Eğer bir sinyal sürekli ise yani her gerçek sayı için bir değeri var ise bu sinyal tüm frekanslardaki sinüslerin Foruier integrali şeklinde gösterilebilir [20]. Bu durumda Foruier dönüşümü formülü aşağıdaki gibi olmaktadır.

$$F(\omega) = \int_{-\infty}^{\infty} f(t) e^{-i\omega t} dt \quad (3.7)$$

Dijital bir sinyalle çalışırken ise bu yöntem yerine ayrık zamanlı Foruier dönüşümünün uygulanması gerekmektedir.

3.4.1.2. Ayrık-zamanlı foruier dönüşümü

Ayrık zamanlı Fourier dönüşümü, bir ayrık-zaman işaretinin farklı frekanslardaki karmaşık üstel işaret bileşenlerini vermektedir. Fourier dönüşümü bazen Fourier spektrumu, Frekans spektrumu veya sadece Spektrum olarak ifade edilmektedir. Ayrık zamanlı Fourier Dönüşümü, ayrık zaman işaretini sürekli frekans bileşenlerine ayrıştırmaktadır. Bu nedenle

bir ayrık-zamanlı işaretin ayrık zamanlı Fourier dönüşümü frekansa bağlı sürekli bir fonksiyondur[20]. Bir ayrık zamanlı Fourier dönüşümünün formülü aşağıdaki gibidir.

$$DTFT_{\omega}(x) = \sum_{-\infty}^{\infty} x(n)e^{-j\omega n} \quad (3.8)$$

Zaman ve teknoloji ilerledikçe Fourier dönüşümünün uygulamasıyla ilgili değişik algoritmalarda ortaya çıkmıştır. Bunlardan bir tanesi hızlı Fourier dönüşümü yani kısa ve İngilizce ismiyle FFT dir. Bu algoritma sinyali parçalara bölerek her bir parçanın Fourier dönüşümünü almaktadır. Böylece zamandan kazanmış olur [20]. FFT algoritmasında dikkat edilmesi gereken nokta FFT algoritması bizlere 2 nin kuvvetleri kadar sayıdan oluşacak elemanlar kadar bir dizi vermesidir [21].

Frekans tayfı bir sinyalin içindeki frekansların ne kadar baskın olduğunu veya zayıf olduklarını bize söyleyen bir grafik görüntüsü verir. Frekans tayfına bakarak frekans düzleminde nasıl bir analiz yapılabileceğini belirleyebilir, herhangi bir gürültünün varlığını anlayabilir, sinyale etki eden dış etkenler var ise frekans düzleminde nasıl bir etkilerinin olduğunu gözlemleyebiliriz. Fakat frekans tayfı bizlere sadece sinyalin içindeki frekans bileşenlerinden ne kadar olduğu hakkında bilgiler vermektedir. Bu frekansların sinyal üzerindeki güçleri hakkında bir bilgi vermez. Bu bilgi için Güç Spektral Yoğunluğu adındaki bir yöntem uygulanmalıdır.

3.4.2. Güç spektral yoğunluğu

Güç spektral yoğunluğu(GSY) bir sinyalin farklı frekanslarındaki enerji yoğunluğu olarak tanımlanabilir. EMG sinyali kaotik bir biyosinyal olduğundan zaman düzleminde miyopati ve nöropati için ayırt edici bir özellik bulmak zordur. Fakat genel olarak güç spektral yoğunluğu rastsal sinyaller için bile benzerlikler veya farklılıklar bulunabilecek bir olgudur. Bunun sebebi sinyalin frekans düzlemindeki maksimum değerlerinin belli olmasıdır. Güç spektral yoğunluğu sinyalin frekans başına düşen enerjisidir. Genel olarak ise sinyalin özilinti fonksiyonun Fourier dönüşümü olarak tanımlanabilir.[22]

$$S_{xx}(f) = \int_{-\infty}^{\infty} R_{xx}(\tau) e^{-j2\pi f\tau} d\tau \quad (3.9)$$

Burada R_{xx} sinyalin özlili fonksiyonudur. S_{xx} ise GSY fonksiyonudur. Aynı zamanda Parseval teoremine göre bir sinyalin Fourier dönüşümünün karesi güç spektral yoğunluğuna eşittir bu yaklaşım ile güç spektral yoğunluğu aşağıdaki formül ile de hesaplanabilir.

$$GS(x) = |F(\omega)|^2 \quad (3.10)$$

GSY hesaplanırken Fourier dönüşümü tüm sinyal üzerinden bölütleme yöntemiyle hesaplanır ve her bir alt bölütün dönüşümün ortalaması alınır [22]. Bölütleme işleme sinyale bir pencere uygulanmasıyla gerçekleştirilir. Pencere boyunca sinyal 1 ile çarpılırken pencere dışında kalan kısımlar 0 ile çarpılır. Böylece sinyalin pencere boyunca olan bölütü analiz edilmiş olur. Bu pencereler birbiriyle örtüşmeli veya örtüşmesiz olarak kullanılabilir. Pencere türü ve uzunluğu incelenecek sinyalin örnekleme frekansına ve morfolojisine göre seçilmelidir. Küçük pencere uzunluğu daha fazla bölüt üzerinden hesaplama yapacağından spektral kestirimin güvenilirliği artar fakat frekans çözünürlüğünü düşürecektir [22].

GSY hesaplamasında iki temel yaklaşım bulunmaktadır. Bunlar klasik(parametrik olmayan) ve model tabanlı(parametrik) yaklaşımlardır. Tez çalışmasında parametrik bir yöntem kullanılmadığından burada sadece parametrik olmayan yöntemlerle ilgili söz edilecektir.

3.4.2.1. Parametrik olmayan yöntemler

Parametrik olmayan yöntemler GSY'nin temel tanımlarını kullanan ve sinyal üzerinde bir varsayım koymayan yöntemlerdir. Bu yöntemler FFT algoritmasını kullanırlar. Bu nedenle FFT tabanlı spektral kestirim yöntemleri olarak da bilinmektedir. Bu yöntemlerde frekans çözünürlüğü sinyalin uzunluğuna bağlıdır [22]. Bu yöntemlerdeki sorun ise pencerelemekten kaynaklanan spektral sızıntılardır. Parametrik olmayan yöntemler Periodogram, Korrelogram, Blackman-Tukey, Bartlett ve Welch yöntemi olarak sıralanabilir.

Bu yöntemlerden periodogram ve korrelogramın varyansı oldukça yüksek olduğundan veri uzunluğundan etkilenmemektedir. Bu da parametrik olmayan bu yöntemlerin daha zayıf karakteristik göstermesine sebep olmaktadır.

Varyansı düşürmek için Bartlett ortalama peridogram olarak da bilinen kendi yöntemini geliştirmiştir. Bu yöntem standart periodogram yöntemin varyansını azaltmakla birlikte frekans çözünürlüğünü de düşürmektedir. Bu yöntemde örtüşme yapılmaksızın birden fazla n uzunluğundaki sinyal penceresinin GSY si hesaplanır ve hepsinin ortalaması alınır.

Welch yöntemi ise Bartlett yönteminin gelişmiş hali olarak söylenebilir. Bu yöntemde Bartlettten farklı olarak pencereler örtüşmeli olarak kullanılır. Örtüşme n+1. pencerenin n. penceredeki verilerin ne kadarını kapsadığını söyler. Örneğin %50 oranında bir örtüşme bir pencerenin kendinden bir sonraki pencerede bulunan verilerin %50 sinin aynı olduğu yani örtüştüğü anlamına gelmektedir. Bu yöntem sinyalin merkezinden kenarlara doğru gidildikçe oluşan kayıpları önler [22]. Welch yöntemi bu özelliğinden dolayı bu tez çalışmasında kullanılmıştır.

$$\hat{P}_w(f) = \frac{1}{S} \sum_{l=1}^S \hat{P}_l(f), \text{ burada}$$

$$\hat{P}_l(f) = \frac{1}{M} \frac{1}{P} \left| \sum_{n=1}^M w(n) x_l(n) e^{-j 2 \pi f n} \right|^2 \quad (3.11)$$

(3.11) eşitliğinde M örtüşen aralıkların uzunluğu, S örtüşen aralık sayısı w(n) veri penceresi P ise bu pencerenin ortalamasıdır. Bu eşitlik Welch yöntemini tanımlar.

3.4.3. Ortalama ve medyan frekans

Ortalama ve medyan frekans değerleri EMG sinyallerinin frekans düzleminde bakılan 2 tan e istatistiki veridir. Bu değerler genelde GSY üstünden hesaplanır. Sinyalin GSY sindeki dalgalanmalar ve her bir frekans değerine düşen güç değerlerinin birbirlerine yakınlıkları ve uzaklıkları bu değerlerin değiştirmektedir. Dolayısıyla sinyaldeki ani frekans değişimleri ortalama ve medyan frekans değerlerini de değiştirecektir.

$$Mean_{frequency} = \left(\sum_{n=0}^N A_n * f_n \right) / \sum_{n=0}^N A_n \quad (3.12)$$

$$Median_{frequency} = \frac{1}{2} \sum_{n=0}^N A_n \quad (3.13)$$

(3.12) ve (3.13) eşitliklerinde A_n spektrum sinyalinin n . örneğindeki genliğini f_n ise n . örnekteki frekans değerini göstermektedir.

3.5. Dalgacık Dönüşümü

Dalgacık dönüşümü durağan olmayan sinyallerin analizinde faydalı bir yöntem olarak bilinmektedir. Dalgacık dönüşümü tamamen farklı bir değer fonksiyonu ile pencereli Fourier dönüşümüne benzemektedir [23]. Daha önce bahsedildiği üzere Fourier dönüşümü sinyali sinüs ve kosinüs sinyallerine ayırmaktadır. Dalgacık dönüşümünde ise hem gerçek hem de Fourier uzayında lokalize olmuş dalgacık fonksiyonları kullanılmaktadır. Fourier dönüşümü ve dalgacık dönüşümünün arasındaki temel fark budur.

Dalgacık dönüşümünde kullanılan fonksiyon sinyaldeki zaman ve frekans bileşenlerine göre ölçeklendirilebilmektedir. Bu sayede yüksek frekanslarda yüksek zaman düşük frekanslarda ise yüksek frekans çözünürlükleri elde edilebilir[24]. Kısa bir deyişle sinyaldeki frekans değişkenliklerine göre ayarlanabilen pencere fonksiyonları bulunmaktadır. Buna karşın frekans ve zaman çözünürlükleri birbirlerine ters orantılıdır. Yani hem zaman hem de frekans çözünürlüğü aynı anda artırılıp azaltılamaz [25]. Bir dalgacık zamanda geniş bir alana yayılabilir ve bu frekansı düşük aralıklara sıkıştırır. Bu frekansın daha iyi lokalize olmasını ve frekans çözünürlüğünü artırırken zaman çözünürlüğünü düşürmektedir. Tam tersi şekilde dalgacık fonksiyonu zamanda dar alanlara ölçeklendirildiğinde frekans spektrumunu geniş alanlara yaymaktadır. Bu da frekans çözünürlüğünün azalmasına ve zaman çözünürlüğünün artmasına neden olmaktadır. Bu özellik dalgacık dönüşümü kullanılırken sinyalin özelliklerine göre optimum zaman frekans çözünürlüğünün ayarlanmasını sağlar.

Çeşitli dalgacık aileleri bulunmaktadır. Teknik olarak bir dalgacık ailesinde sonsuz sayıda dalgacık fonksiyonu bulunur. Çünkü dalgacık fonksiyonları zamanda sonsuz şekilde ölçeklendirilebilmektedir.


Dalgacık dönüşümü Sürekli Dalgacık Dönüşümü(SDD) ve Ayrık Dalgacık Dönüşümü(ADD) olmak üzere iki ana başlık altında incelenebilir.

3.5.1. Ayrık dalgacık dönüşümü(ADD)

ADD işleminde sinyal SDD işleminde olduğu gibi sürekli değişen ölçek parametreleri yoktur. Bunun yerine sinyal birbirini tümleyen filtrelerden geçirilerek alçak ve yüksek frekans bileşenlerinde ayrılır. Bu işlem sinyalin istenen alt bantlarına ulaşmaya

kadar tekrarlanabilir. Her bir filtre sinyalin alçak frekans bileşenlerini içeren yaklaşık(A) ve yüksek frekans bileşenlerini içeren detaylı(D) alt bantlarını oluşturmaktadır.


Her bir alt bant oluşturulduktan sonra Nyquist teoremine göre örneklerin yarısı atılmaktadır Bu işlem zaman çözünürlüğünü azaltmakta fakat frekans çözünürlüğünü artırmaktadır. Başka bir deyişle her bir filtre çıkışı sonrası zaman düzlemindeki analizlerin güvenilirliği azalırken frekans analizi güvenilirliği artacaktır [26].



Şekil 3.4. Bir ADD ayrışım ağacı[26]

Şekil 10 de bir ADD ayrışım ağacı gösterilmiştir. Bu gösterimde g[n] alçak geçiren h[n] ise bir yüksek geçiren filtredir. Şekilde görüldüğü üzere sinyal her bir dönüşümde alçak ve yüksek frekans bileşenlerini ayrı ayrı içeren 2 farklı sinyale ayrılmaktadır. Örneklerin yarısı atıldığı gibi ayrışan sinyallerin frekans aralıklarında ayrışımın yapıldığı sinyalin total frekansının (Fmax) aralıklarına bölünmektedir [26]. Yaklaşık alt bant sinyali 0-Fmax/2 aralığında frekans bileşenlerini içerirken detaylı alt bant sinyali Fmax/2-Fmax frekans aralığındaki frekans bileşenlerini içerir. Bu frekans aralığı her bir dönüşümde yarıya inerek ilerler.

Bu çalışmada ADD kullanılarak EMG nin alt bandlarına inilmiştir. 2 kademe ADD uygulanmıştır. Daha önce bahsedildiği üzere EMG sinyalinin örnekleme frekansı 23438 Hz dir. Yani sinyaller içlerinde 11719Hz e kadar frekans bileşeni barındırmaktadır. Uygulanan 2 kademeli ADD ile bu sayı 2930Hz e kadar düşürülmüştür. Tezde kullanılan ADD ayrışım ağacının şematik gösterimi aşağıdaki şekilde gibidir.



Şekil 3.5. Çalışmada yapılan ADD ayrışım ağacı

3.6. Sınıflandırıcılar

Birden fazla sınıf veya kategoriye ait bir veri setini belirli matematiksel yöntemler kullanarak sınıflandıran algoritmalara sınıflandırıcı denir. Bu tez çalışmasında kullanılan sınıflandırıcı algoritmaları ve sınıflandırıcılara ait bazı alt başlıklar aşağıda anlatılmıştır.


3.6.1. K-en yakın komşuluk (K-NN)

K en yakın komşuluk algoritması sınıflandırmada ve regresyon uygulamalarında kullanılan parametrik olmayan bir sınıflandırıcı algoritmasıdır[27]. K-NN algoritması basit olarak sınıflandırılmak istenen yeni bir verinin öznitelik düzlemindeki yerinde en yakın komşu veri sayısına bakarak sınıflandırma yapar. K-NN algoritması bir sınıfa ait verilerin öznitelik uzayında birbirine yakın bulunması gerektiği varsayımını yapar. K burada komşu veri sayısıdır.


Yeni sınıflandırılacak bir veri, öznitelik uzayında önceden eğitilmiş verilerin arasına yerleştirilir. Bu verinin seçilen n adet komşu sayısının hangi sınıflara ait olduğuna bakılır ve algoritma hangi sınıfın komşularının daha fazla olduğuna göre yeni verinin sınıfına karar verir[28]. Komşuluk mesafesi hesabında genellikle klasik öklit mesafesi yani bir uzayda iki nokta arasındaki mesafe formülü kullanılır. Öklit mesafesi dışında başka mesafe hesabı eşitlikleri de kullanılabilir. Aşağıdaki eşitlikte öklit mesafesi hesabı görülmektedir.

$$dist((x, y), (x_1, y_1)) = \sqrt{(x - x_1)^2 + (y - y_1)^2} \quad (3.15)$$

K-NN algoritması özellikle tek bir sınıfa ait verilerin öznitelik uzayında farklı yerlere toplu olarak dağılması durumunda faydalı bir algoritmadır. Sınıflandırılacak veriyi bölgesel olarak değerlendirmesi ve bu bölgenin alanının ayarlanabilmesi sebebiyle lineer olarak ayrıştırılamayan veri dağılımlarını ayrıştırabilmesini sağlamaktadır.




Şekil 3.6. Öznitelik Uzayında Yeni Bir Veri(Yeşil)[29].



Şekil 3.7. K=3 değeri için belirlenen yeni verinin komşu verileri[29]

Şekil23. ve Şekil24. te görüldüğü üzere öznitelik uzayına gelen yeni bir verinin belirlenen K değeri kadar komşu veya komşuları belirlenir mesafe seçilen mesafe eşitliğine göre hesaplanır.



Şekil 3.8. Komşu sayısına göre yeni sınıflandırılan veri[29]

Şekil25. te K-NN algoritması kendisine komşu verilerin sayısına bakarak yeni veriyi sınıflandırmıştır. Bu örnekte verinin 3 komşusundan 2 si kırmızı sınıfa 1 tanesi mavi sınıfa ait olduğundan algoritma yeni veriyi kırmızı sınıfına ait olarak belirlemiştir.

Algoritmanın temel versiyonunun, test örneğinden depolanan tüm örneklerle olan mesafeleri hesaplayarak uygulanması kolaydır, ancak büyük eğitim setleri için hesaplama yoğun olabilmektedir. K-NN algoritması sınıflandırılacak verileri seçilen parametrelere göre teker teker değerlendirmektedir. Bu durum çok büyük veri setlerinde K-NN algoritmasının yavaşlamasına sebep olmaktadır. Uygun bir en yakın komşu arama algoritmasının kullanılması, K-NN'yi büyük veri setleri için bile uygun hale getirebilir. Yıllar boyunca en yakın komşu arama algoritmaları önerilmiştir; bunlar genellikle gerçekte gerçekleştirilen mesafe değerlendirme sayısını azaltmaya çalışır [30].


3.6.2. Destek vektör makinesi(SVM)

Destek vektör makineleri sınıflandırmada kullanılan basit ama etkili bir algoritmadır. Öznitelik düzleminde sınıfları ayıracak bir vektör çizerek sınıflandırma yapar. Bu sınır sınıfların verilerine en uzak olacak şekilde çizilir.


SVM algoritması sınıflara yakın ve birbirine paralel sınır çizgileri çizer. Daha sonra bu sınır çizgileri birbirilerine yaklaştırılarak optimal sınır çizgisi elde edilir [31]. Bu sınır çizgisi bir hyperplane(aşırı düzlem) dir.

Aşırı düzlemler verileri sınıflandırmak için olan karar çizgileridir. Aşırı düzlemin farklı taraflarına düşen veriler farklı sınıflara aittir. Aşırı düzlemin boyutu öznitelik sayısına bağlıdır. Aşırı düzlemler öznitelik sayısından 1 eksik boyuta sahip olmaktadır [32]. Bu nedenle öznitelik sayısı 3 ten fazla olduğu vakit aşırı düzlemi betimleyebilmek zordur.

Destek vektörleri ise bu aşırı düzlemi belirleyebilmek için algoritma tarafından çizilen ve sınıflar arasındaki optimal aşırı düzlemi bulmasını sağlar. Bu vektörler öznelik verileri arasında aşırı düzleme en yakın verilerdir. Bu verilerin öznelik uzayındaki konumları aşırı düzlemin pozisyonunu değiştirecek ve dolayısıyla sınıflandırıcının başarısını etkileyecektir[32]. SVM algoritmasında bu vektörler kullanılarak ilk sınır çizgileri çekilir ve bu sınır çizgilerine eşit uzaklıkta bulunan bir aşırı düzlem oluşturulur bu aşırı düzlem optimal aşırı düzlemdir.




Şekil 3.9. Öznelik Uzayında Destek Vektörlerinin Görüntüsü[33]



Şekil 3.10. Optimal Aşırı Düzlemin Bulunması[32]

SVM algoritması belirli bir çizgi aşırı düzlemi çizilemeyen durumlarda da verileri ayırabilmektedir. Bunu öznelik uzayındaki verileri daha çok boyutlu bir uzaya taşıyarak

yapabilir. Birbirinden 2 boyutta ayrılamayan verileri 3. bir boyuta taşıyarak bir aşırı düzlem oluşturması mümkündür. Bu boyutu taşıma işlemini yapan fonksiyona kernel fonksiyonu yapılan işleme kernel hilesi denir[31]. Öznitelik verisinin doğru kernel fonksiyonu ile başka bir boyuta taşınması algoritmanın başarısını artıracaktır.



Şekil 3.11. Kernel Hilesi Sonucu Veri Seti Görüntüsü[34]

3.6.3. Karar ağaçları

Karar ağaçları en temel sınıflandırma algoritmasıdır. Kendisinde gönderilen verileri belirli bir sırayla ve belirli koşullara göre sınıflandırır. En basit hava durumu tahmininden biyomedikal uygulamalara kadar her türlü uygulamada kullanılabilir.

Bir karar ağacı bir dizi veri kümesini karar koşulları uygulayarak daha küçük kümelerle böler. Her bir koşul ağaç içinde bir düğüm oluşturur ve bu düğümler karar koşullarına göre başka kümeleri işaret etmektedir[35]. Karar ağaçlarında kritik nokta koşul sorusudur. Koşul soruları düğüm çıkışlarını düzgün verebilecek şekilde ayarlanmalıdır.

Karar ağaçları çok çıkışlı verilerle çalışabilir. Çıkışların nümerik veya etiket şeklinde olması karar ağacını etkilemez her iki tip çıkışla da çalışabilmektedir. Kullanılan ağaçlar görselleştirilebilir bu nedenle anlaması ve yorumlaması kolaydır. Fakat koşullar yani ağaçtaki düğümler arttıkça ağaç takibi de zor olmaktadır[36]. Bu nedenle karar ağaçları minimum koşul a karşın maksimum verim ilkesiyle oluşturulmalıdır.



Şekil 3.12. Basit Bir Karar Ağacı[36]

3.6.4. Sınıflandırıcı istatistikleri

Bir sınıflandırıcının çıktıları sonucunda sınıflandırıcının verileri ne kadar doğrulukla bulup bulmadığını gösteren bir matris oluşmaktadır. Bu matris karmaşıklık matrisi denir. Bu matristeki veriler ile sınıflandırıcının bir takım istatistikleri çıkarılır. Bu istatistikler sınıflandırıcının verimini söyleyebilmektedir.

Örneğin 2 sınıfın olduğu bir veriyi ele alacak olursak. Sınıflandırıcı sonucunda bu 2 sınıfın ne kadarının doğru sınıflandırıp sınıflandırılmadığı karmaşıklık matrisinde görülebilir. Bu matrsten çıkarılabilecek ve sınıflandırıcı için en önemli 3 istatistik doğruluk, hassasiyet ve özgüllüktür.

Gerçek Sınıf	0	Doğru Negatif	Yanlış Pozitif
	1	Yanlış Negatif	Doğru Pozitif
		0	1
		Tahmin sınıfı	

Şekil 3.13. Karmaşıklık Matrisi

Şekil 5.8 de bir karmaşıklık matrisi görülmektedir. Bu karmaşıklık matrisinde sol taraf verinin gerçek sınıflarını aşağı taraf ise sınıflandırıcı tarafından saptanan sınıfları göstermektedir. Sınıflandırıcı verideki 0 çıktısını 0 olarak sınıflandırmışsa Doğru Negatif(DN) 1 olarak sınıflandırmışsa Yanlış Pozitif(YP) olarak değerlendirilir. Eğer sınıflandırıcı verideki 1 çıktısını 1 olarak sınıflandırmışsa buna doğru pozitif(DP) 0 olarak sınıflandırmışsa yanlış yanlış negatif(YN) olarak değerlendirme yapılır. Bu nokta doğru veya yanlış sözcüğü sınıflandırıcının doğru veya yanlış yaptığını negatif ve pozitif sözcüğü ise verinin türünü göstermektedir.

Nümerik çıktıları olan bu karmaşıklık matrisinde hesaplanması gereken ilk şey sınıflandırıcının doğruluğudur. Bir sınıflandırıcının doğruluğu karmaşıklık matrisinden aşağıdaki eşitlikle hesaplanabilir.

$$Doğruluk = (DP + DN) / (P + N) \quad (3.16)$$

Doğruluk istatistiği sınıflandırıcının tüm verileri ne kadar doğru sınıflandırdığını gösteren bir veridir.


Doğruluk pozitif ve negatif olan tüm veriler üstünden hesaplanmaktadır. Ancak sınıflandırıcının pozitif veya negatif verileri ayrı ayrı ne kadar doğru sınıflandırdığına dair olan istatistikte önem arz etmektedir. Bu nokta hassasiyet ve özgüllük kavramları aklı gelmelidir. Hassasiyet sınıflandırıcının pozitif verileri ne kadar doğru sınıflandırdığını, özgüllük ise negatif verileri ne kadar doğru sınıflandırdığını göstermektedir ve aşağıdaki eşitlikler ile hesaplanabilir.

$$Hassasiyet = DP / (DP + YN) \quad (3.17)$$

$$Ozgulluk = DN / (DN + YP) \quad (3.18)$$

3.6.5. K-kat validasyon

K-kat validasyon bir sınıflandırıcının eğitimi esnasında kullanılan validasyon yöntemlerinden biridir. Validasyon sayesinde sınıflandırıcının tahmini doğruluğunu test verisi kullanmadan görmek mümkündür. K-kat validasyon eğitim verisini K kadar parçaya böler ve bu parçaların her birini ayrı ayrı validasyona ayırır diğer kalan verileri ise sınıflandırıcıyı eğitmek için kullanır. Daha sonra eğitilen bu sınıflandırıcıyı ayırdığı parçaların her biriyle test eder ve bulunan en yüksek doğruluk sonucunu sınıflandırıcı modeli olarak kaydeder.



Şekil 3.14. K=5 değeri için K-kat validasyon veri ayırımı görüntüsü[37]

4.BULGULAR

Tezin bu bölümünde araştırma ve analiz sonuçlarında elde edilen bulgular paylaşılmıştır. Bu bölümde önce EMG sinyallerinin ön işlemlerinden bahsedilmiş daha sonra materyal ve metot kısmında anlatılan yöntemlerin uygulanması sonucu çıkan veriler anlatılmıştır. Daha sonra sağlıklı miyopatik ve nöropatik EMG sinyallerindeki bu verilerin farklılık gösterip göstermediği söz edilip ve öznitelik çıkarımı anlatılmıştır. Yapılan işlemlerin şematik gösterimi aşağıdaki şekildedir.

4.1. Sinyallerin Ön işlemleri

Verilerin dosya uzantısı .bin şeklindedir. Bu dosyayı MATLAB da fid ve fopen komutlarıyla açtıktan sonra 16bit şeklinde sinyaller okutulmuştur. İlk incelemeler yapıldığında gözler görülebilir olan bir taban hattı (baseline) kayması fark edilmiştir. Taban hattı kayması sinyalin kaydı esnasında gerçekleşebilen bir alçak frekans gürültüsüdür. Sinyali şeklen morfolojisini bozmakla birlikte analizler içinde yanıltıcı sonuçlar verebilmektedir. Bu nedenle ilk olarak sinyallerin analizine geçmeden önce bu alçak frekans gürültüsünü yok etmek için bir filtre tasarlanmış ve uygulanmıştır.


Filtre tasarlanırken öncelikle sinyalin frekans spektrumuna bakılmıştır. Frekans spektrumu sinyalin içindeki frekans bileşenlerini bize gösteren ve frekans düzlemiyle ilgili bize bilgi veren bir grafikdir. Bir sinyalin frekans spektrumu fourier dönüşümü ile incelenebilir. Bu dönüşüm MATLAB programında hızlı fourier dönüşümü (fast fourier transform) kullanılarak uygulanmıştır.

4.1.1. EMG sinyallerinin frekans tayfları


EMG sinyalleri daha önce de bahsedildiği gibi 23438 Hz dir. Ayrık zamanlı bir sinyal için fourier dönüşümü ayrık frekanslardaki sinüs sinyallerinin toplamıyla ifade edilmektedir. Bu frekanslar ise sinyalin frekansının 2,3 veya daha büyük katlarıdır. Dijital ortamda alınan sinyaller kesikli olduğundan ayrık zamanlı fourier dönüşümü kullanılmaktadır. Ayrık fourier dönüşümü bizlere simetrik bir frekans tayfı göstermektedir. Bu nedenle frekansın düzlemindeki x-ekseni yalnızca yarısına kadar çizdirilmesi analiz için yeterlidir. Buradaki önemli nokta fourier dönüşümünün kaç noktada alınacağıdır. Daha önce de bahsedildiği gibi ayrık fourier dönüşümünde sinyalin frekansının 2,3 veya daha fazla sinüs sinyallerinden oluşmasından dolayı ideal kabul edilen nokta sayısı sinyalin

örnekleme frekansından daha büyük olan ve 2'nin kuvveti olan ilk sayı bizlere analiz için yeterli olan nokta sayısını vermektedir. Nokta sayısı ne kadar artar ise ayrık frekans düzlemi sinyalin sürekli frekans düzlemine o kadar yakın olacaktır


EMG sinyalimizin örnekleme frekansı 23438Hz olduğundan Fourier dönüşümü için gerekli olan nokta sayısı bu sayıdan büyük ve 2'nin 15. Kuvveti olan 32768 seçilmiştir. Bunun sebebi FFT algoritmasının daha önce bahsedildiği üzere 2'nin kuvvetleri şeklinde çıktı vermesidir. Çıkan değerler için uygun bir frekans eksenini oluşturulmuş ve sinyallerimizin frekans tayfları çizdirilmiştir.



Şekil 4.1. Normal bir EMG sinyalinin Frekans Tayfı



Şekil 4.2. Miyopatik bir EMG sinyalinin Frekans Tayfı




Şekil 4.3. Nöropatik bir EMG sinyalinin frekans tayfı

Frekans tayfını incelediğimizde sinyallerin etkin frekans değerleri yaklaşık 2000Hz civarlarına kadar gelmektedir. Alçak frekans gürültüsü ise 13-16 Hz aralıklarında olduğu bilinmektedir [40]. Bu nedenle üst kesim frekansı 2000 Hz alt kesim frekansı ise 15 Hz olan bir filtre kullanılmasına karar verilmiştir.

4.1.2. Filtreleme işlemi

Filtre sinyale uygulandıktan sonra taban hattı kaymasını başarıyla yok ettiği ve sinyallerin morfolojisini bozmadığı gözlenmiştir. Filtreleme işleminden sonra erindeki dc offset yok edilmiştir. Bunun için ortalama alma yöntemi uygulanmıştır. Son olarak ise tüm sinyaller 8sn lik bir zaman dilimine bölünmüş ve 8 sn lik kısımları incelenmiştir. Genel olarak sinyaller 11.2 sn lik kayıtlardan oluşmaktadır.




Şekil 4.4. Nöropatik bir EMG sinyalinin filtre uygulanmadan önce(kırmızı) ve sonraki(mavi) görüntüsü.

4.2. Sinyallerin MAV Analizi

Filtreleme işleminden sonra EMG sinyallerinin analizi için ilk olarak zaman düzlemi analizine başlanmıştır. 30 normal, 30 miyopatik ve 30 nöropatik olmak üzere toplam 90 EMG sinyali analiz için kullanılmıştır.

Zaman düzleminde analizde ilk olarak daha önce de bahsedilen ve EMG sinyallerinde kasın kasılma gücünü gösteren MAV parametresi analiz edilmiştir. MAV hesaplaması tüm sinyal üzerinden yapılmıştır. Herhangi bir pencereleme veya bölütleme işlemi yapılmamıştır. Bunun sebebi çalışmada EMG sinyalini bir bütün olarak değerlendirebilmek ve daha önce yapıldığı gibi Motor ünite aksiyon potansiyelleri incelenmek yerine genel bir bütün analizi ile ayırt edici parametreler bulabilmektir.

MAV değeri özellikle nöropatik sinyalleri için ayırt edici olabilmesi beklenmektedir. Bunun sebebi nöropatik sinyallerde ani ve tekil olarak gözükabilen aksiyon potansiyellerinin bulunmasıdır. Bu aksiyon potansiyellerini genlikleri sağlıklı EMG sinyallerinde kine göre daha yüksek olduğundan MAV parametresinin normalden daha yüksek olması beklenmektedir.




Şekil 4.5. 90 EMG sinyalinden elde edilen MAV Verilerinin Dağılımı

4.3. Sinyallerin Sıfır Geçiş Oranı Analizi

MAV analizinin ardından EMG sinyallerinin ZCR parametreleri analiz edilmiştir. Daha önce de bahsedildiği üzere sıfır geçiş oranı EMG sinyalinin zaman düzlemindeki analizinden elde edilen aslında bir frekans bilgisidir. Literatüre göre miyopatik sinyallerde aksiyon potansiyelleri düzensiz ve genlikleri düşük olmaktadır. Aynı zamanda miyopatiye sahip EMG verilerinde aksiyon potansiyellerinden sonra seğirme paternleri görülebilmektedir. Bu durum EMG sinyalinin sıfır eksenini normal sinyallere göre daha fazla kesmesine sebep olmalıdır. Bu nedenle miyopatik EMG sinyallerinin ZCR parametresi normal EMG sinyallerine göre daha yüksek olması beklenmektedir.


Tıpkı MAV parametresinde olduğu gibi ZCR parametresi için de sinyalde herhangi bir bölütleme yapılmamış, Hesaplama tüm sinyal üzerinden uygulanmıştır.



Şekil 4.6. 90 EMG sinyalinden elde edilen ZCR Verilerinin Dağılımı

4.4. Sinyallerin Willison Genliğı Analizi

Zaman düzleminde yapılan analizlerin bir diğeri de Willison genliğıdir. Willison genliğı ZCR gibi zaman düzleminde elde edilen bir frekans parametresidir. EMG sinyallerinde bu bir kasılma gücü parametresi olduğı gibi. Miyopatik sinyallerin genliğinin düşük ve ani değışken olması bu parametrenin değıerini artırması beklenmektedir. Bunun tam tersi olarak nöropatik sinyallerde de tekil ve çok yüksek aksiyon potansiyellerinin bulunması bu genliğı miyopatik EMG sinyallerinde göre daha düşük tutmalıdır.




Şekil 4.7..90 EMG sinyalinden elde edilen WA Verilerinin Dağılımı

4.5. Sinyallerin GSY Analizi


Daha önce GSY'nin ne olduğundan ve ne için kullanıldığında bahsedilmişti. RMS ve Varyans analizinden sonra EMG sinyallerinin frekans düzleminde farklılıklarının olup olmadığını analiz etmek için GSY analizi yapılmıştır. GSY hesaplaması için parametrik olmayan bir yöntem olan Welch yöntemi seçilmiştir. Bunun sebebi Welch yönteminin spektral sızıntıları engellemek amacıyla hem pencereleme hem de örtüşme yöntemlerini bir arada kullanmasıdır. EMG sinyali kaotik bir sinyal olduğundan çok kısa sürelerde birden fazla frekans bileşenlerine sahip olabilmektedir.

Welch yöntemi bu frekans bileşenlerini yakalayabilmekte ve frekans analizi için daha doğru bir hesaplama yöntemi sunmaktadır. Matlab ortamında Welch yöntemi pwelch komutu ile kullanılır. Bu komut içine parametre olarak GSY'si hesaplanacak sinyali, pencere büyüklüğünü, örtüşme oranını, GSY hesaplanacak nokta sayısını ve sinyalin örnekleme frekansını alır. Bu parametrelerle birlikte frekans düzlemi de otomatik olarak oluşturulmaktadır.


Pencere büyüklüğü 256 örnek seçilmiştir. Bunun sebebi EMG içindeki aksiyon potansiyellerinin oluşma süresinin 0.1-2 sn arasında oluşmasıdır. Sinyallerin örnekleme frekansı 23438 Hz olduğunu göz önünde bulundurduğumuzda 256 örnek aksiyon potansiyellerinin frekanslarını yakalamak için yeterli olacaktır. %50 örtüşme oranı bize iyi ve yeterli bir frekans çözünürlüğü sağlamaktadır. Bu GSY hesaplanırken her bir pencerenin 128 örneğinin örtüşeceği anlamına gelmektedir. 32768 noktada GSY hesaplatılmıştır. Pwelch komutu GSY hesaplaması yaparken FFT algoritmasını kullanmaktadır dolayısıyla hesaplanan GSY 2 nin kuvvetlerinde sonuç verecektir. Bu nedenle 23438 Hz in üstünde olan ve 2 nin kuvveti olan bu sayı seçilmiştir.



Şekil 4.8. Sağlıklı bir EMG sinyalinin Welch Yöntemiyle Hesaplanmış GSY görüntüsü.



Şekil 4.9. Miyopatik bir EMG sinyalinin Welch Yöntemiyle Hesaplanmış GSY görüntüsü.



Şekil 4.10. Nöropatik bir EMG sinyalinin Welch Yöntemiyle Hesaplanmış GSY görüntüsü.

Normal, Miyopatik ve Nöropatik EMG sinyallerinin GSY grafiklerine bakıldığında hem GSY'lerin genliklerinde hem de morfolojik yapılarında değişiklik gözlemlenmiştir. Miyopatik bir EMG sinyalinin GSY'sinde dalgalanmalar ve yüksek frekans bileşenleri görülmesine rağmen genel frekans gücü sağlıklı bir EMG sinyaline göre düşük nöropatik bir sinyale göre ise çok düşük olduğu gözlemlenebilmektedir.

Nöropatik bir EMG sinyali ise GSY grafiğinde sağlıklı bir EMG sinyaline göre düşük frekanslarda çok yüksek güce sahip olduğu gözlenebilir. Aynı zamanda yüksek frekanslarda gücün çok düşük olduğu gözlenmiştir. Aynı zamanda sinyallerin morfolojik şekilleri frekans güçlerinin farklı dağılımlarda olduğunu göstermektedir bu nedenle


ortalama ve medyan frekanslarda da farklılıklar gözlemlenebileceği düşünülmüştür. Bu farklılıklardan öznitelik çıkarımları öznitelik çıkarımı bölümünde anlatılacaktır.

4.6. Ayrık Dalgacık Dönüşümü Analizi


GSY analizinde gözlenen farklılıkların uygulanan filtre nedeniyle 2000Hz e kadar görülmesinden ötürü EMG sinyallerinin ADD ile analizinde frekans çözünürlüğü daha yüksek alt bantları kullanılarak analizinden elde edilecek verilerin farklılık göstereceği kanısına varılmıştır. Bu nedenle EMG sinyalleri GSY üst frekans sınır 2000 civarına gelecek şekilde bir ADD ye tabi tutulmuştur.

Ayrık dalgacık dönüşümü 2 kademe yapılmıştır. EMG sinyallerinin 23438Hz olması göz önünde bulundurulduğunda ve her bir ADD katmanından elde edilecek yaklaşık alt bantların frekans aralığının yarısını içereceği düşünüldüğünde 2 kademe analiz için yeterli frekans aralığını bize sağlamaktadır. Bu aralık örnekleme frekansının 4'te biri yani 5859.5 Hz dir ve üste yuvarlanarak 5860 Hz kabul edilmiştir. GSY bu frekansın yarısı kadar değerine olacağından 2930 Hz e kadar bir frekans analizi yapılabilir.


[38] Nolu çalışmadan esinlenilerek dalgacık ailesi olarak daebuchies ailesinin 7. dalgacığı kullanılmıştır. Matlab ortamında bu dalgacık 'db7' olarak geçmektedir.



Şekil 4.11. Sağlıklı Bir EMG Sinyalinin 2. Yaklaşık (A2) alt bandının Görüntüsü




Şekil 4.12. Miyopatik Bir EMG sinyalinin 2. Yaklaşık (A2) alt bandının görüntüsü.




Şekil 4.13. Nöropatik Bir EMG Sinyalinin 2. Yaklaşık (A2) Alt Bandının Görüntüsü

ADD işlemi ile alt bantlar elde edildikten sonra A2 bandının GSY hesaplamaları yapılmıştır. Bu hesaplama sinyale uygulanan yöntemin birebir aynısı olarak yapılmıştır. Bu GSY ler incelendiğinde sağlıklı, miyopatik ve nöropatik EMG sinyallerinin alt A2 alt


bandının GSY sinden farklılıklar gözlenmiştir. Bu farklılıklar öznitelik çıkarımı bölümünde detaylı olarak anlatılmıştır.



Şekil 4.14. Sağlıklı Bir EMG Sinyalinin A2 alt bandının GSY görüntüsü.



Şekil 4.15. Miyopatik bir EMG Sinyalinin A2 alt bandının GSY görüntüsü




Şekil 4.16. Nöropatik bir EMG sinyalinin A2 alt bandının GSY görüntüsü

4.7. Öznitelik Çıkarımı

Yapılan analizler sonucunda normal, miyopatik, nöropatik EMG sinyallerini ayırt edebilecek öznitelikler ampirik olarak seçilmiştir. Zaman düzleminde yapılan analizler sonucunda MAV, ZCR ve WA parametreleri öznitelik olarak seçilmiştir. Frekans Düzlemindeki analiz sonucunda da Sinyallerin GSY ların bölütlere ayrılmış ve bu bölütlerin altında kalan alanlar bir öznitelik olarak tercih edilmiştir. Bunun yanı sıra GSY maksimum değeri, ortalama ve medyan frekansları da sınıflar arası değişiklik gösterdiği gözlemlenmiş ve öznitelik olarak seçilmiştir.

Yapılan ADD analizi sonucunda ise EMG sinyallerinin A2 alt bantlarının GSY lerinin gözlemlenen morfolojik özelliklerine göre bir takım matematiksel hesaplamalara tabi tutulmuştur. Bu hesaplamalar, GSY larının integrali, varyans ve RMS değerleri ve son olarak ortalama frekans değerleri öznitelik olarak seçilmiştir.

Bu seçimler sonucu 3 farklı sınıfı ayırt edebilmek için toplam 14 adet öznitelik seçilmiştir. Bu öznitelik 90 sinyal için ayrı ayrı bulunmuş ve 15*90 boyutunda bir matrise atanmıştır. Burada fazlalık kolon skor verisi olarak ayarlanmıştır. Normal EMG sinyalleri için 0, miyopatik EMG sinyalleri 1, nöropatik EMG sinyalleri için 2 rakamları sınıflandırıcı cevabı için ayarlanmıştır. Öznitelik matrisi bir sınıflandırma algoritmasına giriş olarak verilir ve öznitelik matrisindeki herhangi bir satır algoritmanın cevabı olarak seçilir. Sınıflandırma algoritması kalan diğer satırlardaki veriler kullanılarak seçilen cevap satırını çıkış kabul edecek şekilde eğitilir.



Şekil 4.17. Öznitelik çıkarımının şematik gösterimi

5.SINIFLANDIRICI SONUÇLARI

Tezin bu bölümünde oluşturulan öznitelik matrisi ile anlatılan sınıflandırıcıların eğitilmesi, sonrasında bu eğitilen sınıflandırıcıların başarı yüzdeleri ve bu sınıflandırıcıların eğitim verisinde bulunmayan 27 başka EMG sinyali ile test edilmesi ve bu testin sonuçlarından bahsedilecektir. Toplam 3 sınıf olduğundan dolayı bu 3 sınıfı 2 li gruplara bölerek de eğitim ve testler yapılmıştır. Normal-Miyopatik, Miyopatik-Nöropatik ve Normal-Nöropatik olmak üzere 3 farklı grup oluşturulmuş. Bu gruplarında eğitim ve test sonuçlarına bakılmıştır. Bu gruplar için eğitimde 42'şer testte ise 18'er sinyal kullanılmıştır. Ayrıca toplam 90 sinyalden elde edilen veriler ile de K-kat validasyonlu bir eğitim de yapılmış ve sonuçları bu bölümde paylaşılmıştır. Validasyon için K değeri 5 seçilmiştir.

5.1. Sınıflandırıcıların Eğitim ve Test Sonuçları

MatLab ortamının bize sağladığı “Deep Learning Toolbox” aracının altında bulunan “Classification Learner” uygulaması sayesinde ayrıca bir kod yazmadan MatLab da bulunan öntanımlı sınıflandırma algoritmaları eğitilebilmektedir. Bu sayede aynı veri ile birden fazla sınıflandırıcıyı aynı anda eğitmek ve sonuçları görebilmek mümkündür.

Aynı zamanda bu uygulama bize validasyon imkanı da sağlamaktadır. Bu uygulamada k-kat validasyon kullanılarak eğitilen sınıflandırıcının tahmini yüzdesini görebilmek mümkündür.

Analizler sonucunda seçilen ve elde edilen 15*90 lık öznitelik matrisi MatLab daki bu uygulamada sınıflandırıcıların eğitimi için kullanılmıştır. K-kat validasyon için K sayısı 5 olarak seçilmiş sınıflandırıcının cevap satırı 1. satır olarak seçilmiştir. Daha önce de bahsedildiği üzere matrisin 1. satırı skor verilerden oluşmaktadır.

14 öznitelik kullanılarak sağlıklı, miyopatik ve nöropatik sinyallerin sınıflandırılması için gerçekleştirilen eğitim sonucunda bir KNN algoritması olan “Fine KNN” ve karar ağacı algoritması olan “Bagged Trees” sınıflandırma algoritmaları %91,1 oranıyla en yüksek doğruluk oranlarını vermiştir. Her iki sınıflandırıcının eğitim sonucu ortaya çıkan karmaşıklık matrisi aşağıda verilmiştir. Bu matrisler k-kat validasyon sonucu oluşmuştur. K=5 değeri seçildiği için 90 verinin 18 tanesi eğitim içinde validasyon için kullanılmış ve bu 18 veri her bir katta bir pencere gibi data set üzerinde örtüşmesiz olarak kaydırılarak

değişmiştir. Bu sayede algoritme her seferinde 72 veriyle eğitilmiş ve 18 veriyle test edilmiş olur. Yani veri setinin %80 i eğitim için %20 si test için kullanılmıştır.




Şekil 5.1 90 EMG sinyalinden elde edilen öznelilik verileriyle eğitilen Fine KNN sınıflandırıcının eğitim sonucu karmaşıklık matrisi

Oluşan karmaşıklık matrisindeki veriler ile yapılan istatistiki hesaplamalar sonucu Fine KNN sınıflandırıcının eğitim sonucu doğruluğu %91,1, hassasiyeti %93,33, özgüllüğü ise %90 bulunmuştur. Bu verilere ait çizelge aşağıda verilmiştir.

Çizelge 5.1. 90 sinyal verisiyle eğitilen Fine KNN sınıflandırıcı eğitim sonucu karmaşıklık matrisi istatistikleri

Doğruluk	91,1%
Hassasiyet	93,33%
Özgüllük	90%



Şekil 5.2 90 EMG sinyalinden elde edilen öznelik verileriyle eğitilen Bagged Tree sınıflandırıcının eğitim sonucu karmaşıklık matrisi

Eğitim sonucu oluşan Bagged Trees sınıflandırıcıya ait karmaşıklık matrisindeki veriler ile sınıflandırıcının doğruluğu %91,1, hassasiyeti %95, özgüllüğü ise %86,7 olarak hesaplanmıştır. Aşağıdaki çizelgede çizelgesi verilmiştir.


Çizelge 5.2 90 sinyal verisiyle eğitilen Bagged Tree sınıflandırıcı eğitim sonucu karmaşıklık matrisi istatistikleri

Doğruluk	91,1%
Hassasiyet	95%
Özgüllük	86,7%

90 veri ile eğitimlerden sonra veri seti eğitim ve test seti olarak veriler içinden rastgele seçilerek 2 parçaya bölünmüştür. 63 veri eğitim için 27 veri ise test için ayrılmıştır. Bu eğitim ve test seti de kendi içinde 2 li sınıflar şeklinde eğitime ayrılmıştır. Bu sınıflar normal-miyopatik, normal-nöropatik, ve miyopatik-nöropatik tir. Her bir sınıf için 42 eğitim 18 test verisi bulunmaktadır. Tüm eğitimlerin sonucunda oluşan karmaşıklık matrisi K-kat validasyon yöntemi ile oluşmuş ve k değeri 5 seçilmiştir.

14 öznelik kullanılarak Normal ve miyopatik EMG sinyallerinin sınıflandırılması için gerçekleştirilen eğitim sonucunda bir karar ağacı algoritması olan “Bagged Trees” algoritması %97,6 doğruluk ile en yüksek doğruluğu sağlamıştır. Şekil 6.2 de bu

algoritmanın normal ve miyopatik 21'er sinyalden elde edilen toplam 42 sinyalin öznitelikleri ile eğitimi sonucunda oluşan karmaşıklık matrisi verilmiştir. Yani toplam normal ve miyopatik verilerin %70'i eğitim %30'u test için kullanılmıştır.



Şekil 5.3. Normal ve Miyopati sınıfları için eğitilen bagged tree sınıflandırıcının eğitim sonucu karmaşıklık matrisi

Bu karmaşıklık matrisinden yapılan hesaplar ile eğitim sonucu sınıflandırıcının hassasiyeti %95,23 özgüllüğü ise %100 hesaplanmıştır. Bu hesaplamalara dair oluşan çizelge aşağıda verilmiştir.

Çizelge 5.3. Bagged Tree Sınıflandırıcının Eğitim Sonucu Normal ve Miyopatik Sınıflandırmasının İstatistikleri

Doğruluk	97,60%
Hassasiyet	95,23%
Özgüllük	100%

Bu sınıflandırıcı algoritması eğitim sonrasında 2 sınıftan da 9 tane olmak üzere toplam 18 sinyalden elde edilen öznitelik matrisiyle test edilmiştir. Test sonucu sınıflandırmanın doğruluğu %83,33 hesaplanmıştır. Test sonucunda oluşan karmaşıklık matrisi aşağıda verilmiştir.

		Model Bagged Trees	
T r u e	0	7	1
	1	2	8
		0	1
		Predicted Class	

Şekil 5.4. Eğtilen Bagged tree sınıflandırıcının normal ve miyopati sınıfları testi sonucu karmaşıklık matrisi


Karmaşıklık matrisinden hesaplamalar sonucunda hassasiyet %%88.8 özgüllük ise %77.7 çıkmıştır. Bu hesaplamaları içeren çizelge aşağıdaki gibidir.

Çizelge 5.4. Bagged Tree Sınıflandırıcının Test Sonucu Normal ve Miyopatik Sınıflandırmasının İstatistiksel Hesaplamaları

Doğruluk	83,33%
Hassasiyet	88,80%
Özgüllük	77,70%

Normal ve miyopatik sinyal grubunun ardından normal ve nöropatik sinyal grubundan oluşan 42 sinyal ile eğitim yapılmıştır. Yani toplam normal ve nöropatik verilerin %70 i eğitim %30 u test için kullanılmıştır.

Bu eğitim sonucunda en yüksek doğruluk oranını %95,2 oranıyla SVM algoritmasının bir türü olan “Cubic SVM” algoritması vermiştir. Eğitim sonucu oluşan karmaşıklık matrisi aşağıdaki şekilde verilmiştir.



Şekil 5.5. Normal ve nöropati sınıfları için eğitilen Cubic SVM sınıflandırıcının karmaşıklık matrisi

Bu karmaşıklık matrisinden yapılan hesaplar ile eğitim sonucu sınıflandırıcının hassasiyeti %90,47 özgüllüğü ise %100 hesaplanmıştır. Bu hesaplamalara dair oluşan çizelge aşağıda verilmiştir.

Çizelge 5.5. Cubic SVM Sınıflandırıcının Eğitim Sonucu Normal ve Nöropatik Sınıflandırmasının İstatistiksel Hesaplamaları

Doğruluk	95,20%
Hassasiyet	90,47%
Özgüllük	100,00%

Bu sınıflandırıcı daha sonra normal ve nöropatik 18 sinyalden elde edilen öznelik matrisiyle test edilmiş ve test sonucunda %77,7 doğruluk elde edilmiştir. Test sonucunda oluşan karmaşıklık matrisi Şekil 6.5 teki gibidir.

		Model Cubic SVM	
T r u e C l a s s	0	7	2
	2	2	7
		0	2
		Predicted Class	

Şekil 5.6. Eğtilen Cubic SVM sınıflandırıcının normal ve nöropati sınıfları testi sonucu karmaşıklık matrisi

Karmaşıklık matrisindeki verilerle yapılan hesaplamalara neticesinde. Normal ve nöropati sınıflandırması için Cubic SVM sınıflandırıcının hassasiyeti ve özgüllüğü %77,7 çıkmıştır. Hesaplamalara ait çizelge aşağıda verilmiştir.

Çizelge 5.6. Cubic SVM Sınıflandırıcının Test Sonucu Normal ve Nöropatik Sınıflandırmasının İstatistiksel Hesaplamaları

Doğruluk	77,70%
Hassasiyet	77,70%
Özgüllük	77,70%

2 li sinyal gruplarının sonuncusu olan miyopatik ve nöropatik sinyallerden oluşan öznitelik matrisiyle de bir eğitim gerçekleştirilmiştir. Bu eğitim sonucu hem Linear SVM hem de Fine K-NN algoritmaları maksimum doğruluk sonucunu vermiştir. Eğitim sonucu bu doğruluk sonucu %100 dür. Toplam miyopati ve nöropati verilerinin %70 i eğitim %30 u test için kullanılmıştır. Oluşan karmaşıklık matrisi şekil 5.7 da gösterilmiştir.



Şekil 5.7. Miyoapati ve Nöropati sınıfları için eğitilen Linear SVM ve Fine KNN algoritmalarının karmaşıklık matrisi

Bu matristeki veriler kullanılarak yapılan hassasiyet ve özgüllük hesaplamaları %100 çıkmıştır. Hesaplamalara ait çizelge aşağıda verilmiştir.

Çizelge 5.7. Linear SVM ve Fine KNN sınıflandırıcıların eğitimi sonucu miyopatik ve nöropatik sınıflandırmasının istatistiksel hesaplaması

Doğruluk	100,00%
Hassasiyet	100,00%
Özgüllük	100,00%

Sınıflandırıcılar nöropati ve miyopatik 18 sinyalden elde edilen öznitelikler ile test edilmiş ve test sonucu her iki sınıflandırıcı %94,4 oranında bir doğruluk vermiştir. Test sonucu her iki sınıflandırıcının karmaşıklık matrisi bire bir aynı çıkmış ve şekil 5.8 de verilmiştir.

		Models Linear SVM and Fine K-NN	
T r u e C l a s s	1	9	0
	2	1	8
		1	2
		Predicted Class	

Şekil 5.8. Eğtlen Linear SVM ve Fine K-NN sınıflandırıcıların miyopati ve nöropati sınıfları test sonucu karmaşıklık matrisi.


Bu karmaşıklık matrisinden yapılan hesaplamalar sonucu her iki algoritma içinde hassasiyet %88,9 özgüllük ise %100 çıkmıştır. Hesaplamalara ait çizelge aşağıdaki gibidir.

Çizelge 5.8. Linear SVM ve Fine KNN sınıflandırıcıların test sonucu miyopatik ve nöropatik sınıflandırmasının istatistiksel hesaplaması

Doğruluk	94,44%
Hassasiyet	88,90%
Özgüllük	100,00%

2 li grupların eğitim ve testlerinden sonra 3 sınıfı birden sınıflandırmak için eğitimler yapılmış ardından bu sınıflandırıcıların testleri gerçekleştirilmiştir.

63 sinyal ve 14 öznitelik kullanılarak gerçekleştirilen eğitim sonucunda K-NN sınıflandırıcı algoritmalarından biri olan “Fine K-NN” algoritması %93,7 doğruluk sağlamıştır. Tüm gruplara ait verilerin %70 i eğitim için kullanılmış kalan %30 u test için ayrılmıştır. Aşağıdaki şekilde bu algoritmanın eğitimi sonucu oluşan karmaşıklık matrisi görülmektedir



Şekil 5.9. 63 veri ile 3 lü sınıflandırma için Eğitim sonucu Fine K-NN algoritmasının karmaşıklık matrisi

Bu karmaşıklık matrisindeki veriler kullanılarak Fine K-NN sınıflandırıcının eğitim sonucu hassasiyeti %92,85 özgüllüğü ise %95,23 hesaplanmıştır. 3'lü sınıflandırmada pozitif durumu sinyalin miyopati veya nöropati olma durumu olarak ele alınmıştır. Hassasiyet ve özgüllük hesaplamaları aşağıdaki çizelgede verilmiştir.

Çizelge 5.9. Fine KNN sınıflandırıcının eğitim sonucu normal, miyopatik ve nöropatik sınıflandırmasının istatistiksel hesaplaması

Doğruluk	93,70%
Hassasiyet	92,85%
Özgüllük	95,87%

Fine K-NN algoritmasından sonraki en yüksek sonucu Linear (çizgisel) SVM algoritması vermiştir. Bu algoritmanın doğruluğu eğitimi sonucu %90.5 çıkmıştır. Şekil 5.10. da bu algoritmaya ait karmaşıklık matrisi görülmektedir.



Şekil 5.10. 63 veri ile 3 lü sınıflandırma için Eğitimi sonucu Linear SVM algoritmasını karmaşıklık matrisi

Bu matristeki verilerden Linear SVM sınıflandırıcının eğitim sonucu hassasiyeti %85,71 özgüllüğü ise %100 hesaplanmıştır. Hesaplamaların çizelgesi aşağıda verilmiştir.

Çizelge 5.10. Linear SVM sınıflandırıcının eğitim sonucu normal, miyopatik ve nöropatik sınıflandırmasının istatistiksel hesaplaması

Doğruluk	90,50%
Hassasiyet	85,71%
Özgüllük	100%

Eğitilen modeller eğitim verisinde bulunmayan 27 EMG sinyalinin aynı öznitelik verileriyle test edilmek üzere kaydedilmiştir.

Kaydedilen modeller eğitim verisinde kullanılan veriler dışından seçilen 27 EMG sinyali ile test edilmiştir. Bu 27 EMG verisi içinde 9 sağlıklı, 9 miyopatik, 9 nöropatik EMG sinyallerinden oluşmaktadır.

Eğitim sonucu doğruluğu %93,7 olan Fine K-NN sınıflandırıcı algoritması bu 27 veri ile test edildiğinde %81,5 gibi bir doğruluk sağlamıştır. Şekil32. de test sonuçlarının karmaşıklık matrisi görülmektedir.

		Model Fine K-NN		
T r u e C l a s s	0	7		2
	1	1	8	
	2	1	1	7
		0	1	2
		Predicted Class		

Şekil 5.11. Fine-KNN algoritmasının 27 sinyalden elde edilen özniteliklerle 3 lü sınıflandırma test karmaşıklık matrisi.

Karmaşıklık matrisindeki verileri kullanarak yapılan hassasiyet ve özgüllük hesapları sırasıyla %88.2 ve %77.7 çıkmıştır. Hesaplamaların çizelgesi aşağıda verilmiştir.

Çizelge 5.11. Fine KNN sınıflandırıcının test sonucu normal, miyopatik ve nöropatik sınıflandırmasının istatistiksel hesaplaması

Doğruluk	81,50%
Hassasiyet	88,20%
Özgüllük	77,70%

Linear SVM algoritması 27 sinyalde elde edilen öznitelik verileri ile test edildiğinde %81.5 gibi bir doğruluğa sahiptir. Şekil5.12.de Linear SVM sınıflandırıcının test sonucu karmaşıklık matrisi görülmektedir.

		Model Linear SVM		
T r u e C l a s s	0	7		2
	1		9	
	2	2	1	6
		0	1	2
		Predicted Class		

Şekil 5.12. Linear SVM algoritmasının 27 sinyalden elde edilen özniteliklerle 3 lü sınıflandırma test karmaşıklık matrisi

Karmaşıklık matrisindeki verileri kullanarak yapılan hassasiyet ve özgüllük hesapları sırasıyla %88.8 ve %77.7 çıkmıştır. Linear SVM algoritmasının test sonucu istatistiksel hesaplamaları aşağıdaki çizelgedeki gibidir.

Çizelge 5.12. Linear SVM sınıflandırıcının test sonucu normal, miyopatik ve nöropatik sınıflandırmasının istatistiksel hesaplaması

Doğruluk	81,50%
Hassasiyet	88,20%
Özgüllük	77,70%

Sınıflandırıcılar testte eğitimde olduğundan daha az başarı göstermiştir. Bunun sebebi testte kullanılan verilerin dağılımıyla ilgili olabileceği gibi aynı zamanda testte kullanılan veri sayısının da sınıflandırıcıda kullanılan veri sayısından daha az olması olabilir.

Yine de Fine K-NN algoritması eğitimde Linear SVM den daha fazla başarı göstermesine rağmen testte iki algoritmada ayı başarıya sahiptir. Karmaşıklık matrislerine bakıldığında miyopati ve nöropati için ayrı başarı oranlarının olduğu söylenebilir.

2 sınıflandırıcının karmaşıklık matris verilerine baktığımızda ise Fine K-NN algoritmasının nöropati için daha doğru sınıflandırma yaptığını, linear SVM algoritmasının ise miyopati için daha doğru sınıflandırma yaptığını söyleyebiliriz. Buna karşın iki sınıflandırıcının da hassasiyetleri aynı çıkmıştır.

Sonuç olarak tez çalışması kapsamında yapılan uygulamalar sonucu %81,5 oranında doğruluğa sahip sınıflandırıcılar elde edilmiştir. Aynı zamanda 90 veri ile eğitim sonucu olan sınıflandırıcılar %91,1 doğruluğa sahiptir. K-kat validasyondaki K değerinin 5 olduğunu göz önünde bulundurursak 18 verilik bir test veri seti seçmiş olsaydı bu doğruluğu yakalayabilirdik. Sınıflandırıcıların özellikle rahatsızlıklara sahip EMG sinyallerini bulmakta %88,8 oranında bulabilmesi miyopati ve nöropati için doğru öznitelikler bulunduğunu bizlere söyleyebilmektedir. Bu çalışma ileri ki çalışmalarda daha iyi eğitilen ve test sonuçları daha yüksek doğruluklara sahip sınıflandırıcı algoritmalarıyla hastalara fiziksel konsültasyonu minimize edecek, kan testine veya daha ileri seviyelerde biyopsiye ihtiyaç duymadan sadece EMG sinyalleri kullanılarak yüksek doğruluklu bir sistem ve algoritma tasarımının yapılması için ışık olmuştur. Özellikle ALS gibi kritik hastalıkların erken teşhisinin EMG sinyalleri ile mümkün olabileceğini göstermektedir. Çalışmada yapılan tüm eğitim ve test sonuçlarında ortaya çıkan sınıflandırıcı istatistikleri aşağıdaki çizelgede verilmiştir.

Çizelge 5.13. Tüm Sınıflandırıcı İstatistikleri

<u>Eğitim Sonucu Oluşan Sınıflandırıcı İstatistikleri</u>							
Normal-Miyopatik-Nöropatik Üçlü Grubu Sınıflandırması							
90 Sinyal İle Yapılan Eğitim				63 Sinyal İle Yapılan Eğitim			
Sınıflandırıcı	Doğruluk	Hassasiyet	Özgüllük	Sınıflandırıcı	Doğruluk	Hassasiyet	Özgüllük
<u>Fine K-NN</u>	91,10%	93,33%	90%	<u>Fine K-NN</u>	93,70%	92,85%	95,87%
<u>Bagged Tree</u>	91,10%	95%	86,70%	<u>Linear SVM</u>	90,50%	85,71%	100%
<u></u>							
Sınıflandırıcı	Doğruluk	Hassasiyet	Özgüllük	Normal-Miyopatik İkili Grubu Sınıflandırması			
<u>Bagged Tree</u>	97,60%	95,23%	100%				
<u></u>							
Sınıflandırıcı	Doğruluk	Hassasiyet	Özgüllük	Normal-Nöropatik İkili Grubu Sınıflandırması			
<u>Cubic SVM</u>	95,20%	90,47%	100%				
<u></u>							
Sınıflandırıcı	Doğruluk	Hassasiyet	Özgüllük	Miyopatik-Nöropatik İkili Grubu Sınıflandırması			
<u>Linear SVM</u>	100%	100%	100%				
<u>Fine K-NN</u>	100%	100%	100%				
<u></u>							
<u>Test Sonucu Oluşan Sınıflandırıcı İstatistikleri</u>							
Sınıflandırıcı	Doğruluk	Hassasiyet	Özgüllük	Normal-Miyopatik-Nöropatik Üçlü Grubu Sınıflandırması			
<u>Fine K-NN</u>	81,50%	88,20%	77,70%				
<u>Linear SVM</u>	81,50%	88,20%	77,70%				
<u></u>							
Sınıflandırıcı	Doğruluk	Hassasiyet	Özgüllük	Normal-Miyopatik İkili Grubu Sınıflandırması			
<u>Bagged Tree</u>	83,33%	88,80%	77,70%				
<u></u>							
Sınıflandırıcı	Doğruluk	Hassasiyet	Özgüllük	Normal-Nöropatik İkili Grubu Sınıflandırması			
<u>Cubic SVM</u>	77,70%	77,70%	77,70%				
<u></u>							
Sınıflandırıcı	Doğruluk	Hassasiyet	Özgüllük	Miyopatik-Nöropatik İkili Grubu Sınıflandırması			
<u>Linear SVM</u>	94,44%	88,90%	100%				
<u>Fine K-NN</u>	94,44%	88,90%	100%				
<u></u>							

Çalışma sonucunda EMG sinyallerindeki aksiyon potansiyellerini ayırıştırma gibi zorlu ve karmaşık işlemleri kullanmadan, zaman ve frekans düzlemi analizlerinin yanı sıra ayırık dalgacık dönüşümü de kullanarak çıkarılan öznelikler sonucunda başarılı sınıflandırıcı sonuçları elde edilmiştir. Doğrudan EMG sinyallerinden elde edilen öznelik sayısı literatürde bulunan bir çok çalışmadan daha fazladır.



6.SONUÇ VE ÖNERİLER

Tez çalışması kapsamında yapılan analiz ve sınıflandırma uygulamaları sonucunda eğitim sonuçlarının literatürde daha önce yapılan çalışmalara göre daha yüksek veya benzer olduğu görülmektedir. Buna karşın test sonuçları kimi çalışmalardan daha kötü gibi gözükse de yapılan bazı çalışmalardan yüksek bulunmuştur.

EMG sinyallerinin analizinde altın standart kabul edilen aksiyon potansiyelleri ayrıştırması oldukça zahmetli, karmaşık ve uzun süren bir işlemdir. Bu çalışmada EMG sinyali bir bütün olarak ele alınmıştır. Bu nedenle yapılan hesaplamalar daha hızlı olmaktadır. Bunun yanı sıra çıkarılan öznitelik matrisi şu zamana kadar literatürde olan çalışmalardan daha fazla öznitelik sayısına sahiptir.

EMG sinyali çok kaotik bir sinyaldir. Aynı zamanda EKG, EEG gibi otonom bir şekilde alınamaz. Yani hasta kendi isteğiyle ilgili kası kasmadan EMG gerçekleştirilemez. Bu noktada EMG operatörünün rolü çok önemlidir. Hastayı doğru yönlendirmesi, eğer iğne elektrot kullanılıyor ise elektrotun yerleşimi, operatörün sinyalin doğru alınıp alınmadığını anlaması için gerekli olan yeterli eğitimi almış olması çok önemli faktörlerdir. Bu yeterliliklerin sağlanması için EMG çalışmalarında kontrollü veri alınması daha sağlıklı olacaktır.

Miyopati ve nöropati kavramları şemsiye kavramlardır. Bu kavramlar aslında semptomları aynı olan fakat sebepleri farklı olan birden fazla rahatsızlığı işaret etmektedirler. Her ne kadar semptomları aynı olsa da EMG sinyallerinde etkileri farklı olabilmektedir. Öyle ki sağlıklı gibi görünen miyopatik EMG sinyalleri literatürde mevcuttur. Bu nedenle çalışma yapılırken miyopati ve nöropati kavramları altında aynı sınıflara giren hastaların sinyallerinin analiz edilmesi hem analizi kolaylaştıracak hem de öznitelik kalitesini artıracaktır.

Her insanın genetiği birbirinden farklıdır. Dolayısıyla her insanın ulaşabileceği kas gücü hem genetik hem de çevresel etkenlerle değişmektedir. Değişen şeyi sadece kas değil aynı zamanda vücudumuzda ne kadar nöron olduğu bunların uyartımlarının nasıl olacağı da genetik ve çevresel faktörlere bağlıdır. Bu nedenle her insanın EMG sinyali aynı değildir. Özellikle zaman düzleminde genlik bazında kimi sağlıklı insandan alınan EMG sinyali başka bir insandan alınan miyopatik bir sinyale genlik bazında benzeyebilir. Aynı zamanda cinsiyet, yaş, boy-kilo bunları etkileyebilecek faktörlerdir. Bu nedenle bazı zamanlar zaman düzleminde genlik bazında öznitelik bulmaz kolay olmaz. Yine kontrollü

alınan EMG verileriyle yaş ve cinsiyet gruplarını daraltarak yapılacak çalışmalar öznitelik kalitesini dolayısıyla sınıflandırıcının doğruluğunu artırabilir.

Test sonuçlarının bazı çalışmalardan daha düşük olduğundan bahsetmiştik. Fakat literatürde ayrıştırma yöntemi kullanılmadan sağlıklı, miyopati ve nöropati ayrımı yapan sayılı çalışma vardır. Çalışmalar daha çok 2'li sınıf halinde yapılmıştır. Bu 2 li sınıflar arasında sağlıklı ve nöropati ayrımı yapan çalışma sayısı yine azdır. Bu çalışma kapsamında test sonuçlarına bakıldığında miyopati sinyallerinin tespitini çok daha doğru yaptığı karmaşıklık matrislerinden anlaşılabılır. Doğruluk yüzdelerini düşürme sağlıklı ve nöropatik sinyallerin birbirinde daha az ayrılmasından kaynaklıdır. Bu nokta nöropati ve sağlıklı sinyalleri birbirinden ayırabilecek daha başarılı bir öznitelik bulmak sınıflandırıcıların doğruluk oranını yükseltecektir. Yine sınıflandırıcının doğruluk oranları test edilen veri sayısı ile de ilgilidir. Çalışmada testler 27 sinyal ile gerçekleştirilmiş ve EMG sinyalleri bölütlenmemiştir. Sinyal sayısını artırmak doğruluk oranlarını artırabilir.

Çalışma esnasında MatLab ortamının bize sağladığı uygulama ve araçlar kullanılmıştır. Bu uygulama ve araçlar içlerinden daha önceden tanımlı algoritmaları kullanırlar. Bu nedenle bu algoritmaların parametrelerini değiştirmek mümkün değildir. Eldeki verileri daha düzgün şekilde ayırmak ve sınıflandırabilmek için bu algoritmalara ek olarak bir takım optimizasyon algoritmaları kullanılması var olan özniteliklerden daha kalitelisi ve ayırıcı olanını bulmayı sağlayabilir. Bu durum hem sınıflandırıcıları hızlandırmak hem de sınıflandırıcıların doğruluğunu artırmak için kullanılabilir.

KAYNAKLAR

- [1] S. Gallik, "Chapter 7. Muscle Tissue," ed.
- [2] J. G. Webster, *Medical Instrumentation, Application and Design*. 1978.
- [3] "Smooth Muscle". Available: <https://courses.lumenlearning.com/suny-ap1/chapter/smooth-muscle/>
- [4] "Skeletal Muscle". Available: <https://courses.lumenlearning.com/suny-ap1/chapter/skeletal-muscle/>
- [5] "Kas dokusu ve çeşitleri." Available: <http://www.biyolojiportali.com/konu-anlatimi/16/9/Kas-Dokusu-ve-Cesitleri-Destek-ve-Hareket-Sistemi-3>
- [6] "Kas Fizyolojisi," ed.
- [7] "Types of Muscle Contractions: Isotonic and Isometric." Available: <https://courses.lumenlearning.com/suny-fitness/chapter/types-of-muscle-contractions-isotonic-and-isometric/>
- [8] U. F. K. Yücel, "Kuvvetlendirme Egzersizleri," ed.
- [9] R. M. Rangayyan, *BIOMEDICAL SIGNAL ANALYSIS*.
- [10] M. Z. Jamal, "Signal acquisition using surface EMG and circuit design considerations for robotic prosthesis," *Computational Intelligence in Electromyography Analysis-A Perspective on Current Applications and Future Challenges*. IntechOpen., 2012.
- [11] B. F. Erik Stalberg, "The role of electromyography in neurology," *Electroencephalography and clinical Neurophysiology*, vol. 103, pp. 579-598, 1997.

- [12] "What is a Myopathy?" Available: <https://www.manchesterneurophysio.co.uk/adults/conditions-we-treat/orthopaedic-msk-conditions/myopathy/what-is-myopathy.php>
- [13] "Neuropathy (Peripheral Neuropathy)." Available: <https://my.clevelandclinic.org/health/diseases/14737-neuropathy>
- [14] S. C. Center. "5 Types of Neuropathy and What to Do About Them." Available: <https://www.spinecorrectioncenter.com/5-types-of-neuropathy-and-what-to-do-about-them/>
- [15] L. D. W. JAY M. WEISS, JULIE K. SILVER, *Easy EMG A Guide to Performing Nerve Conduction Studies and Electromyography*. Elsevier Inc., 2016.
- [16] M. S. M. Nikolic, "Detailed Analysis of Clinical Electromyography Signals EMG Decomposition, Findings and Firing Pattern Analysis in Controls and Patients with Myopathy and Amyotrophic Lateral Sclerosis," Ph.D, Faculty of Health Science, University of Copenhagen, 2001.
- [17] V. K. B. Archana B. Kanwade, "Feature Extraction of EMG Signals in Time and Frequency Domain for Myopathy, Neuropathy and Healthy Muscle," presented at the 3rd International Conference on Electrical, Electronics, Engineering Trends, Communication, Optimization and Sciences, 2016.
- [18] P. P. Angkoon Phinyomark, C. Limsakul, "Feature reduction and selection for EMG signal classification," *Expert Systems with Applications*, vol. 39 pp. 7420–7431, 2012.
- [19] T. M. William Gallagher, J. Huggins, M. Shinohara, D. Gao, R. Menassa, J. Ueda, "An Improved Human-Robot Interface by Measurement of Muscle Stiffness," presented at the International Conference on Biomedical Robotics and Biomechatronics, Roma, Italy., June 24-27, 2012.

- [20] Z. CÖMERT, "Fourier Dönüşümü Matlab Uygulamalı," ed, .2015.
- [21] Y. D. D. İ. AYDIN, "Frekans domain'inde İşlemler," ed.
- [22] A. Erdamar, "Spektral Analiz," ed, 2017.
- [23] "Wavelet Transform." Available: <http://gwyddion.net/documentation/user-guide-en/wavelet-transform.html>
- [24] B. Y. S. Grace Chang, M. Vetterli, "Adaptive Wavelet Thresholding for Image Denoising and Compression," *IEEE TRANSACTIONS ON IMAGE PROCESSING*, vol. 9, pp. 1532-1546, 2000.
- [25] A. Erdamar, "Dalgacık Dönüşümü," ed, 2017.
- [26] S. J. Pan Qi, J. G. L. Calvo, P. Schweitzer, "Discrete Wavelet Transform optimal parameters estimation for arc fault detection in low-voltage residential power networks," *Electric Power Systems Research*, vol. 143, February 2017.
- [27] N. S. Altman, "An introduction to kernel and nearest-neighbor nonparametric regression," *The American Statistician*, vol. 46, no. 3, pp. 175–185.
- [28] D. C. D. L. Massart, "Alternative k-nearest neighbour rules in supervised pattern recognition : Part 1. k-Nearest neighbour classification by using alternative voting rules," *Analytica Chimica Acta*, vol. 136, pp. 15-27, 1982.
- [29] "KNN (K nearest neighborhood, en yakın k komşu)." Available: <http://bilgisayarkavramlari.sadievrenseker.com/2008/11/17/knn-k-nearest-neighborhood-en-yakin-k-komsu/>
- [30] "K-Nearest Neighbors." Available: http://www.psgminer.com/help/k_nearest_neighbors_.htm?ms=AAA=&mw=MjQw&st=MA==&sct=OTczLjU5OTk3NTU4NTkzNzU=

- [31] W. S. Noble, "What is a support vector machine?," *NATURE BIOTECHNOLOGY*, vol. 24, no. 12, pp. 1565-1567, 2006.
- [32] R. Gandhi. (2008). "Support Vector Machine — Introduction to Machine Learning Algorithms." Available: <https://towardsdatascience.com/support-vector-machine-introduction-to-machine-learning-algorithms-934a444fca47>
- [33] S. RAY. (2007). "Understanding Support Vector Machine algorithm from examples (along with code)." Available: <https://www.analyticsvidhya.com/blog/2017/09/understaing-support-vector-machine-example-code/>
- [34] (2018). "Machine Learning —Classification — Support Vector Machine— Kernel Trick— Part 10." Available: <https://medium.com/@ekrem.hatipoglu/machine-learning-classification-support-vector-machine-kernel-trick-part-10-7ab928333158>
- [35] J. R. OUINLAN, "Decision Trees and Decisionmaking," *IEEE: TRANSACTIONS ON SYSTEMS. MAN. AND CYBERNETICS*, vol. 20, no. 2, 1990.
- [36] E. K. Ulgen. "Makine Öğrenimi Bölüm-5 (Karar Ağaçları)." Available: <https://medium.com/@k.ulgen90/makine-%C3%B6%C4%9Frenimi-b%C3%B6l%C3%BCm-5-karar-a%C4%9Fa%C3%A7lar%C4%B1-c90bd7593010>
- [37] (2018). "K-Fold Cross Validation" Available: <https://medium.com/datadriveninvestor/k-fold-cross-validation-6b8518070833>
- [38] A. Subasi, "Classification of EMG signals using PSO optimized SVM for diagnosis of neuromuscular disorders," *Computers in Biology and Medicine*, vol. 43, pp. 576–586, 2013.
- [40] H. Küçük, "EMG İŞARETLERİNİN TANI DESTEK AMAÇLI SINIFLANDIRILMASI", Doktora Tezi, Ondokuz Mayıs Üniversitesi, Fen Bilimleri Enstitüsü, 2015.