

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

MAKİNE ÖĞRENME ALGORİTMALARIYLA ALT ÇENEYE BAĞLI
KASLARIN YORGUNLUK ANALİZİ VE BRUKSİZM TANI
YÖNTEMLERİNİN GELİŞTİRİLMESİ

Temel SÖNMEZOCAK

DOKTORA TEZİ

Elektronik ve Haberleşme Mühendisliği Anabilim Dalı

Elektronik Programı

Danışman

Doç. Dr. Serkan KURT

Kasım, 2021

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**MAKİNE ÖĞRENME ALGORİTMALARIYLA ALT ÇENEYE BAĞLI
KASLARIN YORGUNLUK ANALİZİ VE BRUKSİZM TANI
YÖNTEMLERİNİN GELİŞTİRİLMESİ**

Temel SÖNMEZOCAK tarafından hazırlanan tez çalışması 05.11.2021 tarihinde aşağıdaki jüri tarafından Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Elektronik ve Haberleşme Mühendisliği Anabilim Dalı, Elektronik Programı **DOKTORA TEZİ** olarak kabul edilmiştir.

Doç. Dr. Serkan KURT
Yıldız Teknik Üniversitesi
Danışman

Jüri Üyeleri

Doç. Dr. Serkan KURT, Danışman
Yıldız Teknik Üniversitesi

Doç. Dr. Ahmet SERBES, Üye
Yıldız Teknik Üniversitesi

Doç. Dr. Mustafa Emre AYDEMİR, Üye
İstanbul Esenyurt Üniversitesi

Doç. Dr. Umut Engin AYTEN, Üye
Yıldız Teknik Üniversitesi

Doç. Dr. Aysel ERSOY, Üye
İstanbul Üniversitesi-Cerrahpaşa

Danışmanım Doç. Dr. Serkan KURT sorumluluğunda tarafımca hazırlanan “Makine Öğrenme Algoritmalarıyla Alt Çeneye Bağlı Kasların Yorgunluk Analizi ve Bruksizm Tanı Yöntemlerinin Geliştirilmesi” olarak bu tez çalışma hazırlanmıştır. Bu tez çalışması kapsamında etik rapor alındığında tezin başlığı olan “Kas Yorgunluğu ve Destek Sistem Tasarımı” sonrasında “Makine Öğrenme Algoritmalarıyla Alt Çeneye Bağlı Kasların Yorgunluk Analizi ve Bruksizm Tanı Yöntemlerinin Geliştirilmesi” olarak tez jürisi tarafından değiştirilmiştir. Tez çalışma konusu değiştirilmemiştir. Bu çalışmada veri toplama ve veri kullanımında gerekli yasal izinleri aldığımı, diğer kaynaklardan aldığım bilgileri ana metin ve referanslarda eksiksiz gösterdiğimi, araştırma verilerine ve sonuçlarına ilişkin çarpıtma ve/veya sahtecilik yapmadığımı, çalışmam süresince bilimsel araştırma ve etik ilkelerine uygun davrandığımı beyan ederim. Beyanımın aksinin ispatı halinde her türlü yasal sonucu kabul ederim.

Temel SÖNMEZOCAK

İmza

Bu alıřma, Yıldız Teknik Üniversitesi Teknopark Koordinatörlüğünün Bruksizm Tanı ve Tedavi Sistem Geliştirilmesi isimli G022020 numaralı projesi ile desteklenmiştir.

Aileme

Ve

Biricik eşime

TEŞEKKÜR

Bu tez çalışmasının en başından beri benden maddi ve manevi desteğini esirgemeyen ve sürekli olarak bu çalışmada bana yol gösteren başta danışman hocam Doç. Dr. Serkan KURT hocama ve de tez izlemede sürecinde bana yol değerli hocalarım Doç. Dr. Ahmet SERBES ve Doç. Dr. Mustafa Emre AYDEMİR hocalarıma ve de medikal katkılarından dolayı Doç Dr. Raşit Cevizli hocama çok teşekkür ederim. Ayrıca Maddi ve manevi yönden her zaman beni destekleyen üzerimde büyük hakları olan aileme ve eşime teşekkürü bir borç bilirim.

Temel SÖNMEZOCAK

İÇİNDEKİLER

SİMGE LİSTESİ	ix
KISALTMA LİSTESİ	x
ŞEKİL LİSTESİ	xii
TABLO LİSTESİ	xiv
ÖZET	xv
ABSTRACT	xvii
1 GİRİŞ	1
1.1 Literatür Özeti.....	1
1.1.1 Bruksizm Tanılama Yöntemleri	1
1.1.2 Dış İskelet Kaslarında Yorgunluk Tanısı.....	4
1.1.3 Biyolojik Sinyaller için Filtreleme Yaklaşımları.....	7
1.2 Tezin Amacı	9
1.3 Orjinal Katkı.....	10
2 TEMEL BİLGİLER	12
2.1 Alt Çenenin Anatomik Yapısı.....	12
2.1.1 Masseter Kası	12
2.1.2 Temporal Kası	13
2.1.3 Medial Pterygoid Kası.....	13
2.1.4 Lateral Pterygoid Kası	14
2.2 İskelet Kasların Yapısı	14
2.2.1 Motor Ünite.....	15
2.2.2 Kasların Kasılma Durumları.....	16
2.2.3 Kas Yorgunluğu.....	19
2.3 Elektromiyografi (EMG) Sistemleri	20
2.4 Mikroelektromekanik (MEMS) Akselerometre Sistemler	22
3 MATERYAL VE YÖNTEMLER	25
3.1 Sinyal Kayıtlarının Elde Edilmesi ve Ön İşleme Çalışmaları.....	25
3.1.1 Elektromiyografi (EMG) Tabanlı Ölçüm ve Veri Kayıt Sistemi... 25	
3.1.2 Akselerometre (MEMS) Tabanlı Ölçüm ve Veri Kayıt Sistemi.... 31	
3.2 Bruksizm Tanılaması için Parametrik Özellikler	33
3.2.1 Sinyallerin Genlik ve Frekans Özellikleri	33

3.2.2	Otoregresyon (AR) Parametreleri.....	38
3.3	Fourier Dönüşümü.....	40
3.4	Dalgacık Dönüşümü.....	42
3.4.1	Sürekli Dalgacık Dönüşümü	42
3.4.2	Ayrık Dalgacık Dönüşümü.....	43
3.5	Yapay Sinir Ağları	48
3.5.1	YSA'ların Tarihçesi	48
3.5.2	YSA'ların Avantaj ve Dezavantajları.....	49
3.5.3	Yapay Sinir Hücresinin Yapısı.....	50
3.5.4	YSA'ların Eğitilmesi	52
3.5.5	YSA'lar için Öğrenme Algoritmaları.....	55
3.6	Sınıflandırma Algoritmaları.....	56
3.6.1	Karar Ağacı Algoritması.....	57
3.6.2	Lineer Diskriminant Algoritması.....	59
3.6.3	Destek Vektör Makine Algoritması	59
3.6.4	Naive Bayes Algoritması	61
3.6.5	En Yakın Komşuluk Algoritması	62
3.7	Sınıflandırmada Performans Kriterleri.....	63
3.7.1	Karmaşıklık Matrisi	64
3.7.2	ROC Eğrileri	65
3.7.3	Ortalama Karesel Hata ve Doğrusallık İlişkisi	66
3.8	Genişletilmiş Kalman (EKF) Filtre Yaklaşımı	67
4	BRUKSİZM TANILAMASINDA MAKİNE ÖĞRENME ALGORİTMALARIYLA YAPILAN ANALİZ ÇALIŞMALARI	70
4.1	EMG Sinyalleri Kullanılarak Yapılan Analiz Çalışmaları	70
4.2	MMG Sinyalleri Kullanılarak Yapılan Analiz Çalışmaları	75
4.3	EKF Filtreleme Modeliyle Adaptif bir Yöntem Geliştirilmesi	76
5	YAPILAN ANALİZLERİN SONUÇ VE BULGULARI	83
5.1	EMG Sinyalleriyle Yapılan Analizlerin Sonuç ve Bulguları.....	83
5.2	MMG Sinyalleriyle Yapılan Analizlerin Sonuç ve Bulguları.....	93
5.3	EKF Filtre Modeliyle Adaptif Yöntemin Performans Sonuçları	98
6	SONUÇ VE ÖNERİLER	107
	KAYNAKÇA	112

A ETİK KURUL RAPORU	125
TEZDEN ÜRETİLMİŞ YAYINLAR	127

SİMGE LİSTESİ

ΔW	Ağırlık Değişim Miktarı
δ	Çıkış Hata Miktarı
dB	Desibell
dbN	Daubachies dalgacığı (N ölçeklemeli)
$\psi(t)$	Dalgacık Fonksiyonu
D_{jk}	Dalgacık Detay Bileşenleri
E_j	Dalgacık Entropisi
$AgCl$	Gümüşklorür
P_k	Hata Kovaryansı
w_k	İşlem Gürültüsü
$J(n)$	Jakobian Matrisi
$k\Omega$	Kilo Ohm
K_k	Kalman Kazancı
Q	Kalite Faktörü
μ_m	Marquardt Parametresi
μV	Mikro Volt
μF	Mikro Farad
nF	Nano Farad
α	Momentum Katsayısı
v_k	Ölçüm Gürültüsü
$\phi(t)$	Ölçekleme Fonksiyonu
F_s	Örnekleme Frekansı
λ	Öğrenme Katsayısı
R^2	Regresyon Korelasyonu

KISALTMA LİSTESİ

AAC	Absolute Amplitude Change (Mutlak Genlik Değişimi)
ADD	Ayrık Dalgacık Dönüşümü
ANS	Autonomic Nervous System (Otonom sinir Sistemi)
AR	Autoregression (Oto regresyon)
BM	Bulanık Mantık
CMMR	Common Mode Rejection (Ortak mod bastırma oranı)
DASD	Difference Absolute Standard Deviation
DT	Decision Tree (Karar Ağacı)
DP	Doğru Pozitif
DN	Doğru Negatif
EMG	Elektromiyografi
EKF	Extended Kalman Filter (Genişletilmiş Kalman Filtresi)
EKG	Elektrokardiyografi
EEG	Elektroensefalografi
EDA	Elektrodermal Aktivite
FFT	Fast Fourier Transform
GA	Genetik Algoritma
HR	Heart Rate (Kalp Atış Hızı)
KNN	K- Nearest Neighbour (En Yakın Komşuluk)
LM	Levenberg-Marquart
LD	Linear Discriminant (Lineer Diskriminant)
LOG	Log Detector
MFL	Maksimum Fraktal Uzunluğu
MVC	Maximum Voluntary Clenching (Maksimum Gönüllü Kasılma)
MAV	Mean Absolute Value (Ortalama Genlik)
MMG	Mekanomiyogram
MEMS	Mikro elektromekanik Sistemler
MUAP	Motor Ünite Aksiyon Potansiyeli
MNF	Mean Frequency (Ortalama Frekans)
MDF	Median Frequency (Medyan Frekans)
MN	Measurement Noise (Ölçüm Gürültüsü)

MLP	Multi Layer Perceptron (Çoklu Katmanlı Perseptron)
MSE	Mean Square Error
MVC	Maximum Voluntary Contraction
NB	Naive Bayes
PN	Process Noise (İşlem Gürültüsü)
PMSD	Percentage Mean Square Difference
PSD	Power Spectral Density (Güç Spektrum Yoğunluğu)
PSG	Polisomnografi
RBF	Radial Basis Function (Radyal Tabanlı Fonksiyon)
RF	Random Forest (Rastgele Orman)
RMS	Root Mean Square
RMSE	Root Mean Square Error
RDC/TMD	Research Diagnostic Criteria for Temporomandibular Disorders
ROC	Receiver Operating Characteristic (Alıcı İşletim Karakteristiği)
SD	Standard Deviation (Standart Sapma)
SDD	Sürekli Dalgacık Dönüşümü
SVM	Support Vector Machine (Destek Vektör Makine)
SMR	Spektral Moment Oranı
SNR	Signal to Noise Rate (Sinyal Gürültü Oranı)
SSC	Slope Sign Change (Eğim İşareti Değişimi)
VAR	Varyans
WAMP	Willison Amplitude (Willison Genliği)
WL	Wavelength (Dalga boyu)
WShEn	Wavelet Shannon Entropy
YSA	Yapay Sinir Ağları
YP	Yanlış Pozitif
YN	Yanlış Negatif
ZC	Zero Crossing (Sıfır Geçiş Sayacı)

ŞEKİL LİSTESİ

Şekil 2.1	Masseter ve temporal kasların anatomik görünümü	13
Şekil 2.2	Medial ve lateral pterygoid kasların anatomik görünümü	14
Şekil 2.3	Çizgili kas yapısı.....	15
Şekil 2.4	Motor ünite	16
Şekil 2.5	Motor nöronlar ile sinir kas bağlantısı.....	17
Şekil 2.6	Aksiyon potansiyelin dalga şekli.....	18
Şekil 2.7	Kas hücresinde depolarizasyonun oluşması.....	18
Şekil 2.8	Örnek bir deneğe ait EMG sinyal grafikleri.....	21
Şekil 2.9	MUAP sinyallerinden EMG sinyal bileşenlerin elde edilmesi	22
Şekil 2.10	MEMS akselerometre ile örnek bir denekten alınan MMG sinyali.....	22
Şekil 2.11	MMG sinyalin elde edilmesi	23
Şekil 2.12	MEMS akselerometre iç yapısı.....	24
Şekil 3.1	AD624 Enstrümantasyon yükseltici blok devre yapısı	26
Şekil 3.2	İkinci dereceden Butterworth band geçiren filtre devre yapısı.....	26
Şekil 3.3	Filtre yapılarına ait bode diagramları ve transfer fonksiyonları	27
Şekil 3.4	EMG sinyalin filtreleme sonrası frekans spektrumu.....	27
Şekil 3.5	Deneyler için EMG ölçüm ve kayıt sistemi.....	29
Şekil 3.6	Akselerometre sinyallerinin FFT spektrumu ile genlik değişimleri.....	32
Şekil 3.7	MEMS tabanlı bruksizm tanılama sistemine ait deneysel düzenek	33
Şekil 3.8	Örnek bir EMG sinyaline ait frekans-güç spektrumu	41
Şekil 3.9	EMG sinyalinin detay ve yaklaşım bileşenlerine ayrıştırılması	45
Şekil 3.10	Daubechies fonksiyonu (db4 8 seviyeli)	46
Şekil 3.11	EMG sinyalinin dalgacık entropi değerlerinin elde edilmesi	47
Şekil 3.12	Örnek bir YSA yapısı	48
Şekil 3.13	Biyolojik sinir hücresi.....	50
Şekil 3.14	Yapay sinir hücresi	51
Şekil 3.15	Örnek bir karar ağacı yapısı	57
Şekil 3.16	Örnek bir destek vektör makine sınıflandırma grafiği.....	60
Şekil 3.17	KNN algoritması çalışma akış diyagramı	63
Şekil 3.18	Örnek bir ROC eğrisi	65
Şekil 3.19	Çalışmada kullanılan EKF modeli.....	67

Şekil 4.1 YSA, AR katsayıları ve dalgacık entropisine dayalı uygulama	72
Şekil 4.2 Giriş özelliklerine göre oluşturulmuş YSA mimari yapıları	74
Şekil 4.3 MEMS tabanlı sistemin uygulamasına ait blok şeması	75
Şekil 4.4 PN sabit tutulmasıyla MN değişikliklerinin MSE ile ilişkisi	79
Şekil 4.5 MN sabit tutulmasıyla PN değişikliklerinin MSE ile ilişkisi	79
Şekil 4.6 Geliştirilen adaptif EKF modeli	80
Şekil 5.1 Bruksizm aktivitesi esnasında örnek bir denekten alınmış EMG sinyalleri	83
Şekil 5.2 Kasılma süresince MNF/MDF özelliklerin değişim grafikleri	84
Şekil 5.3 Alt çenedeki kas yorgunluğu durumlarındaki MNF/MDF dağılımları ..	85
Şekil 5.4 Giriş özellik sayılarının YSA performans analizi için R katsayıları	86
Şekil 5.5 Giriş özellik sayılarının YSA performans analizi için ROC eğrileri	86
Şekil 5.6 DT, KNN, LD, NB ve SVM'ye ait sınıflandırma performansları	88
Şekil 5.7 YSA giriş özelliklerine göre elde edilen MSE histogram grafikleri	91
Şekil 5.8 YSA giriş özelliklerine göre elde edilen validasyon performansları	91
Şekil 5.9 YSA giriş özelliklerine göre yapılmış regresyon analizler	92
Şekil 5.10 MNF, MDF, MFL, ZC ve DASD kullanılmasıyla karmaşıklık matrisleri	95
Şekil 5.11 MNF, MDF, MFL, ZC ve DASD özelliklerin kullanılmasıyla YSA'dan elde edilen doğruluk oranlarını gösteren karmaşıklık matrisleri	96
Şekil 5.12 MNF, MDF, MFL, ZC ve DASD özelliklerin kullanılmasıyla YSA'dan elde edilen doğruluk oranlarını gösteren ROC eğrileri	97
Şekil 5.13 EMG sinyalin zaman domenindeki geliştirilen EKF modeliyle karşılaştırmalı filtrelenmiş grafikler	98
Şekil 5.14 MMG sinyalin zaman domenindeki geliştirilen EKF modeliyle karşılaştırmalı filtrelenmiş grafikler	99
Şekil 5.15 Filtrelenmiş ve filtrelenmemiş EMG sinyalin frekans spektrumları ..	100
Şekil 5.16 Filtrelenmiş ve filtrelenmemiş MMG sinyalin frekans spektrumları ..	101
Şekil 5.17 Geliştirilen adaptif EKF sisteminin v_k değerlerinin makine öğrenme algoritmalarla sınıflandırmadaki performanslar için karmaşıklık matrisleri	104
Şekil 5.18 Filtrelenmiş ve filtrelenmemiş EMG sinyallerden elde edilen özelliklerin dağılımları	105
Şekil 5.19 Filtrelenmiş ve filtrelenmemiş MEMS tabanlı MMG sinyallerden elde edilen özelliklerin dağılımları	106

TABLO LİSTESİ

Tablo 3.1	EMG tabanlı sinyaller için kullanılan özelliklerin korelasyonları	37
Tablo 3.2	MEMS tabanlı sinyaller için kullanılan özelliklerin korelasyonları	38
Tablo 3.3	Aktivasyon fonksiyon örnekleri	52
Tablo 3.4	Karmaşıklık matris tablosu	64
Tablo 4.1	AR(12) giriş özellikleriyle oluşturulmuş YSA performansları	73
Tablo 4.2	Dalgacık entropisi giriş özellikleriyle oluşturulmuş YSA performansları	73
Tablo 4.3	Dalgacık entropisi ve AR(12) giriş özelliklerin birlikte kullanılmasıyla oluşturulmuş YSA performansları	74
Tablo 4.4	Filtre performans analizlerinde kullanılan özellikler	81
Tablo 5.1	YSA kullanılmasıyla elde edilen karmaşıklık matrisi	87
Tablo 5.2	Özellik sayılarına göre sınıflandırmadaki doğruluk oranları	89
Tablo 5.3	AR ve WShEn özellikleriyle YSA'dan oluşan karmaşıklık matrisler	93
Tablo 5.4	Özellik sayısına göre sınıflandırma sonuçları	94
Tablo 5.5	Farklı (k-fold) değerleriyle elde edilen doğruluk oranları	102

Makine Öğrenme Algoritmalarıyla Alt Çeneye Bağlı Kasların Yorgunluk Analizi ve Bruksizm Tanı Yöntemlerinin Geliştirilmesi

Temel SÖNMEZOCAK

Elektronik Haberleşme Mühendisliği Anabilim Dalı

Doktora Tezi

Danışman: Doç. Dr. Serkan KURT

Bruksizm, çiğneme kaslarının kasılarak dişlerin gıcırdaması ve alt çenenin sıkılması olarak bilinir. Bruksizmden dolayı dişlerin aşınması, çene ağrısı ve çene kaslarında oluşan yorgunluk nedeniyle hastaların yaşam kalitesini olumsuz etkilenir. Teşhisi, konusunda uzmanlık ve klinik ortam gerektirmesiyle zor ve zaman alıcıdır. Teşhis genellikle uyku sırasında masseter kaslarının elektromiyografi aktivitesinin izlenmesiyle yapılır. Yüzey elektromiyografisi sinyallerinin kullanılması ekonomik ve pratik bir çözüm olmasına rağmen, çevresel etkilerden dolayı çene kaslarının yorgunluk ve parafonksiyonel hareketlerini elektromiyografi sinyalleri ile tespit etmek zordur. Bu tez çalışmasında hem elektromiyografi hem de akselerometre tabanlı olarak kaslardan elde edilen sinyallerin etkin bir şekilde filtrelenmesinde genişletilmiş Kalman filtre modeline dayalı yeni bir adaptif yöntem geliştirtirilmiştir. Elde

edilen sinyallerin farklı genlik ve frekans özellikleri, sinyallerin dalgacık dönüşümleriyle Shannon Entropi özellikleri ve de otoregresyon analiziyle de regresyon katsayı özellikleri değerlendirilmiştir. Elde edilen bu özellikler, bruksizm esnasında ortaya çıkan çene sıkma ve diş gıcırdatma eylemlerine ek olarak ayrıca alt çenede oluşan kas yorgunluk durumları da dikkate alınarak belirlenmiştir. Bu özelliklerden sadece en etkili olanları yapay sinir ağlarıyla belirlenerek daha az özellikler ile bruksizm esnasında ortaya alt çene aktiviteleri ve kas yorgunlukları belirlenerek en etkili bruksizm tanılması bu tez çalışmasında yapılabilmektedir. Dolayısıyla tanılama için beş farklı makine öğrenme algoritmaları ayrı ayrı kullanılarak alt çene aktiviteleri sınıflandırılmış, bu algoritmaların da birbirlerine göre performansları karşılaştırılmıştır. Bruksizmin en etkin tanılmasında ayrıca hem elektromiyografi tabanlı hem de akselerometre tabanlı olmak üzere klinik bir ortama gereksinim kalmadan ev ortamında veri kaydına da olanak sağlayan, giyilebilir ve düşük maliyetli güvenilir bir sistem geliştirilmiştir.

Anahtar Kelimeler: Adaptif filtre yapıları, elektromiyografi, mikroeletromekanik sistemler, sınıflandırma algoritmaları, yapay sinir ağları.

Machine Learning Algorithms in Fatigue Analysis of Lower Jaw Muscles and Development of Bruxism Diagnostic Methods

Temel SÖNMEZOCAK

Department of Electronic and Communication Engineering

Doctor of Philosophy Thesis

Supervisor: Assoc. Prof. Dr. Serkan KURT

Bruxism is known as grinding of the teeth and clenching of the lower jaw by contraction of the chewing muscles. It negatively affects the quality of life of patients due to tooth wear, pain and fatigue in the jaw muscles. Diagnosis is difficult and time-consuming, requiring a clinical setting. The diagnosis of bruxism is usually made by monitoring the electromyographic activity of the masseter muscles during sleep. Although the use of surface electromyography signals is an economical and practical solution, it is difficult to detect fatigue and parafunctional movements of the jaw muscles with electromyography signals due to peripheral effects. In this thesis, by developing a new adaptive method based on the Extended Kalman Filter model for lower jaw muscles, different amplitude and frequency features for the effectiveness of bruxism diagnosis, Shannon entropy features with wavelet transforms of signals and regression coefficient

features with autoregression analysis are obtained. These features are determined by considering the muscle fatigue conditions in the lower jaw, in addition to the jaw clenching and teeth grinding actions that occur during bruxism. Only the most effective of these features are determined by artificial neural networks and using lesser features could be made by determining lower jaw activities and muscle fatigue during bruxism. Therefore, for diagnosis, five different machine learning algorithms are used separately and mandibular activities are classified, and the performances of these algorithms are compared with each other. In the most effective diagnosis of bruxism, a wearable and low-cost system is developed that allows data recording in the home environment, based on electromyography and accelerometer-based, without the need for a clinical environment.

Keywords: Adaptive filter structures, electromyography, microelectromechanical systems, classification algorithms, artificial neural networks.

1.1 Literatür Özeti

Bruksizm günümüzde yaygın olarak görülen kronik, dental bir problemdir. Tanı ve tedavi için etkili bir yöntemi yoktur [1]. Literatürde birçok tanımı bulunmaktadır. Bruksizm dişlerin parafonksiyonel olarak gıcırdaması ve alt çenenin istemsiz olarak sıkılması olarak tanımlanır [2], [3]. Bruksizmi olan hasta kişilerin tanısında çiğneme kaslarında hipertrofi oluşumu, dişlerde aşınma, özellikle de implantlarda kırıklar, diş kayıpları, çene kaslarında yorgunluk ve ağrı, alt çene eklemlerinde ağrı ve temporomandibular eklem diski deplasmanları görülmektedir. Bruksizmin yarattığı bu etkiler fizyolojik yapının çok üzerinde bir kuvvet uygulanmasından kaynaklanmaktadır [4].

Bruksizm genellikle gece görülmektedir. Normal durumda uyku ve dinlenme esnasında alt çene açıktır ve dişler temasta olmaz. Alt çenede bulunan kaslar gevşek durumdadır. Normalde ısırma kuvveti 2-12 kg olmaktadır. Bruksizmde ise bu değer 22-26 kg arasında görülmekte ve de uzun süre diş sıkma durumunda kaslarda zorlanma, ağrı ve kas yorgunluğu olarak görülmektedir [5], [6]. Dolayısıyla Bruksizmin tanılama literatür araştırması yapılırken kas yorgunlukları ile ilgili olarak yapılan çalışmalar da dikkate alınmıştır. Ayrıca etkin tanılama alt çene kaslarından alınan biyolojik işaretlerin tamamen gürültülerden arındırılması da başlıca önemli bir konudur. Bu sebeple filtreleme alanlarında yapılan çalışmalar da ayrıca bu literatür araştırmasında dikkate alınmıştır.

1.1.1 Bruksizm Tanılama Yöntemleri

Bruksizm tanısı klinik olarak yapılmaktadır. Hastadan alınan anamnez (diş gıcırdama sesleri), diş aşınması, çiğneme kaslarındaki hipertrofi, baş ağrısı, çiğneme kaslarındaki ağrı ve kas yorgunluğu ve dil veya yanakta diş izleri v.b.

bulgular, bruksizmin başlıca klinik tanısını oluşturmaktadır. Bruksizm tanısındaki klinik bulgular aşağıda maddelenmiştir.

- Hastanın uyku esnasında diş gıcırdatması
- Çene hareketinden dolayı dişlerde aşınma
- İstemli olarak kasılmada masseter kasında hipertrofi
- Sabahları çiğneme ve servikal kaslarda ağrı ve kas yorgunluğu
- Temporal kas bölgesinde baş ağrısı
- TME'nin kilitlenmesi veya klik sesi duyulması
- Dil ve yanakta diş izleri bulunması
- Diş eti çekilmesi
- Diş ve ya dolguların kırılması
- Ağız açıklığının kısıtlanması
- Soğukta diş hassasiyeti

Ayrıca hastanın çene ısırma kuvvetinin ölçülmesi ve diş aşınma tespiti için ağız içi aparey kullanımı, çiğneme kaslarındaki özellikle de masseter ve temporal kaslarda elektromiyografi (EMG) işaretler, polisomnografi (PSG) kayıtları ile hastanın bruksizm teşhisi yapılabilmektedir [7-9].

Bruksizm süresi ve sıklığına dair yapılan çalışmalarda farklı sonuçlar bildirilmiştir. Trenouth'ın 1979 yılında yaptığı çalışmada bruksizmi olan bir kişide uyku esnasındaki diş teması sayısı ölçülmüş ve bu sayı gece boyunca ortalama 1325,5 olarak bulunmuştur. Sağlıklı bireylerdeki diş teması ise ortalama 359,95 olduğu gösterilmiştir. Aynı çalışmada ise sağlıklı bir bireyde toplam diş teması süresi ortalama olarak 5,4 dk olarak bulunmuşken, bruksizmi olan bir bireyde ise bu süre 38,7 dk olarak bulunmuştur. Amemori ve ark., 2001 yılında yaptıkları bir çalışmada, bruksizm sırasında saat başına düşen diş teması süresi 47,8 s ile 174,9 s olarak bildirmişlerdir. Bruksizm sırasında ağız içinde oluşan kuvvetler, alt ve üst çeneye yerleştirilen gerilme ölçen (strain gauge) sensörlü sistemler ile ölçülebilmektedir. 10 bruksizm hastası üzerinde yapılan bir deneyde 3 gece boyunca 499 alt çene hareketine bağlı aktiviteler yapılmış ve de ortalama 22,5 kg kuvvetin bir saatte 3,6 defa 7,1 s sürelerde oluşturulduğu bulunmuştur. Yine başka bir çalışmada 13,5 defa 5,7 s süreyle oluştuğu ve de tüm uyku süresinin %8'inde bruksizme bağlı alt çene aktivitelerinin ortaya çıktığı görülmüştür [10]. Ağız içine yerleştirilen basınç sensörleri ile bruksizm esnasında dişlerde oluşan basınç kuvvetlerinin algılanmasında yapay zekânın kullanıldığı akıllı bir basınç sensör sistemi geliştirilmiştir [11].

EMG yöntemi ile özellikle rehabilitasyon ve dış iskelet sistemlerinde alt ve üst ekstremitelerde kasların kasılmasıyla hareket sınıflandırılması ve de tahmini konusunda EMG ölçümleri son yıllarda popüler olmuştur. Bruksizm, parafonksiyonel bir aktivite olması sebebiyle, oklusal kuvvet algılama yerine sadece EMG ile rahatsızlığın tanısı için etkili bir yöntem henüz net olarak ortaya konmamıştır. Popülasyonun %60'ını oluşturan normal kişilerde de stres ve anksiyeteye bağlı olarak popülasyonun ritmik parafonksiyonel aktiviteler görülebilmektedir [12], [13]. Bu aktiviteler esnasında çiğneme kaslarının EMG sinyallerinde yaklaşık 1 Hz'lik periyotlar halinde ritmik aktivite patlamaları oluşmaktadır. Ayrıca kasılma süresince ortalama genlik değeri yaklaşık olarak maksimum gönüllü kasılmanın (MVC) %10'u kadardır, ve uyku esnasında 8 saniyeden fazla sürmektedir [14], [15]. Özellikle de uyku esnasında bu aktivitenin ayırt edilmesi laboratuvar ortamında uzman kişilerce değerlendirme gerektirdiğinden maliyetli ve bir uzmanlık gerektiren bir süreçtir [16].

Bruksizm tanısını klinik olarak ortaya koymada son yıllarda EMG ile birlikte elektrokardiyografi (EKG) ve elektroensefalografi (EEG) sinyallerinin ortak analize dayalı çalışmalar yapılmaktadır [17], [18]. EMG sinyallerinden elde edilen 1 s periyotlu ortalama genlik (MAV) değeri ile EKG sinyallerinin kalp atış hızı (HR) özellikleri yapay sinir ağları (YSA) ile sınıflandırılarak bruksizme dayalı çene kaslarındaki kasılma aktiviteleri ortaya çıktığında kalp atış hızında da HR değişiklik olduğunu ortaya konulmuştur. Öznitelik olarak MAV, HR ile birlikte gözönüne alındığında, sağlıklı bireylerin %80'i doğru tahmin edilmiş, düşük frekanslı hasta bireylerin %60'ı doğru tahmin edilerek tüm grup için sınıflandırmada doğruluk oranları %64 olarak elde edilebilmektedir [17]. Bruksizmi sınıflandırmada EEG sinyalleri ile birlikte EKG ve EEG ile birlikte ele alındığında daha da etkin sonuçlar elde edilebilmektedir [18].

Günümüze bruksizminin değerlendirilmesi için ayrıca hastaların partnerleri tarafından belirtilen bir öğütme sesi, diş aşınması, temporomandibular eklemden ve çiğneme kaslarının ağrı ve elektromiyografi gibi klinik bulgular dahil olmak üzere çeşitli yöntemler vardır. Ancak günümüzde bruksizmin klinik uygulamada değerlendirilmesi esas olarak klinik bulgulara dayanmaktadır. Teşhis objaektif olmadığından, bu tür bir değerlendirmenin doğruluğu yeterli değildir [19], [20].

Bu sebeple bruksizmin özellikle uyku esnasında değerlendirmesinde altın kural, bir uyku laboratuvarında veya hastanede kalış sırasında ses-video PSG kaydının yöntemi ile çiğneme kaslarının EMG'si ile birlikte değerlendirilmesi olmaktadır [21-23]. Ancak, günümüzde tüm bu yöntemin uygulanışı karmaşık ve yüksek maliyeti olmaktadır. Bu nedenle ev ortamında da kullanılabilecek, zaman almayan ve ekonomik olarak uygulanabilecek etkin yöntemlerin geliştirilmesi önemlidir.

1.1.2 Dış İskelet Kaslarında Yorgunluk Tanısı

Bruksizmin teşhisindeki en önemli belirtilerden biri, alt çene kaslarında ortaya çıkan ağrı ve kas yorgunluğudur. Kas yorgunluğu ortaya çıktığında kaslarda dengesizlik, titreme ve kuvvet kaybı görülebilmektedir [24]. Bruksizm kas yorgunluğuna bağlı olarak kas aktivitelerindeki kuvvet düşüşü veya kas ağrısına bağlı rahatsızlık durumlarının ortaya çıkması olarak tanımlanmaktadır [25]. Bir başka deyişle kas yorgunluğu, kasların üzerinde etki oluşturan dinamik ve statik yüklenme ile oluşmaktadır. Dolayısıyla kas yorgunluğu kas konsantrasyonu, çalışma sıklığı ve şiddetiyle doğrudan ilişkilidir [26].

Literatürde kas yorgunluğu ile yapılan çalışmalar özellikle son yıllarda medikal, rehabilitasyon ve de insan-makine etkileşimi alanlarında yoğunlaşmaktadır. Kas kasılma miktarının algılanmasıyla ilgili literatürde ilk olarak deri yüzeyini kaplayan EMG sensörleri ilgili çalışmalar yapılmıştır. Bu çalışmalar sayesinde kas gücünün tespiti, kas zayıflığının algılanması, fizyoloji ve rehabilitasyon alanlarında teşhis metodu olarak kullanılmaktadır [27], [28]. Sonrasında yüzey EMG'nin kas yorgunluğunun tespiti ve ölçümü için kullanılabileceği de gösterilmiştir. Bu tür çalışmalar için kaslarda yorgunluk yok iken alınan sinyaller arasındaki farklılıklar önem taşımaktadır. Bu farklılıklar sinyalin frekans bölgesindeki kayma ve genlikteki artışın miktarlarıdır. Bu türden yapılan çalışmalar neticesinde kas yorgunluğunun kaslardaki kasılma gücünde bir azalma oluşturmasıyla sensörlerden alınan analog sinyallerin frekans spektrumlarının dönüşümü yapılarak alçak frekans bölgesine doğru kayması ve genlikteki artış kaslardaki yorgunluğun göstergesidir [29-32]. Fakat, EMG sinyallerindeki frekans kaymasının nasıl tespit edilebileceği çok açık değildir. Bazı araştırmacılar gürültüye karşı daha duyarsız medyan frekansını değişken olarak seçerken, diğer

bazı araştırmacılar ise spektrumdaki değişimlere karşı ortanca frekans, sinyalin genliği gibi değişkenleri seçerek kas yorgunluğunu belirlemektedirler [33-36].

Literatürde farklı sınıflandırma algoritmaların ortaya çıkışı ile kas yorgunluğu belirlemede EMG işaretlerinde öz nitelik çıkarımı için sınıflandırma yöntemleri olarak yapay sinir ağları (YSA), bulanık mantık (BM) kullanılmaktadır [37-40]. Bunun için zaman-frekans metodu ve bağımsız bileşenler analizi ile yorgunluk tespit edilmeye çalışılmıştır. Fazik istemli hareketler boyunca farklı denekler üzerinde EMG verileri kaydedilerek frekans-zaman domeninde incelenilmiştir. YSA ile, üst ekstremitede oluşan kas yorgunluğu belirlenmiştir. Özellikle çıkarımında Wigner-Ville ve Sürekli Dalgacık Dönüşümleri yöntemleri kullanılmıştır. Özelliği çıkarılan sinyaller için yorgun yada yorgun olmayan şeklinde YSA ve Levenberg-Marquart (LM) algoritmalarıyla %90 üzerinde belirlilik ve hassasiyette kullanılacağı gösterilmiştir [41].

Ayrıca bir başka çalışmada EMG işaretlerinden öznitelik vektörlerini bulmak için farklı sınıflandırma teknikleri kullanılmıştır. Bu çalışmada farklı sınıflara ait Otoregresyon (Autoregression AR) parametreleri elde edilerek sonrasında Genetik Algoritmalar (GA) ile birlikte YSA kullanılarak yorgunluğun sınıflandırılması yapılmıştır. Yapılan bu çalışmada GA ile ağa ait değerler YSA eğitimi sırasında ağa ait topoloji ve ağırlık değerlerinin başarılı bir şekilde belirlenebildiği ve böylelikle ağın eğitimi sırasında problem yaşanmadığı, kolaylıkla eğitilebildiği görülmüştür [42].

Buraya kadar anlatılan kısımda literatürde kas yorgunluğu için EMG verileriyle yapılan çalışmalar özetlenmiştir. Ancak literatürde kas yorgunluğunu belirlemede alternatif yöntemlerden biri de mekanomiyogram (MMG)'dir. MMG, kaslardaki hareketin mekanik aktiviteler esnasındaki kas yüzeyinde oluşan ivme, titreşim v.b. salınımların bazı özel sensörler veya MEMS sistemlerle ölçülmesi metodu olmaktadır [43-45]. Bazı çalışmalar ise; yorgun kaslarda kasılma kuvvet sertliği ölçümünün uygunluğu ile ilgili MMG, EMG ve kas sertliği sensörü ile elde edilen sinyallerin karşılaştırma analizlerini içermektedir [46]. Özellikle de ivmeölçer kullanılarak yapılan MMG analizlerinde elde edilen mekanik sinyaller ile ilgili olarak kası örten deri üzerinde, MMG sinyallerin genliği kasın merkezinde en

yüksek değerde olup, kasın tendon bölgesine yaklaştıkça azaldığı tespit edilmiştir [47]. Bu sayede kastaki mekanik aktivitelerin ayrı ayrı toplanması ile belirlenen bir indeks olan MMG ile kas yorgunluğu, ağrıları ve rahatsızlık incelemelerinde kullanılmaktadır [48-50]. MMG sinyalinin kullanılmasının EMG sinyaline göre bir çok avantajı bulunmaktadır. Deri yüzeyindeki empedans değişimlerine karşı duyarsızlık göstermesi, elektromanyetik dalgaların yol açmış olduğu gürültülerden etkilenmemesi sebebiyle MMG sinyalleri tercih edilebilmektedir [51-53].

Birçok araştırmada EMG ve MMG sinyalleri hem ayrı bir şekilde değerlendirilmiş, hem de birlikte kullanılarak değerlendirilmektedir. EMG ve MMG sinyallerinin birlikte kullanılmasıyla ilgili olarak, Parkinson hastalarında agonist ve antagonist kasları üzerine yapılan çalışmalardır [54]. Örnek olarak, bu iki sinyallerden spektral özellik çıkartmak için dalgacık ve temel bileşen analizi uygulanmıştır [55]. EMG ve MMG sinyallerinin birlikte kullanılmasıyla ilgili yapılan araştırmalarda özellik çıkarılması için son yıllarda dalgacık dönüşümü kullanılmakta ve de bu özellikler genellikle YSA kullanılarak sınıflandırılmaktadır [56-59].

Son yıllarda kas yorgunluğu ile ilgili yapılan araştırmalara baktığımızda yapılan çalışmalar yüzey elektromiyografi ile ilgilidir. 2016 yılında yapılan bir çalışmada, EMG sinyalleri, on iki gönüllüden üç farklı yük seviyesinde üst kol kasılmalarından elde edilen deneylerle elde edilmiştir. Bu çalışmada, EMG sinyaline ait ortalama frekans (MNF), spektral moment oranı (SMR), dalgacık metodunayla entropi özellikleri kullanılmış, ve de SMR parametresine bağlı bu özelliğin kullanılmasıyla diğer MNF ve entropi özelliklerine kıyasla kas yorgunluğunun belirlenmesinde etkin olarak kullanılabileceği görülmüştür [60]. 2017 yılında yapılan bir başka çalışmada ise dinamik kasılmayı ayırt etmek için yüksek çözünürlüklü zaman-frekans yöntemlerine, diğer bir deyişle Stockwell dönüşümü, B-dağılımı ve genişletilmiş modifiye B-dağılımı temelli analiz önerilmiştir. Her bir yöntemden on iki özellik çıkarılmış ve genetik algoritma (GA) ve ikili parçacık sürüsü optimizasyonu kullanılarak öne çıkan özellikler seçilmektedir. Farklı makine öğrenme algoritmaları sınıflandırmalar için Naive Bayes (NB), radyal temelli fonksiyon (RBF), rastgele orman (RF) ve destek vektör makinesi (SVM)

algoritmaları kullanılmıştır. Önerilen tüm zaman-frekans dağılımlarında EMG sinyallerinin durağan olmayan çeşitlemelerini göstermektedir. Özelliklerin çoğunda, kas yorgunluğu ve yorgunluk dışı durumlarda büyük ölçüde ayırt edici olduğu görülmüştür. Polinom çekirdeği bazlı SVM'nin kombinasyonunun, GA kullanılarak seçilen özelliklerle sınıflandırılmasında %91 doğruluk elde edilmiştir. Özellikle, dinamik kas yorgunluğu durumlarını saptamak için polinom çekirdeği bazlı SVM kombinasyonunun da kullanılabileceği kanıtlanmıştır [61]. Kas yorgunluğunun tespiti için 2019 yılında bir çalışmada, iki otonom sinir sistemi (ANS) analizine dayanan kas yorgunluğu tespiti için alternatif bir invaziv olmayan metodoloji önermektedir. Diğer bir deyişle elektrodermal aktivite (EDA) ve HR değişkenliği arasında ilişki vardır. Standart yüzey EMG analizine dayanarak, izometrik biceps kasılması yapan 32 sağlıklı birey yorgun ve yorgun olmayan şeklinde iki gruba ayrılarak karşılaştırma yapılmıştır. Önerilen SVM sınıflandırıcısı, özyinelemeli bir özellik eleme aşamasını takiben, %83'lük maksimum bir dengelenmiş hassasiyet göstermiştir. Sonuçlarımız kas yorgunluğunun etkili olmayan EDA ve HR işlemleriyle invazif olmayan bir şekilde yorgunluğu tanımlanabileceğini göstermektedir [62].

1.1.3 Biyolojik Sinyaller için Filtreleme Yaklaşımları

EMG'ye bağlı ölçüm sistemleri yıllardır özellikle de alt ve üst ekstremité kaslarına dayalı dış iskelet sistemlerinde [63-65], bu kaslarda oluşan yorgunluk ve ağrı durumlarının belirlenmesinde [66], [67], Parkinsona bağlı titreşimlerin algılanmasında [68-70] ve de alt çene kas aktivitelerine dayalı bruksizm varlığı gibi rahatsızlıkların teşhisinde [18], [71] sıklıkla kullanılmaktadır. Bununla birlikte EMG ölçümlerine alternatif olarak özellikle de kas aktivitelerinin algılanmasına yönelik olarak hareketin yönü ve kontrolü için kaslardaki mikro titreşimlerin algılanmasına yönelik MEMS tabanlı sistemler de ayrıca son yıllarda kullanılabilmektedir [72-74]. Ancak tüm bu sistemler dış etkenlerden ve de kişilerin kendisinden kaynaklı gürültülerden kolaylıkla etkilenebilmekle beraber bu sinyallerin doğruluğunu etkilemede birtakım dezavantajları da ayrıca mevcuttur. Özellikle EMG sinyalleri gözönüne alındığında en önemli faktör sinyal gürültü oranıdır (SNR). EMG sinyallerin işlenmesinde sinyalin kendisi EMG problemlerinden alınan çok düşük gerilim sinyallerinin diğer bir deyişle kaslarda

oluşan motor ünite aksiyon potansiyeli (MUAP) sinyallerinin yükseltilmesiyle elde edilmekte, bu sayede var olan gürültüler de yükseltilebilmektedir. EMG sinyallerin kullanımıyla ilgili diğer bir dezavantajı ise, komşu kaslardan gelen elektromiyografik işaretlerden de kolaylıkla etkilenebilmesidir. Ayrıca sensör problemlerinin deriye tam olarak temas etmemesi, derinin terlemesi ve de sert cilt kaynaklı faktörlerin skin impedance değişmesine sebebiyet vermesinden kaynaklı hatalı ölçümlerin ortaya çıkması ve de bunun sonucunda yanlış sınıflandırmalara sebebiyet vermesidir [74], [75]. İvme sensörü (akselerometre) tabanlı MEMS sistemlerin dezavantajı ise yapısı gereği kas kasılmasına bağlı olarak deri yüzeyindeki mikrotitreşim esasına dayalı olarak algılama yapımlarıyla kişilerin istemsiz vücut hareketlerinden dolayı oluşan titreşimlerden kaynaklı olarak düşük frekanslarda 5 Hz'e kadar yüksek genlikli gürültülere karşı oldukça duyarlı olmasıdır [67].

Kaslardan alınan sinyaller ile ilgili olarak EKG ve EMG sinyallerin filtrelenmesi üzerine literatürde yapılan çalışmalara son yıllarda rastlanılmaktadır. EKG sinyallerinin filtrelenmesinde Wiener ve Kalman filtre modelleri kullanılmıştır [76], [77]. EMG sinyalleri ile ilgili olarak dirsek eklem açılarının algılanması ve kas yorgunluğu analizlerinde Kalman filtre çalışmaları da ayrıca yapılmıştır [78-81]. EMG sinyalleri kullanılarak filtre performansları bakımından RMS, VAR, MAV, LOG, WL, AAC, DASD, ZC, WAMP zaman ve frekans özellikleri birlikte değerlendirilebilmektedir. Tüm bu değerlendirmelerde değerlendirme kriterleri olarak Kalman filtre yaklaşımlarında regresyon korelasyonu R^2 , eğim kesişimi (Slope Intercept) [78], RMSE [79-81], Wiener filtre ile beraber Kalman filtresinin kullanılmasıyla da MSE, PMSD, SNR, PSD kullanılmaktadır [77].

Ancak insan vücudundan elde edilen sinyallerin doğrusal olmayışı göz önüne alındığında sadece EKF modeline dayalı filtreleme çalışmaları yapılmıştır. Literatürde yapılan bu çalışmalardan farklı olarak tez çalışmasında kullanılan model parametrelerinin kendiliğinden ayarlanabilmesi diğer bir deyişle de adaptif olmasıdır. Ayrıca bruksizm alanında da ilk defa kullanılabilir olmasıyla da hem MEMS tabanlı hem de EMG tabanlı sinyallerde doğrudan kullanılabilmesidir. Dolayısıyla filtrenin performans değerlendirme kriterleri olarak MSE ile birlikte etkili beş farklı zamana bağlı genlik ve frekans özellikleri (MNF, MDF, MFL, ZC ve

DASD) aynı şekilde farklı sınıflandırma algoritmalarıyla (KNN, NB, DT, SVM ve LD) birlikte incelenmiştir.

1.2 Tezin Amacı

Bruksizm rahatsızlığı günümüz toplumunda özellikle de uyku esnasında yaygın görülmesiyle, hastalarda hipertrofi oluşumu, diş kaybı ve dişlerde aşınma, çene kaslarında ağrı ve yorgunluk, uyku kalitesinin bozulmasıyla da yorgunluk hissi vermesiyle buna bağlı olarak hastalarda yaşam kalitesini olumsuz etkileyen kronik bir rahatsızlıktır. Bu rahatsızlığın tanısının ortaya konulmasında günümüzde klinik laboratuvar ortamlarında hastaların EMG ölçümleriyle birlikte uyku laboratuvarlarında ses ve video kayıtları ile birlikte bu rahatsızlığın teşhisi konulabilmektedir. Ayrıca literatürde EMG ölçümleriyle birlikte bruksizmin tanısının etkinliğini ortaya koymada EKG ve EEG tabanlı sistemler üzerine çalışmalar da mevcuttur [17], [18]. Tüm bu çalışmaları gözönüne aldığımızda bruksizm tanısının ortaya koyulmasında ekonomik olmamakla birlikte zaman alıcı ve uzmanlık gerektiren bir süreçtir. Dolayısıyla bu tezin amacı, harici laboratuvar veya klinik ortam gereksinimi kalmadan ev ortamında da bruksizm tanılmasının yapılabilmesi için düşük maliyetli, taşınabilir bir sistemin geliştirilmesidir. Ayrıca bu sistemde sadece tek bir EMG ölçümüyle veya MEMS teknolojisini kullanarak en etkin tanılamamanın yapılması amaçlanmaktadır. Bu nedenle bruksizm tanısında alt çene aktiviteleri incelenirken, bu kaslar için ayrıca kas yorgunluk analizleri de yapılarak etkili tanı yöntemleri geliştirilmesi amaçlanmıştır. Bu tez çalışmasında amaçlanan bir diğer çalışma, düşük maliyetli MEMS akselerometre tabanlı sistemler kullanılarak yeni bir yöntem geliştirilmesidir. Bu sayede donanımsal olarak devre yapıları daha az aktif komponent kullanılmasıyla azaltılarak hem daha kullanışlı hem de enerji tüketimi bakımından verimli hale getirilmiş veya pil sarfiyatı azaltılmıştır. Bu sebeple aktif analog filtre devre yapıları azaltılmasıyla da sinyallerin dijital ortamda filtrelenebilmesine olanak sağlanması, deri teması kaynaklı, çevresel kaslardan kaynaklı, vücut hareketi kaynaklı, aktif donanımsal komponentlerden oluşabilecek elektromanyetik kaynaklı tüm gürültüleri kendiliğinden elimine edebilecek ve de hastalarda yaş ve cinsiyet ayrımı gözetmeksizin adaptif bir filtre modeli geliştirilmesi amaçlanmıştır. Dolayısıyla bu tez çalışması, bruksizmin tanılanmasında kullanılan alt çene kaslarının başın

hareketiyle de sürekli hareket halinde oluşu göz önüne alındığında, bu kaslardan elde edilen karmaşık gürültülü sinyallerin etkin bir şekilde anlamlandırılmasına yönelik olmasının yanı sıra alt ve üst ekstremitte kasları için de uyarlanabilir. Bu sayede, dış iskelet sistemleri, rehabilitasyon robotları, insan makine etkileşimine dayalı robotik sistemler için de literatüre katkı yapılması ayrıca amaçlanmaktadır.

1.3 Orijinal Katkı

Bruksizmin toplumun çoğunluğunda yaygın olarak görülmesiyle, rahatsızlığın tanılanmasında en etkin, kolay ve hızlı bir şekilde yapılması adına son yıllardaki yapılan çalışmalardan farklı olarak, bu tez çalışmasında birtakım yenilikler literatüre kazandırılmıştır. Bunlardan birincisi sadece EMG ölçümlerine dayalı olarak yapılan çalışmalardır. Yapılan bu çalışmalarda, EMG sinyallerinin alt çene aktiviteleriyle birlikte ayrıca etkin bir tanılama için kas yorgunlukları da dikkate alınarak, her bir aktivite için zamana bağlı farklı genlik-frekans özellikleri elde edilmiş, elde edilen özelliklerden en etkili özellikler istatistiksel olarak regresyon ve YSA'lar kullanılarak belirlenmiştir. Belirlenen bu özellikler farklı makine öğrenme (KNN, LD, SVM, DT, NB, YSA) algoritmalarıyla ayrı ayrı sınıflandırılmakta, tanılamada sadece YSA algoritması kullanılarak %98,8 doğrulukla etkin bruksizm tanılanması yapılabilmektedir. İkincisi, Otoregresyon yöntemi de kullanılarak 12 düzenli regresyon katsayı özellikleri alt çene aktiviteleri ve kas yorgunlukları için oluşturularak bu sayede %100 başarıya ulaşılmıştır. Bu sebeple sadece tek bir sensör EMG ile en etkili tanılamaya ulaşılmış, ayrıca taşınabilir ev ortamında da ölçümlerin alınması için EMG ölçüm sistemi tasarlanmıştır. Böylelikle harici bir klinik ortama gerek kalmadan maliyet ve zaman da dikkate alındığında kullanışlı bir yöntem literatüre kazandırılmıştır.

Sadece EMG sistemini kullanarak elde edilen bu çalışmalarda çalışmayı bir adım daha öteye taşımak adına ayrı bir çalışma sağlanmıştır. Bunun için MEMS tabanlı akselerometre sistemi kullanılmasıyla alt çene kaslarının bulunduğu deri yüzeyinden EMG sensör algılamasıyla elde edilen MUAP sinyalleri yerine bu kez alt çene aktivite esnasında görülen mikrotitreşimler algılanarak etkin bir bruksizm tanılanması yapılabilmektedir. Böylelikle EMG sistem kullanılmasıyla ortaya çıkan

evresel kaslardan elde edilen grltler ve de cilt teması kaynaklı olarak cildin kuru ya da nemli olmasıyla elektrodun deriye teması esnasında ortaya ıkan empedans kaynaklı grltler de ortadan kalkmıřtır. Ayrıca EMG sinyallerinin n iřlenmesi iin harici ykselte devre yapılarına da gerek kalmayarak SNR kaynaklı grltlerin de oluřmasının nne geilmiřtir. Bu sistem ile mikrotitreřim sinyallerinden zamana baėlı genlik ve frekans zellikleri elde edilmiř ve de YSA kullanılarak %100 doėrulukla alt ene aktivitelerine baėlı bruksizm tanılması yapılabilmıřtir. Ancak MEMS sistemi vcut hareketlerine karřı duyarlıdır. zellikle de uyku esnasında bař pozisyonu deėiřebilmektedir. MEMS tabanlı grltleri ortadan kaldırmak iin 5 ile 100 Hz arası band geiren aktif filtre tasarlanmıřtır. Yinede son bir katkı olarak hem EMG sistemi iin hem de MEMS tabanlı lm sistemleri iin harici bir analog filtre yapısına ihtiya kalmadan yeni bir filtre yaklařımı geliřtirilmiřtir. Bylelikle sistemin boyut ve maliyetleri de nemli lde azaltılmıřtır. Bu yaklařımda geniřletilmiř Kalman filtresi (EKF) bruksizm tanılması iin ilk defa kullanılarak adaptif hale getirilmiř, bylelikle yeni bir filtreleme modeli ortaya konulmuřtur. Dolayısıyla hastaların yař ve cinsiyetine baėlı oluřan cilt durumları farkı gzetmeksizin kullanıcı kaynaklı olarak oluřabilecek, vcut hareketi kaynaklı ve de evresel kaynaklı oluřabilecek her trl grltleri temsil eden sinyaller kendiliėinden harici bir analog devre yapıları oluřturmadan ortadan kaldırılabilmiřtir. Bu filtre yapısı EMG kaynaklı lm sistemleri iin de adaptif bir yapı olmakla beraber ayrıca, dıř iskelet sistemleri iin rehabilitasyon robotları, insan makine etkileřimine dayalı robotik sistemler iin de uygulanabiliridir.

2.1 Alt Çenenin Anatomik Yapısı

Alt çene ekleminin hareketini sağlayan kaslardan oluşmaktadır. Bruksizm esnasında bu kas grupları aktif rol oynamaktadır. Alt çene kasları çiğneme kasları olarak bilinmekte ve de iskelet kasları grubuna girmektedir. Kafatasında bulunan bu çiğneme kasları fonksiyonlarına göre 4 gruba ayrılmaktadır [82], [83].

Çeneyi Kapatın Kaslar

- Masseter Kası
- Temporal Kası
- Medial Pterygoid Kası

Çeneyi Açın Kaslar

- Lateral Pterygoid Kası
- Anterior Digastrik Kası

Çeneyi İleri-geri Hareket Ettiren Kaslar


- Lateral Pterygoid Kası (ileri hareket)
- Medial Pterygoid Kası (geri hareket)
- Temporal posterior kası (geri hareket)

Çeneyi Yanal Hareketi Sağlayan Kaslar

- Lateral Pterygoid Kası
- Medial Pterygoid Kası

2.1.1 Masseter Kası

Masseter kası, etkin bir çene kapama kuvveti sağlayan güçlü bir kas yapısı ile kafatasının her iki yanak bölgesinde dikdörtgen biçiminde geniş yüzey ve derin liflere sahip bir kas grubudur. Kasıldığında esas görevi çeneyi kapatmak ve dişlerin oklüzyona gelerek diş sıkılmasını sağlamaktır [82-85] (Şekil 2.1).




Şekil 2.1 Masseter ve temporal kasların anatomik görünümü

2.1.2 Temporal Kası

Temporal kası Şekil 2.1’de görüldüğü gibi kafatasının her iki yan taraflarından fossadan başlayıp mandibulanın koronoid çıkıntısında tendonlar ile yapışan yelpaze şeklinde bir kastır. Bu kas farklı yönlerde konumlandırılmış liflerden oluşmuş bir yapıya sahiptir. Ön bölümdeki vertikel (dikey) yönlü lifler kasıldığında, mandibulanın yukarı hareketi ile çenenin kapanmasında rol oynamaktadır. Orta (oblik) lifler kasıldığında mandibulanın yukarı ve geriye doğru, yatay pozisyonundaki arka (horizontal) posterior lifler kasıldığında ise mandibulanın geri yönlü kapanma hareketine yardımcı olur. Görüldüğü bu kas grubu masseter kasıyla birlikte koordineli olarak çene kapatma hareketine yardımcı olmasıyla mandibulayı kapatma hareketinde konumlandırıcı bir rol oynamasıyla dişlerin temasa geçmesi sağlanmaktadır [82-87].

2.1.3 Medial Pterygoid Kası

Alt çenenin kapanmasında ve de öne doğru gelmesinde aktif rol oynamaktadır. Bu kas Şekil 2.2’de görüldüğü gibi fossadan başlayıp aşağı ve geriye giderek mandibulaya bağlanır. Tek taraflı kasılması alt çeneyi “mediotrusive” yönde hareket ettirmektedir [82], [83], [84], [85], [88].



Şekil 2.2 Medial ve lateral pterygoid kasların anatomik görünümü


2.1.4 Lateral Pterygoid Kası

Yorgunluğa karşı dirençli olan bir kas yapısı olmakla birlikte fonksiyonellik bakımından inferior ve superior olmak üzere iki gruba ayrılmaktadır. Inferior lateral pterygoid alt grubu kasları, alt çeneyi açma sırasında çalışmaktadır. Superior lateral pterygoid kasları ise dişler kapalı durumda iken veya çiğneme, diş sıkma gibi hareketlerde aktif durumdadır [82], [83], [84], [85], [88].

2.2 İskelet Kasların Yapısı

Kas dokusu kasılma (kontraksiyon) yapabilen bir dokudur. Damarlı ve sinirli bir yapıya sahip iskelet kasları liflerin meydana getirdiği demetler halinde bulunmakta, tendonlar ile iskelet kemiklerine bağlıdır. Her bir kas lifi birkaç milimetreden birkaç santimetre uzunluğunda olabilmekte, 10 ile 100 μm arasında farklı çaplarda olabilmektedir. Kas lifleri, kalın ve kısa filamentler şeklinde düzenlenmiş miyofibrillere ayrılmıştır. Bir kas lifi “sarcolemma” adı verilen bir hücre zarı ile çevrilidir. Bu zar, kas hücresinin iç sıvısıyla, dış sıvısı arasında iyon geçişini sağlayabilmek için kanallara sahip yarı geçirgen bir membran zarıdır. Bu türden yapıya sahip iskelet kasları çizgili kaslardır. İskelet kasları istemli çalışan kaslardır [24], [84], [85], [89].

Kaslar kimyasal enerjiyi mekanik harekete çevirirler. Bağlandıkları kemikleri hareketi için kasılıp gevşemesi gerekir. Diğer bir deyişle bir kemiğin hareketi için bağlı bulunduğu kemikteki kasın kasılması, bağlı bulunduğu kemikteki diğer kasın gevşemesi gerekir. Dolayısıyla sinirler tarafından bir uyarı geldiğinde kas kasılır. Böylelikle kasılmadaki kasın boyu kısalır, gevşemedeki kasın boyu uzar. Şekil 2.3'te bir çizgili kasın yapısı görülmektedir.




Şekil 2.3 Çizgili kas yapısı

Her bir miyofibrin yapısı Şekil 2.3'te görüldüğü gibi yan yana uzayan veya kısalan aktin ve miyozin bileşenlerinden oluşmaktadır. Kasılma hareketinde Şekil 2.3'te görülen I bandı kısalır, A bandının boyu değişmez böylelikle H bandı neredeyse kaybolur. Gevşeme hareketinde ise bu kez tersi bir durum söz konusudur [24],[90].

2.2.1 Motor Ünite

Şekil 2.4'te görüldüğü gibi bir motor sinir; kas boyunca dallara ayrılarak birçok kas lifini aynı anda uyarabilmektedir. Dolayısıyla bütün lifler aynı anda kasılmakta ve de gevşemektedir. Bu nedenle, tek bir motor sinirden gelen uyarıda, bu sinirin uyardığı liflerin aynı zamanda eylem yaptığından dolayı bu olaya motor ünite adı verilmektedir.



Şekil 2.4 Motor ünite


Motor üniteindeki kas fibrillerinin ya hepsi kasılır ya da hiçbiri kasılmaz. Bu prensibe hep ya da hiç (all-or-none) prensibi denilmektedir. Dolayısıyla kas lifleri kısmen kasılmaz. Tamamen kasılır ya da hiç kasılmaz. Ancak, bir motor üniteindeki bütün liflerin uyarılmasıyla bütün kas için göz önüne alındığında hep ya da hiç prensibi kasın tamamı için geçerli değildir. Çünkü kasın tamamı birden fazla sinir tarafından uyarılabilir. Motor ünitelerin adedi vücudun çeşitli bölgelerinde kasın büyüklüğüne göre değişmekle beraber kas büyüdükçe bu sayı artar [91], [92].

Motor sinirleri, sinir hücrelerin bir araya gelmesiyle oluşmuştur ve de sadece bir tek sinir hücresi ya polarize ya da depolarize olabilmektedir. Dolayısıyla iki durum söz konusudur. Motor uç plakalarına “var-yok” iki seviyeli durum bilgisini gönderir. Böylece her bir kas lifi de ya gevşeme ya da uyarılmış (kasılmış) durumdadır. Normal kas hareketinin özelliği, harekette yumuşaklık, devamlılık ve hassasiyettir. Bu özellikler, herhangi bir kasın birçok motor ünitesinden meydana gelmesinden kaynaklanmaktadır. Mesela küçük bir harekette kas hareketinin yapılmasında sadece bir motor ünitesi faaliyette iken daha fazla büyük hareketlerde ise birçok motor ünitesi faaliyettedir. Şayet tamamı uyarıldığında kas hareketi en üst düzeydedir [93].

2.2.2 Kasların Kasılma Durumları

Kas kasılmasında, kasın farklı kısımlarında bulunan motor ünitelerinin uyarılmasıyla gerçekleşmektedir. Diğer bir deyişle kasların kasılması, sinirler


aracılığıyla beyinden iletilmiş olan uyarıcı potansiyellerin kaslarda oluşturduğu MUAP sayesinde olmaktadır. Diğer bir deyişle bir MUAP'ların oluşması için kas liflerinde sinirler aracılığıyla beyinden iletilen uyarıcı potansiyelleri vasıtasıyla olmaktadır. Kaslardaki kasılma miktarı artmasının nedeni ise daha fazla motor nöron devreye girmesiyle MUAP'larda artışın görülmesi şeklindedir. Bir sinir hücresi birçok kas fibrile bağlı olmakla birlikte Şekil 2.5'te görüldüğü gibi bağlı olduğu kas fibrilleri sinirlerle kuşatılmasıyla motor ünite olarak isimlendirilir.



Şekil 2.5 Motor nöronlar ile sinir kas bağlantısı


Bir motor üniteye yer alan bütün kas hücrelerinde aksiyon potansiyeli oluşmuşsa, o motor ünitesinde yer alan bütün kas hücreleri eş zamanlı olarak aynı anda kasılır [94].

Sinir ve kas hücreleri uyarılabilen hücrelerdir. Bu hücreler eşik değerlerinin üzerinde bir uyarıldıklarında bu uyarı bütün hücreye yayılabilmektedir. Hücrelerin içerisinde sodyum (Na^+), potasyum (K^+) ve klor (Cl^-) iyonları bulunmaktadır. Bu iyonlar, seçici geçirgen hücre zarından hücre içine ve dışına hareket edebilmektedirler. Bir potansiyel fark oluşur. Bu değer, -50 mV ile -120 mV arasında değişmektedir. Böylelikle aksiyon potansiyeli oluşmaktadır.



Şekil 2.6 Aksiyon potansiyelin dalga şekli

Esasen hücre zarından içeriye Na^+ iyonlarının girmesi ve de bir miktar K^+ iyonlarının dışarı çıkmasıyla ortaya çıkmaktadır. Bu olaya depolarizasyon denir. Şekil 2.7’de bu olay gösterilmektedir ve de kaslardaki kasılmanın temel faktörüdür. Şekil 2.6’da aksiyon potansiyeli görülmektedir [24], [89], [95].



Şekil 2.7 Kas hücresinde depolarizasyonun oluşması

Şekil 2.6’daki grafikte de görüldüğü gibi aksiyon potansiyelin belirli bir tepe değere ulaşmasıyla depolarizasyonda yaşanan olaylar bu kez tersine işlemeye başlamış olur. Ardından tekrar dinlenme seviyesindeki potansiyelle dönüşüm gerçekleşir. Anlatılan olaylar tersine işler ve tekrar dinlenme potansiyeli seviyesine düşer. Bu olaya ise “repolarizasyon” denir. Bu değişimlerin tamamına aksiyon potansiyeli denmektedir [24].

Kas kasılmasında, kas hücrelerindeki gerekli enerjiyle birlikte aktin ve miyozin iplikçiklerinin birbiri içine kaymasıyla bu hareketin sonucunda kasın boyunun kısılmasına ve de tendonlar ile bağlı bulunduğu kemiğin hareket etmesi gerçekleşmiş olur [91].

Kas kasılmanın da kendi içinde bir kısım türleri mevcuttur. Bu türler izometrik ve izotonik ve izokinetik olmak 3 adet türü mevcuttur.

2.2.2.1 İzometrik Kasılma

Kasın uzunluğunun sabit kalması ve de geriliminin (iç kuvvet) artmasıyla oluşan kasılma türüdür. Böyle bir kasımda dıştan gelen dirençlere karşı oluşan daha büyüktür. Bu durumda eklemde herhangi bir hareket söz konusu değildir.

2.2.2.2 İzotonik Kasılma

İzometrik kasılmanın aksine kasın uzunluğunun kısılması ve de kastaki gerilimin sabit olmasıdır. Bu durumda eklemlerde hareket eylemi görülür. En çok karşılaşılan kasılma türüdür. Konsantrik ve eksantrik olmak üzere iki çeşidi mevcuttur.

Konsantrik kasımda; kas gerilimi sabit iken kasın boyunun kısılmasıdır. Bu durumda mekanik bir kaldırma gerçekleşir. Eksantrik kasımda ise; kas gerilimi sabit iken fakat kasın boyunun bu kez uzamasıdır. Örneğin koldan indirilmesiyle ters yönde yapılan bir hareket şeklinde örneklendirilebilir.

2.2.2.3 İzokinetik Kasılma

Hareket için maksimum kuvvet uygulansa dahi hareketin her açıda sabit hızda yapılabilmesidir. Ortaya konan direnç ve de kuvvetler her açıda farklılık gösterebilir. Bu türden kasılmanın yapılabilmesi için özel bir tip izokinetik ihtiyaç vardır [91].

2.2.3 Kas Yorgunluğu

Kas yorgunluğu ile ilgili farklı tanımlamalar mevcuttur. Bu tanımlamalardan bazılarını özetlemek gerekirse; Lorist ve Ark.'a göre bireylerin ortaya koyduğu güç yeteneğindeki azalmadan ortaya çıkan motor yorgunluğu olarak tanımlamaktadır. Kallenberg ve Ark.'a göre kas yorgunluğu, EMG sinyalindeki genlik artışı ve güç

spektrumdaki frekanslarda azalma olarak tanımlar. Genel olarak söylemek gerekirse kas yorgunluğu, kasların kasılmasında ortaya çıkan gücün azalması ve de sürdürülmesindeki ortaya çıkan yetersizlik olarak tanımlanmaktadır.

Kas yorgunluğu nöromasküler sistemde ortaya çıkan geniş etkileri olan ve zaman bağlı bir olgudur. Nöromasküler aktivitenin başlamasından kısa bir süre sonra, kasın kuvvet oluşturma kapasitesinde geçici bir düşüşe neden olan bir biyolojik süreç olarak tanımlanmaktadır [96].


Bir başka tanıma göre; kaslardaki enerji depolarının azalması (örn. ATP-PC ve glikojen miktarı), metabolik artık maddelerin (örn. kaslarda ortaya çıkan laktik asitin) birikmesinden dolayı PH seviyesinin düşmesiyle nöral iletinin ve de aksiyon potansiyelinin azalmasıdır. Kas yorgunluğu kasın tamamında ya da bölgesel olarak ortaya çıkabilmektedir. Bölgesel kas yorgunluğunda bölgesel ağrı, kas titremesi ve güçteki verimin azalması fiziksel olarak ortaya çıkabilmektedir [89], [91].

Kas yorgunluğu, kaslarda oluşan statik ve dinamik yüklenmeyle ortaya çıkmaktadır. Kas yorgunluğunun en temel belirtileri arasında EMG işaretlerinin frekans değişimlerinin zaman içinde değişmesiyle ölçülmektedir. Kas yorgunluğu meydana geldiğinde, sinyalin genlik değerlerinde artış gözlenirken, frekans güç spektrumunda ise frekans bandında azalış, diğer bir deyişle frekansların ortalaması veya ortanca frekansın kasılma süresi boyunca azalması anlamına gelmektedir. Bunun sebebi ise yorgunluk ortaya çıktıkça kas zarı üzerinde oluşan MUAP'ların iletim hızının azalmasıdır. Bu durumun sonucunda toplam güç spektrumu, alçak frekanslara doğru kaymaktadır [89].

2.3 Elektromiyografi (EMG) Sistemleri


Elektromiyogram diğer bir deyişle EMG; kasların dinlenme ve kasılma durumlarında oluşan elektriksel sinyallerdir. Kaslardaki elektriksel sinyallerin incelenmesi neticesinde, kaslardaki ve motor sinir sistemindeki olağan dışı durumların teşhisinde önemli bilgiler sağlar.

EMG sinyali, zamanda durağan olmayan, gürültülü ve karmaşık bir sinyaldir. EMG sinyalin genliği değişken olmakla birlikte “gaussian” dağılım ile ifade edilir. EMG sinyallerinin eğer tek bir kas lifi ya da sinirden sinyal elde edilmesi için iğne elektrotlar, eğer bütün kas yüzeyindeki aktivitelerin incelenmesinde ise yüzey elektrotlar kullanılmaktadır [89]. Örnek olarak Şekil 2.8’de bu çalışmada örnek bir denneğin masseter kasından alınmış bir EMG sinyalin zaman domenindeki genliğinin görünümü ve de frekans-güç spektrumu gösterilmiştir.



Şekil 2.8 Örnek bir deneye ait EMG sinyal grafikleri


EMG sinyalin elde edilmesi için öncelik olarak sinyalin alınacağı kasın kasılması gerekir. Bu durumda merkezi sinir sistemi ve de motor üniteleri önemli bir rol oynar. Merkezi sinir sisteminden motor sinir vasıtasıyla gelen darbe sinyalin sonucunda aksiyon potansiyeli oluşur. Bu potansiyel, motor ünitesinde bulunan tüm kas liflerinde aynı anda meydana gelir ve de tüm kas hücreleri aynı anda bu motor ünitesinde uyarılarılarak depolarizasyon oluşur. Depolarizasyon sonucu kas kasılır ve de kas lifleri etrafında elektrik alan oluşur. Bu alan tüm kas liflerinde oluştuğu için sonucunda MUAP oluşur. Dolayısıyla kas liflerine yerleştirilen elektrotlar sayesinde MUAP tespit edilir. Bu durum bize EMG sinyalini vermektedir. Şekil 2.9’da örnek olarak gösterilmiştir [97].



Şekil 2.9 MUAP sinyallerinden EMG sinyal bileşenlerin elde edilmesi


2.4 Mikroelektromekanik (MEMS) Akselerometre Sistemler

Kas dokusunda meydana gelen mekanik bir aktivitenin, diğer bir deyişle mekanik salınımları kaydetmek için sipesifik transdüserler MEMS ivmeölçerler, kullanarak tahmin edildiği, faydalı ve invazif olmayan bir yöntemdir. Bu yöntem ile elde edilen işaretler mekanomiyogram (MMG) işareti olarak adlandırılır. Tipik olarak bir MMG sinyali, bu tez çalışmasında MEMS akselerometre kullanılmasıyla elde edilebilmektedir. Bu tez çalışmasında kullanılmak üzere örnek bir deneyin temporal kaslarından alınmış bir MMG sinyali Şekil 2.10'da gösterilmektedir.



Şekil 2.10 MEMS akselerometre ile örnek bir denekten alınan MMG sinyali

MMG kayıtlarının EMG kayıtlarına göre birtakım avantajları vardır. MMG sinyali mekanik salınım yapmasıyla mekanik olarak algılanabilmesinden dolayı kişinin terlemesi gibi faktörler karşısında deri empedansındaki değişikliklerden etkilenmez. Elektromanyetik alanlarda nispeten EMG sinyaline kıyasla uygulanabilir. Ayrıca MMG sinyalinin kas dokusunun yayılma özelliği dikkate alınmasıyla kolaylıkla ölçülecek yüzeyin herhangi bir yerine yerleştirilebilir.




Şekil 2.11 MMG sinyalin elde edilmesi

İnsan vücudunda, kas kasılmasıyla oluşan iç kas titreşiminden dolayı aktif kas lifi içindeki basınç dalgaları üreten yanal boyutsal değişiklikler, mekanik titreşimi oluşturmaktadır. MMG sinyalleri, bir dizi aktif kas lifi tarafından üretilen basınç dalgalarının bir sonucudur ve kasın mekanik aktivitesini temsil etmektedir. MMG sinyalin genliği ise, alınan motor ünitelerin sayısına bağlıdır. Motor ünitelerin uyarılma hızı arttığında, bu durumda MMG sinyalin de genliği artacaktır. Genel itibariyle kas titreşiminin frekans aralığı, kütle, viskozite ve basınç kaynaklı olarak kişiden kişiye farklılık gösterir. Şekil 2.11’de örnek bir MMG sinyalin elde edilmesi temsili olarak gösterilmektedir. Bu sinyaller, genellikle 5 Hz ile 100 Hz arasındaki frekans aralıklarında anlamlı özellikler içermektedir [24], [97].

Mekanik bir hareketi algılamada en yaygın kullanılan bir MEMS teknolojisi kapasitif MEMS’lerdir. Bu yapılarda sabit bir elektrot dizisi ve de hareket edebilen bir elektrot dizilerin bir birleriyle olan mesafelerine bağlı olarak oluşan kapasitif etki prensibine göre çalışmaktadır. Bu tip sensörler hareketi algılamada yaygın olarak kullanılmaktadır. Kapasitif bu tip MEMS’ler yüksek sıcaklıklarda bile hassasiyeti ve doğruluğu yüksek olabilmektedir. Bu tip yapılarda referans sabit bir

plaka üzerinde yay ile bağlanmış hareketli bir plakanın dış çevreden gelen hareket veya titreşime bağlı olarak hareket etmesiyle sabit plakaya göre uzaklaşması veya yaklaşmasına bağlı olarak oluşan kapasitans değişimiyle hareket, yön, titreşim gibi mekanik hareketlerin algılanması prensibine göre çalışmaktadır. Böylelikle hareket değişimine bağlı olarak gerilim çıkışı elde etmiş oluruz. Bu tip kapasitif MEMS yapıları ivme hareket yönü algılama (akselerometre); pozisyon yönü, denge algılama (jiroskop) yapıları olarak, tasarlanabilmektedir. Şekil 2.12’de örnek bir MEMS akselerometre iç yapısı gösterilmektedir.



Şekil 2.12 MEMS akselerometre iç yapısı

Bu tür yapılarda bir yönde hareket etmesi için sınırlandırılmış bir yaya ve sabit dış plakalara bağlı bir kütle vardır. Böylece belirli bir yönde bir hızlanma uygulanırsa, kütle hareket edecek ve plakalar ile kütle arasındaki kapasitans değişecektir. Kapasitördeki bu değişim ölçülür, işlenir ve belirli bir hızlanma değerine karşılık sinyal bu şekilde üretilmiş olur [98].


3.1 Sinyal Kayıtlarının Elde Edilmesi ve Ön İşleme Çalışmaları

Bu tez çalışmasında yaşları 14 ile 43 arasında değişen 20 denneğin alt çene kaslarından sinyaller gerçek zamanlı olarak farklı zaman aralıklarında elde edilmiştir. Sinyallerin elde edilmesinde Helsinki Deklerasyonuna bağlı kalmak koşuluyla deneklere istedikleri zaman deneyden çekilebilmeleri hususunda özgür oldukları bildirilmiştir. Ayrıca bruksizm farkındalığı, anksiyete, stress, yorgunluk ve çene ağrısı v.b. durumları olup olmadığı hususunda deneklere sorulmuştur. EMG ölçümlerinde 15mm çapında AgCl bipolar elektrotlar masseter kaslarının bulunduğu deri yüzeyine, her bir elektrot arası mesafe 1cm olacak şekilde tutturulmuştur [99], [100]. MEMS akselerometre olarak ADXL335 sensör kullanılarak her bir denek için masseter ve temporal kaslarının bulunduğu deri yüzeylerine tutturulmuştur. Deneysel çalışmalarda diş sıkma, gıcırdatma hareketleri ve çene kas yorgunluğu aktivitelerinin dişlere zarar vermemesi için her bir deneye ağız içi aparey kullandırılmıştır.

3.1.1 Elektromiyografi (EMG) Tabanlı Ölçüm ve Veri Kayıt Sistemi


Deneysel olarak deneklerden harici bir klinik ortam gereksinimi olmadan ev ortamında da sinyallerin düzgün bir biçimde alınabilmesi için elektronik donanımsal sistemler oluşturulmuştur. Bu bölümde EMG tabanlı sinyaller göz önüne alınarak sistem alt yapısı oluşturulmaktadır.

EMG tabanlı sistemler, kas aktiviteleri esnasında microvolt μV seviyesinde gerilim sinyalleri oluşturmaktadır. Bu nedenle sinyallerin yükseltilebilmesinde AD624 enstrümantasyon yükselteci değişken kazanç ayarlamalı (kazanç:100-1000, CMMR:130 dB) kullanılmıştır. Şekil 3.1’de değişken kazanç ayarlamasına sahip bu devre yapısı gösterilmektedir [101].




Şekil 3.1 AD624 Enstrümantasyon yükseltici blok devre yapısı


Bu çalışmadaki yükselteç devrelerinde kullanılan entegre komponentlerin bipolar beslemesi şebeke beslemesi kaynaklı gürültüler için çentik filtresi kullanılmıştır. Ancak EMG sinyallerine çevresel kaslardan gelen ve de deri teması kaynaklı gürültüler kolaylıkla karışmakta, ve de SNR'a bağlı olarak bu gürültülü sinyaller de yükseltilebilmektedir. EMG sinyallerinin anlamlı frekans aralıkları 10 Hz-500 Hz aralığında bulunmaktadır [75]. Bu sebeple köşe frekansı 10 Hz olan yüksek geçiren ve köşe frekansı 500 Hz olan alçak geçiren 2.ci dereceli alçak ve yüksek geiren Butterworth analog filtre devreleri tasarlanmıştır. Filtrelerin genel devre yapısı Şekil 3.2'de gösterilmektedir.



Şekil 3.2 İkinci dereceden Butterworth band geçiren filtre devre yapısı



Şekil 3.3 Filtre yapılarına ait bode diagramları ve transfer fonksiyonları




Şekil 3.4 EMG sinyalin filtreleme sonrasındaki frekans spektrumu

Butterworth filtre yapısı sabit kazanç değerine sahip olmakla birlikte 0 dB'den başlayıp -3 dB'e kadar düz bir frekans yanıtına sahiptir. Bu nedenle kalite faktörü $Q=0,707$ değerine sahiptir [102]. Butterworth filtresi analog tasarımı Chebyshev ve Eliptik filtre modellerine kıyasla çok daha basit bir yapıda olmakla birlikte yüksek düzenli tasarımlarda kararlıdır. Dolayısıyla yüksek frekanslı gürültüleri yok etmede yumuşatma devrelerinde tercih sebebi olmaktadır [103]. Şekil 3.3'te tasarlanan filtre yapılarına ait Bode diagramları ve transfer fonksiyonları gösterilmektedir.

Şekil 3.3'te görüldüğü gibi alçak geçiren filtrenin köşe frekansı -3 dB' de köşe frekansı 500 Hz olmaktadır. Dolayısıyla Şekil 3.4'teki frekans spektrumu incelendiğinde 500 Hz'den sonraki frekanslara ait genlik bileşenleri filtre edilmektedir. Aynı şekilde 10 Hz'e kadar düşük frekanslı bileşenler filtrelenebilmektedir. Ayrıca filtrelenen bu sinyaller dijital ortamda 50 Hz çentik filtre kullanılarak şebeke gürültüsünün de ortadan kalktığı Şekil 3.4'teki grafiklerden de görülmektedir.

Bu çalışmada 12bit ADC, kullanılmış, EMG sinyalleri çift kutuplu (bipolar) pozitif ve negatif yönlü sinyaller olması sebebiyle, sinyalin negatif genliklerin pozitif bölgede örneklenmesi için sinyallere DC gerilim eklenerek öteleyici (shifting) devreden geçirelerek örneklenmiştir. EMG sinyalleri 32 bit Atmel SAM3X8E ARM Cortex-M3 işlemci kullanılarak F_s : 4500 Hz aralığında örnekleme frekanslarıyla kayıt edilerek PC ortamına Baud Rate: 250000 bps haberleşme hızında aktarılmıştır.

Şekil 3.5'te Deneklerden alınan EMG sinyallerinin ölçüm ve kayıtlarında oluşturulan deney düzeneği ve de sonradan ev ortamı için kullanışlı hale getirilerek elde edilmiş ölçme ve kayıt sistemi gösterilmektedir. Bu sistemde sonradan tüm devre yapıları minimize edilmiş ve de DC güç kaynağı yerine adaptör beslemeli DC bataryalı bir yapıya dönüşmüştür. Böylelikle şebeke kaynaklı gürültüler için harici çentik filtre ünitesine de gerek duyulmadan boyut ve maliyet bakımından kullanışlı hale getirilmiştir.



Şekil 3.5 Deneyler için EMG ölçüm ve kayıt sistemi

3.1.1.1 EMG Sisteminin Kalibrasyonu

EMG sinyalleri için ölçüm öncesinde deneklerin çene ısırma kuvvetlerinin farklılıkları ve de EMG proplarının deri yüzey empedansından dolayı oluşan farklılık gözönüne alındığında her bir kişinin çene hareketleri esnasında ortaya

çıkabilecek çene sıkmadaki maksimum kasılma (Maximum Voluntary Contraction MVC) değerleri farklıdır. MVC'nin belirlenmesinde sinyalin RMS genlik değeri hesaplanmıştır [104]. MVC değerlerin kişiden kişiye farklı oluşu rahatsızlık tanısını ortaya koymada ciddi sıkıntılar ve yanlış tanının ortaya konulmasını beraberinde getirir. Bu sebeple çalışmada her bir ölçüm öncesinde kalibrasyon işlemleri yapılmıştır. Bu bağlamda her bir bireyin çene sıkmadaki MVC değerleri belirlenmiştir [66]. Bu sebeple deneklere öncelikle dişleri korumak için ağız içi aparey giydirilerek alt çenenin maksimum düzeyde kasılması için 3 sn süreyle ısırma (çene sıkma) ve de gevşeme (çene açma) kayıtları alınarak maksimum kasılmadaki %100 MVC'de RMS genlik değerleri her bir birey için belirlenmiştir. Sonraki aşamada her bir bireyden ısırma (çene kapama) hareketi %50 MVC durumunda gerçek zamanlı EMG sinyalleri kayıt edilerek, deneklerin çene kaslarında ağrı ve yorgunluk hissi oluşana kadar sıkılması istenmiştir. Kas yorgunluk ve ağrı oluşum süresi kişiden kişiye değişmekle beraber kas yorgunluğu ve/veya ağrının değerlendirilmesi sırasında kas yorgunluğu RDC/TMD kriterlerine göre 0 ile 10 birim arasında puanlanarak değerlendirilmiştir [105]. Ortalama kayıt süresi 60 sn $\pm$ 20 sn sürmüştür. Bu eylemler farklı zaman aralıklarında her bir denek için tekrarlanmıştır. Böylelikle deneklerin yorgunluk ve ağrı durumunu temsil edebilecek EMG veri kayıtları yapılmıştır.

Bir diğer aşamada ise farklı bir zamanda çok tekrarlı olarak 10 sn'lik süre boyunca tüm deneklerin rastgele çiğneme ve diş gıcırdatmaları istenmiştir. Bu aşamada Çene kaslarının %10 MVC değerlerinde EMG verileri her bir birey için kaydedilmiştir. Tüm veriler belli bir zaman aralığında kaydedildiğinden EMG analizleri için her bir veri sinyali 1sn'lik periyotlar halinde pencereleme yapılarak brüksizm tanılama da kullanılmak üzere bilgisayar ortamına aktarılmıştır [14], [15].

3.1.1.2 Normalizasyon

Sayısal dönüşüm için EMG sinyallerine pozitif DC sinyal eklenerek, bu sinyallerin yukarı yönde ötelenmesiyle gerçekleştirilmiştir. Bunun sebebi kullanılan 12 bit A/D dönüşümün 0 ile 3,3 V arasındaki değerleri sayısallaştırmasıdır. Sinyallerin sayısallaştırılmasıyla ayrıca bu sinyallerinin max ve min değerleri dikkate alınarak

normalizasyonun yapılması sağlanmıştır. Böylelikle deneklerden alınmış EMG sinyallerinin sınıflandırmada en doğru performansın elde edilmesi sağlanmaktadır. Çünkü kalibrasyon esnasında her bir bireyin çene kas güçleri farklıdır. Dolayısıyla bu farklılık, en etkili bir biçimde bruksizm teşhisin konulmasında kullanılan makine öğrenme ve sınıflandırıcı algoritmalarda sınıflandırma problemlerini ortaya çıkararak, teşhisin etkili bir biçimde ortaya konulmasını olumsuz olarak etkilemektedir. Normalizasyon denklemi eşitlik (3.1)'de ifade edilmektedir.


$$Z = \frac{X - \min(X)}{[\max(X) - \min(X)]} \quad (3.1)$$

(3.1)'de Z, X'in maksimum ve minimum değerleri arasında normalize edilmiş değerini temsil etmektedir. Bu değerler 0 ile 1 arasında değer almaktadır [106].

3.1.2 Akselerometre (MEMS) Tabanlı Ölçüm ve Veri Kayıt Sistemi

Bu çalışmada deneklerin alt çene kas aktiviteleri esnasında masseter kasından elde edilen tüm titreşim sinyalleri saniyede 4500 örnek olacak şekilde (Fs: 4500Hz) 12 bit A/D çevirici ile sayıllaştırılarak data kayıtları her bir denek için sinyaller elde edilebilmektedir. Bu bağlamda sensor olarak ADXL335 MEMs akselerometre sensörü deneklerin masseter kası yüzeyine giyilebilir bir yumuşak bir band başlık ile sabitlenmiştir. Bu sensörün düşey “z” eksenindeki frekans algılama aralığı 0,5 ile 500 Hz arasında mikro titreşimler algılanabilmektedir. Kişilerin istemsiz vücut hareketlerinden dolayı oluşan titreşimlerden kaynaklı gürültüler ve de diğer yüksek frekans gürültüleri için dijital ortamda 4.cü derece butterworth 5-100 Hz band geçiren (bandpass) filtre kullanılmıştır. Bunun için deneklerden masseter kasının kasılma ve gevşeme durumları için rastgele başlarını hareket ettirmeleri istenerek sinyallerin vücut hareketleri kaynaklı gürültülerden arındırılıp arındırılmadığı hızlı Fourier dönüşümleri (FFT) yapılarak ayrıca incelenmiştir. Bu

dönüşümlerde istemsiz vücut hareketleri kaynaklı yüksek genlikli düşük frekanslı bileşenlerin filtrelemeyle ortadan kalktığı rahatlıkla görülmektedir (Şekil 3.6).




Şekil 3.6 Akselerometre sinyallerinin FFT spektrumu ile genlik değişimleri

Bu çalışmada yapılan analizlerinde deneklerden alınan 1s periyodunda toplamda 100 adet sinyalden 12 adet zaman ve frekans özellikleri elde edilerek toplamda 1200 adet veri kullanılarak sınıflandırılmıştır. Çıkış özellikleri olarak 3 farklı sınıf mevcuttur. Bunlar;

- 1-Çene kaslarının gevşeme durumu,
- 2-Çene kaslarının diş sıkma durumu,
- 3- Ritmik parafonksiyonel diş gıcırdatma durumu

Şeklinde. Şekil 3.7’de bruksizm tanılama için tasarlanmış MEMS tabanlı akselerometre sistemine ait tüm aşamalarını gösteren düzenek yapısı gösterilmektedir.



Şekil 3.7 MEMS tabanlı bruksizm tanılama sistemine ait deneysel düzenek

3.2 Bruksizm Tanılaması için Parametrik Özellikler

3.2.1 Sinyallerin Genlik ve Frekans Özellikleri

Sinyallerin genlik ve frekans özellikleri bakımından bu çalışmada birbirlerinden farklı özellik parametreleri belirlenmiştir. Bu özellikler herhangi bir dönüşüm işlemi yapılmadan kolaylıkla hesaplanabilmektedir. Dolayısıyla gerçek zamanlı sinyallerin işlenmesi de kolay olmaktadır. Bu bölümde kullanılan bu özellikler aşağıda madde madde açıklanmıştır [106-113].

- **Ortalama Mutlak Genlik (MAV):** Sinyalin genlik deęerleri hakkında önemli bilgiler içermektedir. Özellikle kasın kasılması durumunda ortalama mutlak genlik deęeri önemli ölçüde artmaktadır. Eşitlik (3.2) kullanılarak deneklerin alt çene kaslarından elde edilen sinyallerin MAV deęerleri her bir sinyal için hesaplanabilmektedir.

$$MAV = \frac{1}{N} \sum_{i=1}^N |X_i| \quad (3.2)$$

(3.2)'de X_i , N uzunluęundaki X sinyalinin i noktasındaki mutlak deęeri anlamına gelmektedir [110].

- **Ortalama Karekök (RMS):** Bir sinyale ait genlik deęerlerinin etkin deęeridir. Eşitlik (3.3)'de de ifade edildięi gibi N uzunluęundaki X sinyalinin i noktasındaki deęerlerinin karelerinin ortalamasının karekökü demektir. Kasılma anındaki sinyalin RMS ve standart sapma (SD) özelliklerini içeren sayısal deęerler önemli ölçüde artmaktadır.

$$RMS = \sqrt{\frac{1}{N} \sum_{i=1}^N X_i^2} \quad (3.3)$$

- **Ortalama Frekans (MNF):** MNF, sinyalin herbir frekansa ait güç spektrum yoğunluęu deęerleri ile frekansların çarpınlarının toplam güç spektrum yoğunluęuna bölünmesiyle elde edilen ortalama frekans deęeridir. Eşitlik (3.4)'te gösterildięi şekilde hesaplanır.

$$MNF = \frac{\sum_{j=1}^M f_j P_j}{\sum_{j=1}^M P_j} \quad (3.4)$$

(3.4)'te f_j deęeri, j frekans spektrumundaki frekans deęeri, P_j ise, aynı şekilde güç spektrumunu ifade etmektedir.

- **Ortanca (Medyan) Frekans (MDF):** MDF, spektrumun iki yarısının ortasındaki frekans değeridir. Spektrumdaki ortanca frekans olarak bilinmektedir. (3.5)'teki eşitlikte gösterilmektedir [106].

$$MDF = \sum_{j=1}^{MDF} P_j = \sum_{j=MDF}^M P_j = \frac{1}{2} \sum_{j=1}^M P_j \quad (3.5)$$

- **Mutlak Genlik Değişimi (AAC):** AAC parametresi sinyalin dalgaboyunun ortalamasının alınması dışında sinyalin dalga boyu (WL) değeri ile eşdeğer kabul edilmektedir. Eşitlik (3.6)'da ifade edilmektedir.

$$AAC = \frac{1}{N} \sum_{i=1}^{N-1} |X_{i+1} - X_i| \quad (3.6)$$

- **Willison Genliği (WAMP):** Bu parametre, sinyalin frekans bilgisinin bir ölçüsüdür. EMG'nin genliğinin önceden belirlenmiş bir eşik seviyesini aştığında genlik seviyeleri arasındaki farklardan kaynaklanan tekrar sayılarıdır. Eşitlik (3.7)'de ifade edilmektedir.

$$WAMP = \sum_{i=1}^{N-1} [f(|X_i - X_{i+1}|)]; \quad (3.7)$$

$$f(X) = \begin{cases} 1, & \text{Eğer } X \geq \text{eşik değeri} \\ 0, & \text{aksi takdirde} \end{cases}$$

- **Mutlak Standart Sapma Farkı (DASD):** Bu parametre, değeri RMS özelliğine benzemekte diğer bir deyişle dalgaboyunun standart sapma değeridir. Eşitlik (3.8)'e göre hesaplanmaktadır [111].

$$DASDV = \sqrt{\frac{1}{N-1} \sum_{i=1}^{N-1} (X_{i+1} - X_i)^2} \quad (3.8)$$

- **Sıfır Geçiş Sayacı (ZC):** Bu parametre, bir sinyalin zaman aralığında tanımlanan frekans bilgisinin bir ölçüsüdür. Eşitlik (3.9)'a göre, belirlenen bir eşik seviyesine göre sinyalin sıfır geçiş durumlarının sayısı olarak ifade edilir. Diğer bir deyişle sinyalin pozitiften negatife veya tersi durumda yön değiştirmesinde sıfır değerine ulaştığı durumların tespit edilmesidir. Sıfır geçiş durumlarında gürültüden etkilenmemesi için bir eşik değeri kullanılmaktadır [107], [112].

$$ZC = \sum_{i=1}^{N-1} [sgn(X_i * X_{i+1}) \cap |X_i - X_{i+1}| \geq \text{eşik değeri}]; \quad (3.9)$$

$$sgn(X) = \begin{cases} 1, & \text{Eğer } X \geq \text{eşik değeri} \\ 0, & \text{aksi takdirde} \end{cases}$$

- **Dalga Boyu (WL):** Bu parametre, bir sinyalin bir aralık boyunca örnekten örneğe genliklerdeki toplam değişimleri açıklamaktadır.

$$WL = \frac{1}{N} \sum_{i=1}^{N-1} |X_{i+1} - X_i| \quad (3.10)$$

- **Log Dedektör (LOG):** Bu parameter kas kasılmasının doğrusal olmayan logaritmik olarak algılanmasını tahmin eden bir parametredir. Matematiksel ifadesi (3.11) nolu eşitlikte gösterilmektedir.

$$LOG = e^{\frac{1}{N} \sum_{i=1}^N \log |X_i|} \quad (3.11)$$

- **Varyans (VAR):** Genel olarak VAR parametresi (3.12)'de görüldüğü gibi bir değişken analog sinyaldeki sapmanın karesel değerlerinin ortalaması olarak tanımlanmaktadır [106].

$$VAR = \frac{1}{N-1} \sum_{i=1}^N X_i^2 \quad (3.12)$$

- **Eğim İşareti Değişimi (SSC):** Sinyalinin frekans bilgilerini temsil etmek için başka bir yöntemdir. Sinyal eğiminin birkaç kez işaret değiştirmesiyle sinyaldeki arka plan gürültüsünü önlemek için üç ardışık segment arasındaki pozitif ve negatif eğimler, eşik fonksiyonu kullanılarak değişim sayısının belirlenmesidir (3.13).

$$SSC = \sum_{i=2}^{N-1} [f(X_i - X_{i-1}) * (X_i - X_{i+1})]; \quad (3.13)$$

$$f(X) = \begin{cases} 1, & \text{Eğer } X \geq \text{eşik değeri} \\ 0, & \text{aksi takdirde} \end{cases}$$

Toplam 20 denekten elde edilen bruksizmin tanısı için alt çene kaslarının gevşeme durumları, çene kapama veya kenetlenmesi, rastgele çiğneme ile birlikte diş gıcırdatma hareketleri ve de kasların diş sıkma esnasında oluşturdukları kas ağrıları ve yorgunluk koşulları altındaki gerçek zamanlı kayıt edilen EMG ve MEMS tabanlı sinyaller için farklı genlik ve frekans özellik (MNF, MDF, MAV, RMS, DASD, SD, MFL, VAR, LOG, ZC, SSC, WL, WAMP ve AAC) parametreleri elde edilerek, bu parametrelerin bruksizm ile ilgili alt çene aktivite sonuçlarına ilişkin olarak korelasyon derecesini araştırmak, diğer bir deyişle anlamlı özellikleri ortaya koymak için istatistiksel olarak regresyon analizleri yapılarak elde edilen korelasyon katsayıları Tablo 3.1 ve Tablo 3.2’de sunulmuştur.

Tablo 3.1 EMG tabanlı sinyaller için kullanılan özelliklerin korelasyonları

Giriş Özellikler	Ortalama±std	R ²	P değeri
MNF	180.21±36.09	0.22	<0.005
MDF	152.80±44.05	0.59	<0.005
LOG	0.014±0.01	0.54	<0.005
VAR	0.68±1.93	0.56	<0.005
SSC	54.76±101.26	0.37	<0.005
MAV	0.022±0.017	0.60	<0.0005
ZC	177.36±144.39	0.77	<0.0001
WAMP	1025.05±891.51	0.72	<0.0001
WL	30.88±25.50	0.64	<0.0001
RMS	0.029±0.022	0.65	<0.0001
DASD	0.0093±0.0077	0.73	<0.0001
AAC	0.0070±0.0059	0.67	<0.0001
SD	0.029±0.022	0.62	<0.0001

Tablo 3.2 MEMS tabanlı sinyaller için kullanılan özelliklerin korelasyonları

Giriş Özellikler	R ²	P değeri
MNF	0,1829	<0.0001
MDF	0,0867	<0.005
LOG	0,0003	0,844
MAV	0,0045	0,502
RMS	0,0135	0,249
MFL	0,0751	<0.001
WL	0,0057	0,453
ZC	0,0829	<0.005
WAMP	0,0007	0,789
AAC	0,0051	0,476
VAR	0,0013	0,712
DASD	0,0180	0,018

Tablo 3.1’de görüldüğü gibi EMG sinyalleri için 13 özellik arasından en etkili 5 özellik seçtiğimizde, bu özellikler ZC, WAMP, RMS, DASD ve AAC olmaktadır. Aynı şekilde Tablo 3.2’de ise MEMS titreşim sinyalleri için en etkili 5 özellik MNF, MDF, MFL, ZC ve DASD olmaktadır. Bu tabloları incelediğimizde EMG hem de MEMS sinyalleri için ortak olan en etkili özellik ZC özelliği olmaktadır. Çünkü R² regresyon katsayısı yüksektir. Ayrıca P değerleri de minimum olmaktadır. Pearson korelasyon (P değerinin) <0,01 olması kabul edilebilir bir ilişki var olduğu anlamına gelmektedir.

3.2.2 Otoregresyon (AR) Parametreleri

Otoregresyon (AR), bir sistemde önemli durum parametrelerini içermektedir ve sistemde zamana bağlı olarak bir değişikliğe çok duyarlı olmasıyla zaman serisi analizi için büyük öneme sahiptir. Bu model, herhangi bir veri setinde temel özellikleri yakalama açısından önemli bir modeldir. Doğrusal bir AR modeli (3.14) eşitliği ile ifade edilmektedir [114-116].

$$X_m = \sum_{i=1}^p a_i X_{m-i} + \varepsilon_m \quad (3.14)$$

(3.14)'te X_m değeri, m anındaki bir sinyalin tahmin edilen değeri olmakla birlikte a_i değeri, ($i=1, 2, \dots p$) p 'ye kadar olan bu sayılar ağırlık katsayılarıdır. Bu değer, AR modelin düzenini ifade etmektedir. ε_m , gerçek ve tahmin edilen değer arasındaki farkı gösteren hata terimidir. Bu değer beyaz gürültü sinyalini veya dürtü biçimindeki durağan olmayan sinyalleri içermektedir [106], [117]. Bu modelde X_m , X_{m-i} değerlerine bağlı olarak zaman serisi şeklinde ifade edilmektedir. Böylece bir sinyalin AR modellenmesi bir dizi parametre ile sonuçlanmaktadır. Bu parametreler, bir sinyalin düzeni hakkında önemli bilgiler içermektedir. Bu bilgiler sayesinde sınıflandırma süreçlerinde ve veri analizlerinde özellik seti olarak kullanılmaktadır.

Bu tez çalışmasında her bir EMG sinyaline ait X_m zaman serisi 12 düzende oluşturularak, bu sinyallere ait AR katsayıları elde edilmiştir. Literatürde 2, 3, 4, 6 ve 8 düzende oluşturulabilmektedir [114-119]. Ancak bu çalışmada EMG sinyallerinin karmaşıklığından dolayı X_m zaman serisine ait AR katsayıları 12 düzende olmaktadır. EMG sinyallerinden elde edilmiş 12 düzenli AR katsayılarını içeren veri seti, bu çalışmada YSA ile sınıflandırılarak yüksek bir performans sağlamaktadır. Dolayısıyla ($a_1, a_2, \dots a_{12}$) 12 düzenli AR katsayıları, X_m zaman serisini temsil eden EMG sinyallerinden, bruksizm'in etkili tanınması için özellik seçimlerinde kullanılmıştır. Matematiksel olarak AR katsayılarını ifade ettiğimizde bu katsayılar a_i değerleri olarak ($i=1,2, \dots p$)' ye kadar (3.15) ve (3.16)'da ifade edilmektedir.

$$X_m = a_1X_{m-1} + a_2X_{m-2} + \dots + a_{12}X_{m-12} + \varepsilon_m \quad (3.15)$$

$$\underbrace{\begin{bmatrix} 1 & X_1 & X_2 & \dots & X_{p-1} \\ X_1 & 1 & X_1 & \dots & X_{p-2} \\ \dots & \dots & \dots & \dots & \dots \\ X_{p-1} & X_{p-2} & \dots & X_1 & 1 \end{bmatrix}}_{\mathbf{R}} \underbrace{\begin{bmatrix} a_1 \\ a_2 \\ \dots \\ a_p \end{bmatrix}}_{\mathbf{a}} = \underbrace{\begin{bmatrix} X_1 \\ X_2 \\ \dots \\ X_p \end{bmatrix}}_{\mathbf{r}}$$

$$\mathbf{a} = \mathbf{R}^{-1} * \mathbf{r} \quad (3.16)$$

3.3 Fourier Dönüşümü

Fourier dönüşümü; zamana bağlı olarak bir sinyale ait frekans bileşenlerini ayrıştırmak için kullanılan bir yöntemdir [120]. Biyolojik işaretler, zamana bağlı olarak ortaya çıkmalarına karşın, bu işaretlerin analizlerinin frekans domeninde yapılması birçok durumda daha anlamlı sonuçlar koyabilmektedir. Frekans domeni analizlerinde, frekans bileşenleri ve bu bileşenlere ait güç spektrum yoğunlukları (PSD) elde edilebilmektedir. Zamana bağlı olarak elde edilen $X(t)$ işareti, (3.17)'deki eşitlik kullanılarak Fourier dönüşümü elde edilmekte ve böylelikle frekans değerlerine bağlı dönüşümü $X(\omega)$ olarak adlandırılmaktadır [121].

$$X(\omega) = F\{X(t)\} = \int_{-\infty}^{+\infty} X(t)e^{-j\omega t} dt \quad (3.17)$$

Ancak tez çalışmasında Fourier dönüşümü analog sinyallerin dijital ortamda 1saniyede 4500 örnek olacak şekilde ($F_s:4500\text{Hz}$) alınmıştır. Diğer bir deyişle sinyaller ayrık hale getirilerek Fourier dönüşümü uygulanmıştır. Bu dönüşüm, $X(nT_s)$ dizisi üzerinde lineer operatör kullanılarak (3.18)'deki eşitlikte tanımlanmaktadır.

$$X(\omega_0 k) = \sum_{k=0}^{N-1} X(nT_s) e^{-j2\pi k n T_s} \quad (3.18)$$

Eşitlik (3.18)'de $k=0, 1, 2, 3, \dots(N-1)$ 'e kadar tanımlanmaktadır. ω_0 frekansı (3.19)'den elde edilmektedir.


$$\omega_0 = \frac{\omega_s}{N} \quad (3.19)$$

(3.18)'de ω_s örnekleme frekansını temsil etmektedir. Frekans çözünürlüğünün mümkün olduğunca yüksek olması için, ω_0 değeri minimum tutularak, işaretin süresinin mümkün olduğunca yüksek tutulması gerekir. Eşitlik (3.18)'den

görüldüğü gibi, N elemanlı ayırık $X_n=X(n)=X(nT_s)$ dizisinin ayırık Fourier dönüşümü sonucunda, N elemanlı $X[k]$ dizisi elde edilmektedir. Bu durum (3.20)'de görüldüğü gibi Hızlı Fourier Dönüşümü (FFT) olarak adlandırılmaktadır [122].

$$X[k] = \sum_{n=0}^{N-1} X[n] e^{-j\left(\frac{2\pi}{N}\right)kn}; \quad k = 1,2,3, \dots, N-1 \quad (3.20)$$

FFT, periyodik sinyaller için kullanılan bir yöntem olmasına rağmen, EMG, EEG, EKG gibi periyodik olmayan biyolojik sinyallere de uygulanabilir. Ancak, spektral bileşenleri zamana göre ayırmada yetersizdir. Bu nedenle bu tezde daha ayrıntılı özelliklerin elde edilmesinde dalgacık dönüşümü kullanılmıştır. Bu çalışmada FFT kullanılmasıyla elde edilen frekans spektrumlarında her bir frekansın f_j değeri ve P_j PSD değerleri elde edilmiştir. Böylelikle sinyale ait MNF ve MDF parametrik özellikleri (3.4) ve (3.5) kullanılarak elde edilebilmektedir. Şekil 3.8'de örnek bir deneğe ait alt çene masseter kasının 1sn'lik bir sürede kasılma esnasında alınmış bir EMG sinyalinin MNF ve MDF değerlerini gösteren frekans spektrumu gösterilmektedir.



Şekil 3.8 Örnek bir EMG sinyaline ait frekans-güç spektrumu

3.4 Dalgacık Dönüşümü

Dalgacık dönüşümü, son yıllarda literatürdeki analizlerde durağan olmayan sinyallerin analizlerinde tercih edilmektedir. Fourier dönüşümünün zaman-frekans analizlerinde yetersiz kalmasından dolayı geliştirilmiş modern bir yöntemdir. Bu yöntemde, zamanın ve frekansın ölçeklenmesiyle gerçek zamanlı bir sinyalden daha fazla özelliklerin elde edilmesi prensibine dayanmaktadır. Bu dönüşüm metoduyla alçak frekanslarda, band genişliğinin dar olduğu yerler için geniş ve ölçeklenebilir bir pencere ile yüksek frekans bileşenlerini analiz etmede kullanılır [123]. Bu metot özellikle, frekans spektrumundaki farklı bölgelerin kolaylıkla frekans çözünürlüklerin ayarlanabilmesinde, spektrum analizlerinde farklı frekans bandlarının kullanılması ile frekans spektrumunun tamamının hesaba dahil edilmemesi ve böylelikle alçak frekanslardaki dönüşüm hızının yüksek olmasını sağlamasıyla da avantajlı bir metot olmaktadır. Dolayısıyla durağan olmayan sinyallerden daha esnek ve kullanışlı zaman-frekans bilgisi elde edilebilmesinde etkili bir metot olmaktadır [124].

3.4.1 Sürekli Dalgacık Dönüşümü

Sürekli dalgacık dönüşümü (SDD)'de, sinyal boyunca kaydırılan ölçeklenebilir, pencere modülleri kullanılmaktadır. Her bir kaydırma işleminin sonucunda sinyalin spektral bileşenleri incelenmektedir. Böylelikle farklı çözünürlükte sinyale ait frekans-zaman spektrumları elde edilmiş olur. Fourier dönüşümünde pencereleme yapılırken sabit ölçekleme ile eşit aralıklarda spektrum elde edilir iken, dalgacık dönüşümünde ise farklı ölçeklemeler kullanılarak zaman-frekans analizleri yapılabilir [125]. Bu dönüşüm metodunun matematiksel denklemi (3.21) eşitliğinde ifade edilmektedir.

$$W(a, b) = \int_{-\infty}^{+\infty} X(t) \frac{1}{\sqrt{|a|}} \psi_{a,b} \left(\frac{t-b}{a} \right) dt \quad (3.21)$$

Eşitlik (3.21)'de sinyalin zamana bağlı değişimi $X(t)$ olarak ifade edilmektedir. $\psi(t)$, dönüşümde kullanılacak dalgacık fonksiyonu; b , farklı frekans seviyeleri için

dönüşüm faktörü olarak tanımlanmaktadır. Ölçeklemede kullanılan bir diğer parametre ise a faktörü olmaktadır. Dolayısıyla a=1, b=0 için $\psi_{a,b}(t) = \psi(t)$ olarak ana dalgacığın kendisi anlamına gelmektedir [126].

3.4.2 Ayrık Dalgacık Dönüşümü

Ayrık Dalgacık Dönüşümü (ADD) metodu, ayrık zamanlı Fourier dönüşümüne benzemektedir. Dolayısıyla giriş sinyali analizler için farklı fonksiyonlar kullanılarak parçalı bir şekilde ayrık olarak analiz edilmektedir. Ayrık zamanlı Fourier dönüşümünden farkı ise, ADD metodunda pencereleme yerine ayrı bir dalgacık fonksiyonunu kullanılarak analizlerin gerçekleşmesidir. SDD'de ise hesaplama yükü ve kullanıldığı işlem miktar bakımından fazladır. Diğer bir deyişle bu yöntemde, yüksek frekanslara çıkıldıkça zaman çözünürlüğü artar ve de düşük frekans çözünürlüğü elde edilir. Alçak frekanslara inildiğinde ise bu kez zaman çözünürlüğü azalır ve yüksek frekans çözünürlüğü elde edilmektedir. Böylelikle Sinyalin zaman-frekans düzleminde etkin bir şekilde işlenmesini sağlamaktadır [120]. Dolayısıyla Bu tez çalışmasında ADD 'nin kullanılması tercih edilmektedir.

ADD, bir durağan olmayan bir sinyale uygulandığında iki önemli fonksiyon karşımıza çıkmaktadır. Bunlar ölçekleme $\phi(t)$ fonksiyonu ve dalgacık $\psi(t)$ fonksiyonudur. Ölçekleme fonksiyonu, giriş sinyali ile konvolüsyona girerek yaklaşım bileşenlerini oluşturmaktadır. Ölçekleme fonksiyonun matematiksel ifadesi (3.22)'de gösterilmektedir.

$$\phi(t) = 2^{-m/2} \phi(2^{-m}t - n) \quad (3.22)$$

Eşitlik (3.22)'de m, ölçekleme seviyesi sayısını belirtmekte, n ise öteleme miktarını ifade eder. Bu fonksiyonun giriş sinyali ile konvolüsyona girerek oluşturduğu yaklaşım katsayılarının matematiksel denklemleri (3.23)'te gösterilmektedir.

$$S_{m,n} = \int_{-\infty}^{+\infty} X(t) \phi_{m,n}(t) dt \quad (3.23)$$

Elde ettiğimiz yaklaşım katsayıları ölçekleme fonksiyonu ile tekrar işleme sokularak yaklaşım ve detay bileşenleri hesaplanır. Dolayısıyla (3.24)'teki eşitlikte yaklaşım bileşenlerini; (3.25)'teki eşitlikte ise detay bileşenlerini ifade etmektedir.

$$A(t) = \sum_{n=-\infty}^{\infty} S_{m,n} \phi_{m,n}(t) \quad (3.24)$$

$$D(t) = \sum_{n=-\infty}^{\infty} T_{m,n} \psi_{m,n}(t) \quad (3.25)$$

Eşitlik (3.25)'teki $T_{m,n}$ detay katsayılarını, $\psi_{m,n}(t)$ ise dalgacık fonksiyonunu ifade etmektedir. Burada yaklaşım ve detay bileşenleri hesaplanırken ölçekleme fonksiyonun daralma ve kayma özellikleri önem kazanmaktadır. Bu durum (3.26)'da ifade edilmektedir.

$$\phi(t) = \sum_k c_k \phi(2t - k) \quad (3.26)$$


Eşitlik (3.26)'da $\phi(t)$ fonksiyonu, zaman ekseninde k kadar ötenerek elde edilen $\phi(2t-k)$ fonksiyonunun, her k değerine karşılık elde edilen c_k ölçekleme katsayısı ile çarpılarak elde edilmektedir. Bu denklemde bir önceki ölçekleme denklemi vasıtasıyla diğer bir ölçekleme fonksiyonu elde edilebilmektedir. Burada dikkat edilmesi gerek iki ölçüt bulunmaktadır. Ortoganallığı sağlamak için ölçekleme katsayılarının karesel toplamı ve de her bir k değerine karşılık gelen c_k ölçekleme katsayıların toplamı ikiye eşit olmalıdır. Ölçekleme katsayıları kullanılarak dalgacık denklemini (3.27) eşitliğinde elde edebilmekteyiz.

$$\psi(t) = \sum_k (-1)^k c_{1-k} \phi(2t - k) \quad (3.27)$$

(3.27)'de $(-1)^k c_{1-k}$ matematiksel ifadesi b_k diğ er bir deyiş le dalgacık katsayısıdır. Dolayısıyla (3.27)'deki eş itliğı tekrar düzenlediğimiz de, (3.28) eş itliğı elde edilmektedir.

$$\psi(t) = \sum_k b_k \phi(2t - k) \quad (3.28)$$

Ölçekleme denklemindeki c_k ve dalgacık denklemindeki b_k katsayıların hesaplanması için sinyalin farklı band genişliğinde ayrıştırılması için Ş ekil 3.9'da görüldüğü gibi $h(k)$ yüksek geçiren (Highpass-HP) ve $g(k)$ alç ak geçiren filtre (Lowpass-LP) filtrelerden geçirilmesi gerekir. Eş itlik (3.29) ve (3.30)'daki bu dönüşüm sonucu elde edilen fonksiyonlar gösterilmektedir [127-130].



Ş ekil 3.9 EMG sinyalinin detay ve yaklaşım bileş enlerine ayrıştırılması


$$\phi(t) = \sqrt{2} \sum_{k=0}^N g(k) \phi(2t - k) \quad (3.29)$$

$$\psi(t) = \sqrt{2} \sum_{k=0}^N h(k) \phi(2t - k) \quad (3.30)$$

Alçak ve Yüksek filtrelerden geçirilen bu fonksiyonların elde edilmesi için c_k ve b_k katsayıların bilinmesi gerekir. Bu katsayıların belirlenmesinde literatürde farklı dalgacık modelleri mevcut olsada Daubechies dalgacığı dönüşümü daha pratik hale gerimektedir. Bu dalgacık dbN olarak sembolize edilmektedir. Böyle bir dalgada $2N$ adet ölçekleme katsayısına sahiptir [131]. Dolayısıyla bu çalışmada Daubechies db4 fonksiyonu Şekil 3.10'da gösterildiği gibi 8 ölçekleme ($k=0, 1, 2, \dots, 7$) uygulanmaktadır. Bu fonksiyon sayesinde (3.31) ve (3.32)'de ifade edildiği gibi, c_k ve b_k zaman domeninde elde edilebilmektedir [132], [133]. Dolayısıyla $A(t)$ ve $D(t)$ bileşenleri, c_k ve b_k sayesinde elde edilebilmektedir.

$$\phi(t) = c_7(2t - 7) + c_6(2t - 6) + \dots + c_0(2t) \quad (3.31)$$

$$\psi(t) = b_7(2t - 7) + b_6(2t - 6) + \dots + b_0(2t) \quad (3.32)$$



Şekil 3.10 Daubechies fonksiyonu (db4 8 seviyeli)


Bu tez çalışmasında deneklerin alt çene kaslarından elde edilen EMG sinyallerinin dalgacık dönüşümleri db4 Daubechies dalgacık fonksiyonu ile 8 ölçekleme yapılarak detay bileşenleri elde edilmiştir. Elde edilen 8 ölçeklemeli detay bileşenlerinin herbirinden Shannon entropileri, $E_1, E_2, \dots, E_8$ 'e kadar hesaplanarak bruksizm tanılamada giriş özellikleri olarak kullanılmaktadır. Bunun için elde

edilen her bir bileşenin dalgacık enerji spektrumları E_{jk} dikkate alınmıştır. Bu durum (3.33) eşitliğinde ifade edilmektedir.

$$E_{jk} = |D_j(k)|^2, \begin{cases} D_j(k): [2^{-(j+1)}fs, 2^{-j}fs] \\ (j = 1, 2, \dots, m) \end{cases} \quad (3.33)$$

$$E_j = - \sum_k E_{jk} \log E_{jk} \quad (3.34)$$


(3.33)'de $D_j(k)$ ifadesi wavelet dönüşümüyle elde edilen detay bileşenlerin örnekleme frekansı (fs) bağlı olarak j ölçeğinde, k anındaki frekans domenindeki ifadesidir. Dolayısıyla Herbir detay bileşenin Shannon entropi E_j değerleri, (3.34) ile hesaplanmıştır. Dalgacık dönüşümüyle elde edilen detay bileşenlerinin entropi özelliklerini gösteren bu yöntem, Şekil 3.11'de gösterilmektedir [134-136].



Şekil 3.11 EMG sinyalinin dalgacık entropi değerlerinin elde edilmesi

3.5 Yapay Sinir Ağları

Yapay sinir ağları (YSA), insanoğlunun biyolojik sinir sistemlerini modelleyen matematiksel bir hesaplama yöntemidir. Bu yöntem literatürde öğrenme, genelleme, sınıflandırma, özellik belirleme ve optimizasyon durumlarında kullanılabilmektedir. Bunun için belli konulardaki verisetlerini kullanarak ağ yapısı kendini eğitir ve de sonrasında önceden karşılaşmadığı bir durum karşısında tahmin kararları verebilmektedir. Diğer bir deyişle, ağ ortamına sunulan bir girdi seti verisine bağlı olarak bir çıktı oluşturabilmesidir. Bu sebeple ağ yapısı, daha önceden girişlere karşılık çıkışları bilinen veri örnekleriyle eğitilerek öğrenme yapabilecek düzeye eriştirilmektedir [137]. Şekil 3.12’de örnek bir YSA yapısı gösterilmektedir.



Şekil 3.12 Örnek bir YSA yapısı

3.5.1 YSA’ların Tarihçesi

YSA’nın kısaca tarihçesine bakacak olursak, ilk defa 1943 yılında Warren McCulloch ve Walter Pitts tarafından ortaya çıkartılmıştır. Sonrasında 1949 yılında Donald Olding Hebb tarafından geliştirilerek Hebbian öğrenme kuramını ortaya koymuştur. 1984 yılında Hopfield’in çalışmalarıyla lineer olmayan çok daha zor problemlerin çözümünü yapabilecek düzeye erişmiştir [138-141].

3.5.2 YSA'ların Avantaj ve Dezavantajları

YSA'ların kullanımda birtakım avantajları mevcuttur [140-142]. Bunları madde madde sıralayacak olur isek;

- Bilgilerin kullanımda ağın tamamında yayılarak saklandığı için bir ya da birkaç bilginin eksikliğinden etkilenmezler.
- YSA'ların birden fazla nöronunun devreden çıkması sonuca etkisi olmamaktadır.
- Öğrenebilir bir yeteneğe sahip olmasıyla benzer olaylar karşısında yorum yaparak karar verme yeteneğine sahiptirler.
- YSA'lar birden fazla işi aynı anda gerçekleştirebilecek yeteneğe sahiptir.
- Yapıları gereği daha önceden hiç karşılaşmadıkları durumlar hakkında sonuç üretebilirler.
- Yapay sinir ağlarının hatalara karşı toleranslı olmalarıyla herhangi bir problem çıktığında anında yanlış karar vererek çıktı üretmezler.

Yukarıda verilen yanı sıra YSA'ların birtakım dezavantajları da mevcuttur. Bu dezavantajlar aşağıda madde madde sıralanmıştır.


- Yapay sinir ağları sadece nümerik bilgiler ile çalışmaktadır. Eğer kullanıcılar herhangi bir veriyi doğru bir şekilde nümerik bilgiye çeviremezler ise YSA yanlış olarak hatalı sonuç üretebilmektedir.
- Genellikle çalışmada hangi ağ yapısının kullanılacağı deneme yanılma yoluyla belirlenebilmektedir. Uygun bir ağ yapısı kurulamaz ise problemin çözümü yapılamamakta veya düşük performansla çalışmasına sebep olabilmektedir.
- Ağın eğitiminde ne zaman sonlanması hususunda geliştirilmiş bir yöntem mevcut değildir. Genellikle eğitimde kullanılan örnekler üzerindeki hatanın belirli bir değerin altına indirildiğinde eğitim sonlandırılmaktadır.
- Ağın öğrenme katsayısı, ağda kullanılacak nöron sayısı, ara katman sayısı gibi parametre değerlerinin belirlenmesinde herhangi bir kural olmamasıyla kullanıcıyı zor durumda bırakabilmektedir.

YSA'ların yukarıda belirtilen dezavantajları olmasına rağmen birçok problem türünün çözümünde başarılı olabilmesiyle minimum hata değerlerinin elde

edilmesinde kullanıcıların yeterince bilgi birikimi ve tecrübeye sahip olması gerekmektedir [137].

3.5.3 Yapay Sinir Hücresinin Yapısı

YSA'lar insan beyninden esinlenerek geliştirilmiş, ağırlıklı bağlantılar ile birbirleri arasında bağlantı kurabilen yapılardır. İnsan beyninde bu yapılar nöron hücresini temsil etmekte ve de birbirlerine bağlanarak sinir ağlarını oluşturmaktadır. Bu bağlantı biyolojik olarak bu bağ yapıları dentrit ve akson uçlarının birbirleriyle bağlantı kurmasıyla gerçekleşmektedir. Dentritler, gelen uyarıları alır ve aksonlara iletirler. Aksonlar da aldıkları uyarıları başka sinir hücresine iletmektedir Şekil 3.13) [142].




Şekil 3.13 Biyolojik sinir hücresi

Şekil 3.13'te gösterilen biyolojik bir sinir hücresinde diğer sinir hücrelerinden gelen uyarıları, bilgiler dentritler vasıtasıyla alınarak bu bilgiler toplanmak üzere hücre çekirdeğine iletilir. Benzer şekilde yapay sinir hücresinde ise ağırlıklı girişler alınarak toplama fonksiyonuna iletilir. Bir yapay sinir ağında toplama fonksiyonu hücrenin net girdisini sağlayan fonksiyondur. (3.35) eşitliğinde bu fonksiyonun matematiksel denklemi gösterilmiştir [132], [142], [143].

$$NET = \sum_{i=1}^n w_i X_i \quad (3.35)$$

(3.35)'de NET, ağırlıklı girişlerin çarpımlarının toplamını ifade etmektedir. w , ağırlıkları, X girişleri, n ise toplam giriş sayısını ifade etmektedir. Yapay sinir hücresinin modeli Şekil 3.14'te gösterilmiştir [132], [142], [143].



Şekil 3.14 Yapay sinir hücresi

Yapay sinir hücresine gelen veriler ağırlıklar ile çarpılırlar. Ağırlık değerleri pozitif veya negative değer olabilir. Şayet sıfır değerini alırsa, bağlı olduğu girişin etkili olmadığı anlamına gelmektedir. Şekil 3.14'te gösterilen aktivasyon fonksiyonu ise, elde edilen net girdinin işlenerek çıktığı diğer bir deyişle sonucu oluşturan fonksiyondur. YSA modellerinde doğrusal olmayan fonksiyonların seçilebilmesi ve de türevlenebilir bir fonksiyon olması önemlidir [132], [142], [143]. Genellikle çok katmanlı YSAlarda günümüzde yaygın olarak sigmoid aktivasyon fonksiyonu kullanılmaktadır. (3.36) eşitliğinde toplama fonksiyonundan gelen NET toplam değerine karşılık sigmoid fonksiyonunun matematiksel ifadesi gösterilmektedir.

$$F(NE T) = \frac{1}{1 + e^{-NE T}} \quad (3.36)$$

Sigmoid fonksiyonuna alternative olarak diğer aktivasyon fonksiyonların matematiksel ifadeleri ve açıklamaları Tablo 3.3'te gösterilmektedir.

Tablo 3.3 Aktivasyon fonksiyon örnekleri

Aktivasyon Fonksiyonu	Açıklama
Lineer Fonksiyon	$F(NE T) = NE T$
Step Fonksiyonu	$F(NE T) = \begin{cases} 1 & \text{eğer } NE T > \text{eşik değ er} \\ 0 & \text{eğer } NE T \leq \text{eşik değ er} \end{cases}$
Sinüs Fonksiyonu	$F(NE T) = \sin(NE T)$
Eşik Değ er Fonksiyonu	$F(NE T) = \begin{cases} 0 & \text{eğer } NE T \leq 0 \\ NE T & \text{eğer } 0 < NE T < 1 \\ 1 & \text{eğer } NE T \geq 1 \end{cases}$
Hiperbolik Tanjant Fonksiyonu	$F(NE T) = \frac{(e^{NE T} + e^{-NE T})}{(e^{NE T} - e^{-NE T})}$

3.5.4 YSA'ların Eğ itilmesi

İnsanoğ lunun beyni yaşam boyu karşılaşt ığı yeni durumlar karş ısında biyolojik sinir ağ yapısındaki sinirsel bağlantılar kurarak kendini sürekli geliřtirmekte, öğrenmektedir. Aynı řekilde yapay sinir hücrelerinden oluşmuş YSA'larda ise, nöron bağlantılarındaki ağırlık değ erlerini güncelleyerek kendini geliřtirmekte, yeni durumlar karş ısında anlamlı sonuçlar üretebilmektedir. Dolayısıyla YSA'larda ağırlık değ erlerinin güncellenmesinde veya belirlenmesinde ağ ın eğ itilmesiyle gerç ekleşmektedir [137]. İlk defa YSA yapısı oluşturulduktan sonra çevresel birimlerden girişler alınır ve rastgele seç ilen başlangıř ağırlık değ erleriyle işleme sokulmaktadır. Sonrasında aktivasyon fonksiyonundan elde edilen çık ıř ile beklenen çık ıř değ erı karşılařtırılarak hata değ erı hesaplanır. Hata değ erı minimum olana kadar iterasyon gerç ekleşerek ağırlık değ erleri güncellenmektedir. Bu duruma ağ ın eğ itilmesi denmektedir. Minimum hata elde edilinceye kadar ağ defalarca eğ itilebilir. Hatanın minimum olmasıya gerç ek değ ere en yakın sonuçları elde edebilecektir ve de karşılaşt ığı yeni bir durumda genelleme yapabilecektir. Bu durumda ağ yapısı eğ itilmiş bir yapısı olmaktadır. Eğ itim işleminin tamamlanmasından sonra ağ yapısının en güncel ağırlık değ erleri ile ağ ın daha önceden karşılařmadığı durumlar test edilerek ağ ın performansı

ölçülmelidir. Bu duruma ağırlık validasyonu denmektedir. Ancak validasyon değeri yüksek çıkana kadar eğitim devam etmelidir. Bu aşamadan sonra ağırlık eğitimi tamamlanmaktadır.

YSA'nın eğitilmesi için ürettiği çıktı değerleri ile beklenen çıktı değerleri arasındaki fark hatası (3.37)'de gösterildiği şekilde hesaplanarak ağırlık değerleri ve öğrenme parametreleri güncellenir.

$$E_n = H_n - \zeta_n \quad (3.37)$$

Yukarıdaki denklemde n.ci durum için E, hata değeri; H değeri beklenen çıkış; ζ değeri ise ağırlık hesapladığı çıkış değeridir. Ancak bu denklemde sadece bir adet işlem elemanı için geçerlidir. Bu durumda hata değeri negative veya sıfır değerleri alabilir. Bunu engellemek için toplam hata (3.38)'deki gibi hesaplanmalıdır.

$$E_{toplam} = \frac{1}{2} \sum_m E_n^2 \quad (3.38)$$

Toplam Hatayı (E_{toplam}) minimum olması için ağırlık değerleri güncellemesi iki şekilde yapılmaktadır. Bunlardan ilki Çıkış ile ara katman arası ağırlıkların güncellenmesi, diğeri ise ara katman ile giriş katmanı arasındaki ağırlıkların güncellenmesi şeklindedir.

3.5.4.1 Çıkış Katmanı ile ara katman arası ağırlıkların güncellenmesi

Çıkış katmanındaki n.ci işlem elemanı ve ara katman üzerindeki j.ci işlem elemanı arasındaki bağlantının ağırlık değerindeki değişim miktarı ΔW_n^a şeklinde ifade ettiğimizde, herhangi t.ci iterasyondaki bu değişim miktarı (3.39)'daki eşitlikte gösterildiği gibidir.

$$\Delta W_n^a(t) = \lambda \delta_n \zeta_j^a + \alpha \Delta W_{jn}^a(t-1) \quad (3.39)$$

(3.39)'daki bu denklemde α momentum katsayısı, λ öğrenme katsayısı, δ_n ise n.ci çıkış biriminin hatasını ifade etmektedir. Öğrenme katsayısı ağırlıklardaki değişim miktarını belli oranlarda ayarlanması içindir. Momentum katsayısı ise ağırlık öğrenme esnasında ağırlık değişim değerini, hata değerindeki değişime bağlı

olarak ayarlar. Örneğin ağırlık değerine kadar arttırılırsa, hata da o denli minimum oluyor ise bu durumda momentum katsayısı arttırılarak minimum hatayı elde etme hızı da böylelikle arttırılmış olunur. Hatanın n.ci çıkış ünitesindeki matematiksel denklemi (3.40) eşitliğinde gösterilmektedir.

$$\delta_n = f'(NET)E_n \quad (3.40)$$

(3.40)'daki bu denklemde aktivasyon fonksiyonunun türevi $f'(NET)$ şeklinde ifade edilmektedir. Hata ve ağırlıkların değişim miktarı (3.39) ve (3.40) ile hesaplandıktan sonra artık t.ci iterasyondaki ağırlık değerinin yeni değeri (3.41) eşitliği kullanılarak hesaplanabilmektedir.

$$W_{jn}^a(t) = W_{jn}^a(t - 1) + \Delta W_{jn}^a(t) \quad (3.41)$$

3.5.4.2 Ara katman ile giriş katman arası ağırlıkların güncellenmesi

Bu işlemde ara katman ile çıkış katmanı arasındaki ağırlık değişimlerinde olduğu gibi çıkış katmanındaki hata miktarları dikkate alınmıştır. Çünkü hataların oluşmasında giriş ve ara katmanındaki değerlerin payı bulunmaktadır. Ara katmanlara gelen bilgiler ya bir önceki ara katmandan ya da giriş katmanından gelmektedir. Bu sebeple giriş katmanı ve ara katman (katmanlar arası) ağırlık güncellemelerinde çıkış katmanındaki işlem elemanlarının tamamının hatası dikkate alınmaktadır. Ağırlık değişim miktarları (3.42) eşitliğinde ifade edilmektedir.

$$\Delta W_{kj}^i(t) = \lambda \delta_j^a \zeta_k^i + \alpha \Delta W_{kj}^i(t - 1) \quad (3.42)$$

(3.42)'deki hata miktarı δ_j^a olduğuna göre, bu hatanın denklemi (3.43) eşitliğinde gösterilmektedir.

$$\delta_j^a = f'(NET) \sum_n \delta_n W_{jn}^a \quad (3.43)$$

(3.43)'deki hata miktarı δ_j^a hesaplanmasıyla yeni ağırlık değerleri (3.44) ile hesaplanabilmektedir.

$$W_{kj}^i(t) = W_{kj}^i(t-1) + \Delta W_{kj}^i(t) \quad (3.44)$$

3.5.5 YSA'lar için Öğrenme Algoritmaları

YSA'ların eğitimi için farklı öğrenme algoritmaları mevcuttur. Bu algoritmalar için literatürde en çok tercih edilen geri yayılım (Back Propagation) algoritması ve de bu algoritmanın geliştirilmesiyle ortaya çıkan Levenberg-Marquardt (LM) algoritmasıdır. Diğer öğrenme algoritmaları ise Delta Bar Delta (DBD), Quasi Newton (QN) v.b. algoritmalarıdır [144-146].

Sistemin gerçek zamanlı ölçümlerinde sistemin doğru cevapları vermesi sistemin temel unsurudur. Diğer bir deyişle çene hareketi esnasında ortaya çıkan durumlar, daha önce karşılaşılan durumdan farklı olsa bile özellikleri doğru bir şekilde anlamalıdır. Bu nedenle tez çalışmasında YSA arasında en yaygın olarak kullanılan ileri beslemeli geri yayılım algoritmasına dayalı (multilayer perceptron MLP) kullanılmıştır. Böylelikle diğer yapay zeka algoritmalarına daha fazla değişken parametre seçeneği sunması avantajıyla tercih sebebi olmuştur. Ayrıca hızlı bir şekilde geri yayılım (back propagation) yapılması için ağı eğitimi Levenberg-Marquardt (LM) algoritması kullanılmıştır. LM algoritmasını ağı eğitmede tercih etmemizin en önemli sebebi, bu algoritmanın ikinci dereceden türev gerektirmesiyle öğrenme hızı yüksek bir algoritma olmasıdır. Günümüzde ağ eğitimi etkin olarak tercih edilmektedir [147-151].

LM algoritmasından bahsedecek olur isek, bu algoritmalar ikinci dereceden türev gerektirir ve öğrenme hızını belirgin bir şekilde arttırmaktadır. Bu algortmada hedef fonksiyonun ağırlıklara göre ikinci türeci alınmasıyla Hessian matrisi elde edilmektedir. (3.45)'te Hessian matrisi matematiksel olarak gösterilmiştir.

$$H(n) = J^T(n) J(n) + \mu_m I \quad (3.45)$$

(3.45) eşitliğinde, H Hessian matrisi, μ_m Marquardt parametresi, I ise birim matrisi ifade etmektedir. J parametresi, Jakobian matrisidir. Bu matris değeri ağ hatalarının ağırlıklara göre alınmış birinci türevini ifade etmektedir. Jakobian matrisi (3.46)'da matematiksel olarak gösterilmektedir.

$$J(n) = \frac{\partial e(n)}{\partial W(n-1)} \quad (3.46)$$

Yukarıdaki (3.46) eşitliğinde $e(n)$, ağ hata vektörüdür. W_n ağırlık parametreleridir. Hessian matrisinin türevinin hesaplanmasında (3.47) eşitliği kullanılmaktadır.

$$g(n) = J^T(n) e(n) \quad (3.47)$$

Dolayısıyla ağırlık parametrelerin güncellenmesinde (3.48) nolu eşitlik kullanılmaktadır.

$$W(n+1) = W(n) - [H(n)]^{-1} g(n) \quad (3.48)$$

Dolayısıyla minimum hatanın elde edilmesinde μ_m Marquardt parametresi azaltılır. Böylelikle en uygun ağırlık değerleri elde edilmektedir [143], [152].


3.6 Sınıflandırma Algoritmaları

Bu tez çalışmasında deneklerin alt çene kaslarından edilen sinyaller, YSA'lar kullanılarak etkili biçimde sınıflandırılarak bruksizm tanınması etkin bir biçimde yapılabilmektedir. Ancak bu çalışmada sınıflandırmada farklı sınıflandırıcılar da

kullanılmış ve kullanılan her bir sınıflandırıcının diğer sınıflandırıcılar ile birlikte giriş özelliklerine göre elde ettikleri performansları karşılaştırmalı olarak analiz edilerek belirlenmiştir. Bu tez çalışmasında YSA 'nın dışında kullanılan diğer sınıflandırıcı algoritmalar, karar ağaçları (Decision Tree DT), Lineer Diskriminant (LD), en yakın komşuluk (K-Nearest Neighbour KNN), destek vektör makine (Support Vector Machine SVM) ve Naive Bayes (NB) olmaktadır. Dolayısıyla bu kısımda, bu algoritmaların matematiksel olarak çalışma ilkesi hakkında bilgilendirmelerden bahsedilmektedir.

3.6.1 Karar Ağacı Algoritması

Karar ağacı (Decision Tree DT) algoritması, ağaç yapısı şeklinde sınıflandırma yapabilen, sınıflandırmada kökten başlayıp, karar düğümlerinde ilerleyen ve sonrasında dal ve yapraklarda sonlanan bir sınıflandırıcı algoritmadır. Kökten başlayarak yapraklara ilerlerken karar vermede her veri dizisinin yarısı elenmektedir. Böylelikle sonuca hızlı ulaşılabilmektedir. Düğüm sayısı n tane olduğunda vereceği karar sayısı $\log_2 n$ olmaktadır [153]. Bu algorithmada her bir düğümde verilen karar ile bir sonraki dal yada yaprağa ulaşarak sonuca gidilmektedir. Şekil 3.15'te örnek bir karar ağacı yapısı gösterilmiştir.



Şekil 3.15 Örnek bir karar ağacı yapısı

Ağaç yapısını oluşturmak için kategori bazında karar düğümleri için ID3, sayısal özelliklere ait kararlar için ise C4.5 algoritmaları geliştirilmiştir. Bu algoritmalar, sistemdeki entropi hesabına dayanmaktadır. Bir sistemin entropisi bir T kümesinin olasılıklarının toplamını ifade eden bir $H(T)$ fonksiyondur. (3.49) eşitliğinde matematiksel olarak ifade edilmiştir [154-155].

$$H(T) = - \sum_{i=1}^n p_i \cdot \log_2 p_i \quad (3.49)$$

(3.49)'de T, sınıf özelliğini temsil etmektedir. Bu özellik için entropi $H(T)$ hesaplanabilmektedir. Karar ağaç yapısı için entropi hesaplanırken mutlaka herbir özelliğin ait olduğu sınıfın ağırlıklı ortalamalarının dikkate alınarak (3.50)'deki gibi hesaplanması gerekmektedir. Dolayısıyla ve entropi arasındaki fark bilgi kazancı olarak adlandırılmaktadır. Bilgi kazancı (3.51)'de gösterilmektedir.

$$H(X, T) = - \sum_{i=1}^n \frac{|T_i|}{|T|} H(T_i) \quad (3.50)$$

$$\text{Bilgi Kazancı}(X, T) = H(T) - H(X, T) \quad (3.51)$$

(3.50) eşitliğinde T sınıfına ait her X özelliğinin ağırlıklı ortalamalı entropisidir. $H(T_i)$ ise, T sınıfının i değerindeki entropi değeridir. Her bir özellik için bilgi kazancı, (3.51)'de gösterilen matematiksel denklem ile hesaplanmaktadır. Bu işlemde bilgi kazancı hesaplanırken her bir özellik için yapılmaktadır. Böylelikle bilgi kazancı en yüksek olan özellik belirlenerek ağaç yapısının kökünü oluşturmaktadır. Bu işlem, karar ağaç yapısını oluştururken diğer dal ve düğümler için kalan özellikler kullanılarak sürekli tekrarlanarak devam eder. Aynı şekilde en yüksek kazancı veren özellik iç düğüm olarak belirlenerek alt düğüm ve yapraklara ulaşıncaya kadar devam etmektedir. Böylelikle karar ağaç (DT) yapısı elde edilir [154].

3.6.2 Lineer Diskriminant Algoritması


Lineer Diskriminant (Linear Discriminant LD), problemleri çözmedeki başarısı yüksek, basit ve kullanışlı bir algoritmadır. Bu algoritma yeni bir değişken oluşturarak özelliklerin doğrusal bir kombinasyonunu sağlar. İki hedef sınıfının birbirlerine olan ayırım mesafesi hesaplanarak doğrusal kombinasyonlarıyla tahmin esasına dayanmaktadır. Ayırım mesafesi Mahalanobis mesafesi olarak (3.52) eşitliği kullanılarak hesaplanabilmektedir [155], [156].

$$\Delta^2 = \beta^T (\mu_1 - \mu_2) \quad (3.52)$$

(3.52) eşitliğinde Δ , Mahalanobis mesafesi tanımlamaktadır. μ_1 ve μ_2 ortalama vektörler, β ise katsayı vektörünü ifade etmektedir.

3.6.3 Destek Vektör Makine Algoritması

Destek Vektör Makinesi (Support Vector Machine SVM), iki farklı sınıfa ait kümelenmiş örneklerin birbirinden ayırabilecek en uygun fonksiyonu hesaplayarak sınıflandırabilen bir sınıflandırma algoritmadır. Bu işlemi yaparken sınıflara ait örnekler +1 ve -1 değerleri arasında etiketlenir. Bu örneklerden birbirlerine en yakın olan veri noktaları, sınıflar arasındaki hiperdüzlemi belirlemek amacıyla sınır bölgesi belirlemek için kullanılmaktadır. Bu veri noktaları destek vektörleri olarak isimlendirilmektedir. Bu hiperdüzlem sınırı içerisinde, sınır genişliğini maksimum yapan fonksiyon belirlenmektedir. Böylelikle veri iki sınıf halinde kümelenmektedir. [157], [158]. Ayrıca sınır genişliğini maksimum yapan bu fonksiyon lineer olabileceği gibi doğrusal olmayan kümelenmelerde bile iki sınıf ayırıcısı olarak kullanılabilmektedir [153], [154]. Bu nedenle doğrusal olmayan sınıflandırmalarda sınıflandırmadaki başarı performansı yüksek bir algoritma olması sebebiyle birçok makine öğrenme uygulamalarında kullanılmaktadır [159]. Şekil 3.16'da örnek bir destek vektör makinesinin sınıflandırma grafiği verilmiştir. Bu grafikteki H_0 hiper düzlem sınıflandırma fonksiyonu olarak aralığı maksimum yapan fonksiyondur.



Şekil 3.16 Örnek bir destek vektör makine sınıflandırma grafiği

Yukarıdaki şekilde gösterilen örnek sınıflandırmada, sınıfları ayıran ve aralığı maksimum yapan H_0 hiper düzlem fonksiyonunun matematiksel ifadesi (3.53) eşitliğinde gösterilmektedir [154].

$$H_0 = \sum_{i=1}^n W_i \cdot X_i + b = 0 \quad (3.53)$$

(3.53) nolu eşitlikte n adet özellik için, W ağırlık vektörünü ifade etmektedir. Şekil 3.17’de gösterilen iki ayrı sınıfa ait örnekler arasında maksimum aralık mesafeleri, H_1 ve H_2 hiper düzlemleri olmaktadır. Bu düzlemlere ait matematiksel gösterimler sırasıyla (3.54) ve (3.55) eşitliklerinde gösterilmektedir.

$$H_1 = W^T \cdot X + b = +1 \quad (3.54)$$

$$H_2 = W^T \cdot X + b = -1 \quad (3.55)$$

H1 ve H2 hiper düzlemleri üzerindeki örnekler destek vektörler olmaktadır. Bu iki vektör arasındaki d mesafesi (3.56) eşitliğinde matematiksel olarak ifade edilmektedir.

$$d = \frac{|W^T \cdot X + b|}{\|W\|} \quad (3.56)$$

H1 ve H2 hiper düzlemleri arasındaki mesafenin maksimum olabilmesi için w vektörünün minimum değeri alması gerekir [158].

3.6.4 Naive Bayes Algoritması

Naive Bayes (NB), istatistiksel teknikleri kullanan bir olasılık sınıflandırıcısıdır. Belirli bir örneğin belirli bir sınıfa ait olma olasılığından yola çıkarak bir verinin hangi sınıfa ait olduğunu tahmin edebilmektedir. Literatürde yapılan çalışmalarda NB algoritmasının büyük veri setlerin kullanılmasıyla karar ağaçları ve sinir ağlarına kıyasla yüksek doğruluk performansları elde edilmektedir [160], [161]. Thomas Bayes'in bulduğu bu algorithmada koşullu olasılık kuramına göre bir X örneğinin C sınıfına ait olma olasılığı $P(C|X)$ şeklinde (3.57)'deki gibi ifade edilmektedir [153], [154].

$$P(C|X) = \frac{P(X|C) \cdot P(C)}{P(X)} \quad (3.57)$$

NB sınıflandırıcı kullanılmasında her örneğe ait X değerinin birbirinden bağımsız olduğunu varsayarak koşullu olasılık hesaplamalarında (3.58) eşitlik kullanılmaktadır.

$$P(C|X) = \prod_{k=1}^n P(X_k|C) \cdot P(C) \quad (3.58)$$

Böylelikle (3.58) eşitliği kullanılarak her bir örneğin koşullu olasılık hesaplamalarında, en yüksek olasılık değerini veren örnek için, hesaplanan sınıfa ait olduğu ait olmaktadır. Dolayısıyla tahmin bu şekilde yapılmaktadır [154].


NB sınıflandırıcı, ses tanıma, kelime tanıma, şifre kontrolü ve hastalık teşhisi gibi birçok alanda kullanılmaktadır. Hızlı ve kolay uygulanabilmesi, üstün bir performansa sahip olmasıyla özellikle büyük veri setlerinde yüksek bir sınıflandırma başarısı elde etmesi bu algoritmanın avantajlarından. Her bir özellik için eşit değerler verilmesi, dinamik sistemlerde eğitimin defalarca yapılması bu algoritmanın başlıca dezavantajları olarak kabul edilmektedir [162].

3.6.5 En Yakın Komşuluk Algoritması

En yakın Komşuluk (KNN) algoritması, hedef düğümler arasındaki mesafeyi kullanarak daha önceden sınıflandırılmış olan eğitim verisindeki en yakın komşusu ya da komşularının oluşturduğu sınıfa atanarak sınıflandırma yapabilen bir algoritmadır. Uzaklılara göre değerlendirilen komşu sayısı K ile gösterilir. Komşuluk mesafeleri Öklid uzaklık denklemi kullanılarak hesaplanabilmektedir [154], [159]. Dolayısıyla sınıflandırılacak X_i verisi ile mesafesi hesaplanacak en yakın N_i arasındaki Öklid uzaklığı $D(X,N)$, n adet özellik için (3.59) eşitliğinde gösterilmektedir.

$$D(X, N) = \sqrt{\sum_{i=1}^n (N_i - X_i)^2} \quad (3.59)$$

Bu algoritmada başlangıç düğümünden diğer düğümlere (3.59) eşitliği kullanılarak hesaplanan tüm Öklid mesafeleri karşılaştırılarak, en küçük mesafeye sahip düğüm, hedef düğüm olarak seçilir. Diğer bir deyişle en küçük mesafeye sahip en yakın K komşunun çoğunluğu hangi sınıfa ait ise, X örneği bu komşuların sınıfına atanarak sınıflandırma tahmini yapılabilmektedir [154], [159], [163]. Bu algoritmaya ait çalışma diyagramı Şekil 3.17'de gösterilmektedir.



Şekil 3.17 KNN algoritması çalışma akış diyagramı

3.7 Sınıflandırmada Performans Kriterleri

Deneklerden alınan EMG ve MEMS sinyalleri ile ilgili olarak sinyallerin genlik ve frekans spektrumlarından elde edilen parametreler ile aynı sinyallerin ayrıca AR katsayılarını içeren parametreler giriş özellikleri olarak bruksizm teşhisi için alt çene aktivitelerini ayırt etmek için bu tez çalışmalarında kullanılmıştır. Çıkış özelliği olarak, çene kasları gevşek oluşu, çene kapalı (diş sıkma), kas yorgunluk/ağrı durumu ve ritmik diş gıcırdatma hareketleri olmak üzere toplamda 4 farklı çıkış durumu sınıflandırılmıştır. Sınıflandırma bu aktiviteleri ayırt etmede bu tez çalışmasında KNN, SVM, LD, DT, NB ve de YSA'lar kullanılmıştır. Ancak sınıflandırmadaki başarı ölçütünün performansının belirlenmesinde farklı ölçüt parametreleri, tablo ve grafikler kullanılarak yapılmaktadır. Bu bölümde sınıflandırmadaki performansın belirlenmesinden kullanılan bu parametreler, tablo ve grafiklerden bahsedilmektedir.

3.7.1 Karmaşıklık Matrisi

Kullanılan sınıflandırıcılar için karmaşıklık matrisi (Confusion Matrix) tabloları sınıflandırıcıların doğruluk performansları için önemli bilgileri içermektedir. Bu tabloda doğru ve yanlış sınıfa ait örnek sayıları gözönüne alınarak sınıflandırmada kullanılan algoritmanın başarısının değerlendirilmesi yapılmaktadır. Bu tablodan yola çıkarak doğruluk, kesinlik, duyarlılık ve hata oranları ele alınabilmektedir. Karmaşıklık matrisi örnek olarak Tablo 3.4'te gösterilmektedir.

Tablo 3.4 Karmaşıklık matris tablosu

		<i>Hedef Sınıf</i>	
		<i>Sınıf1</i>	<i>Sınıf2</i>
<i>Gerçek sınıf</i>	<i>Sınıf1</i>	DP	YP
	<i>Sınıf2</i>	YN	DN

Tablo 3.4'te DP, doğru pozitif; YP, yanlış pozitif; YN, yanlış negative; DN, doğru negative olarak değerlendirilmektedir. Bu tablodan yola çıkarak sınıflandırma performansı için, (3.60) eşitliğinden doğruluk oranları, (3.61) eşitliğinden kesinlik oranları, (3.62) eşitliğinden duyarlılık ve (3.63) eşitliğinden ise hata oranları elde edilebilmektedir [164], [165].

$$\text{Doğruluk}(\%) = \frac{DP + DN}{DP + DN + YP + YN} \quad (3.60)$$


$$\text{Kesinlik}(\%) = \frac{DP}{DP + YP} \quad (3.61)$$

$$\text{Duyarlılık}(\%) = \frac{DP}{DP + YN} \quad (3.62)$$

$$Hata Oranı(\%) = \frac{YP + YN}{DP + DN + YP + YN} \quad (3.63)$$

3.7.2 ROC Eğrileri

ROC, diğer adıyla alıcı işletim karakteristiği (Receiver Operating Characteristic) eğrileri anlamına gelmektedir. Bu eğrilerde düşey eksen, doğru pozitif (DP), yatay eksen ise yanlış pozitif (FP) oranlarının yer aldığı eksenlerdir. Genellikle hasta bireylerin hasta olmayan bireylerden doğru bir şekilde sınıflandırılıp sınıflandırılmadığı hakkında önemli bilgiler sağlamaktadır. Diğer bir deyişle DP değeri maksimum ve de YP değeri minimum değere yaklaştıkça tanı testleri için mükemmele yaklaşarak sınıflandırma performansı diğer bir deyişle doğruluk oranları da artmaktadır. En mükemmel sonuçtaki grafik değerleri (0,0) noktasından (0,1) noktasına ve sonrasında (1,1) noktasına geçmektedir. Kısacası mükemmel bir sonuç için eğri sol üst köşeye en yakın geçen eğriye sahip iken, bu eğri köşegene yaklaştıkça başarısız bir sonucu ifade etmektedir [165-167]. Şekil 3.18’de örnek bir ROC eğrisi gösterilmektedir.



Şekil 3.18 Örnek bir ROC eğrisi

3.7.3 Ortalama Karesel Hata ve Doğrusallık ilişkisi


Bir diğer performans kriteri özellikle de bu tez çalışmasında kullanılan YSA yapıları için ortalama karesel hata (Mean Square Error MSE) olmaktadır. MSE ile, çıkış ve hedef değerler arasında ilişkilendirme yapılarak kullanılan YSA'ların performansı değerlendirilebilmektedir. (3.64)'te $k=1, 2, 3 \dots N$ 'e kadar sayıda oluşan durumlara bağlı olarak çıkış C_k ve hedef değerler H_k arasındaki matematiksel ilişki, diğer bir deyişle MSE'nin matematiksel ifadesi gösterilmektedir. Dolayısıyla çıkış hedef arasındaki farkın küçük olması, kullanılan ağın performansının iyi olduğu anlamına gelmesi demektir.

$$MSE = \frac{1}{N} \sum_{k=1}^N (H_k - C_k)^2 \quad (3.64)$$

YSA yapılarında girdi katmanından gelen verilerin çıktı katmanında bir sonuç üretmesiyle istenen sonuç ile karşılaştırılarak geriye doğru yayılımı ile MSE parametresinin minimize edilmesi için ağırlıkların güncellenmesi sağlanmaktadır. Ancak bazen ağ öğrenme yerine ezberleme yapabilmektedir. Bunun için ağ doğru bir şekilde eğitmek gerekir. Veri kümesi eğitim, doğrulama ve test olmak üzere üç gruba ayrılmaktadır. Oluşturulan ağın performansı açısından eğitim setindeki MSE, bias ve ağırlıklar önemlidir. Bunun için giriş verilerinin anlamlı, ilişkili olması diğer bir deyişle regresyon katsayıların yüksek olması sağlanmalıdır. Validasyon setinde iyileştirme durduğunda eğitim işlemi sonlandırılmaktadır. Test seti ise ağın performansını değerlendirmek içindir. Dolayısıyla test sonuçlarında MSE'nin yorumlanması ağın başarı performansı açısından önemlidir. Burada performans kriteri olarak MSE'nin mümkün olduğunca sıfıra yakın olması ve de doğrusallık ilişkisi bakımından regresyonun (R) 1'e yakın olması (eğim yaklaşık 45°), başarılı bir ağ yapısını değerlendirmede önemli bir kriterdir [119], [144], [149], [150], [168]. Bu ağ yapısı bir kez oluşturulduktan sonra sonradan farklı zamanlarda ve kişilerden alınan bir veriyi kolaylıkla hızlı bir şekilde ayrıştırılabilmektedir. Bu sayede deneklerden gelen verilerin bruksizm rahatsızlığı durumları etkinliği yüksek, hızlı bir şekilde teşhis edilebilmektedir.

3.8 Genişletilmiş Kalman (EKF) Filtre Yaklaşımı

Kalman filtresi ilk olarak Rudolf Kalman tarafından ortaya atılmış bir modeldir. Bu model uzay araçlarında belirlenen hedefe ulaşma, robotik kontrol sistemlerinde, biyomedikal sinyal işleme sistemlerinde kullanılmaktadır [78]. Kalman filtresi doğrusal sistemler için uygun bir filtredir. Ancak Lineer olmayan sistemlerde kullanılabilmektedir. Sonradan gürültülerin etkin bir şekilde ortadan kaldırması için genişletilmiş Kalman filtresi (EKF) geliştirilmiştir [169]. Dolayısıyla bu tez çalışmasında deneklerin alt çeneye bağlı (Masseter+Temporal) kaslardan alınan EMG ve MEMS akselerometre tabanlı MMG sinyallerinin lineer olmamasından dolayı bu yaklaşım modeli kullanılmıştır. EKF yaklaşımında her bir zaman adımında alınan lineer olmayan sinyaller, lineer hale dönüştürülmektedir [170]. Bu çalışmada kullanılan EKF sistemine ait model, Şekil 3.19'da gösterilmektedir.



Şekil 3.19 Çalışmada kullanılan EKF modeli

Bu modelde her bir k anında ayrık hale getirilmiş doğrusal olmayan bir sinyalin denklemi ile ölçüm denklemi aşağıdaki gibi (3.65) ve (3.66) nolu eşitliklerde gösterilmektedir.

$$X_k = AX_{k-1} + w_k \quad (3.65)$$

$$Z_k = HX_k + v_k \quad (3.66)$$

(3.65) ve (3.66) nolu eşitliklerde X_k değeri ve Z_k değerleri, X sinyalinin k anındaki değeri olmaktadır. Z_k değeri ise X sinyalinin k anındaki ölçülen değeridir. w_k ve v_k değerleri sırasıyla sinyalin k anındaki işlem gürültüsü ve ölçüm gürültüsü olmaktadır. Bu gürültüler Q_k ve R_k kovaryans matrisleri olarak ifade edilir. Buradan R_k parametresinin bulmak kolaydır ancak Q_k parametresini hesaplamak kolay değildir. Bu parametreden P_k hata kovaryansı hesaplanarak sürekli bir döngü içerisinde kendini bir önceki hata kovaryans değeri P_k^- (3.67) ve k anındaki Kalman kazancı K_k , (3.68)'daki eşitlikte gösterilen matematiksel denklemler kullanılarak güncellenmektedir. Hata kovaryansının güncellenmesi (3.69) nolu eşitlikte gösterilmektedir [76], [171].

$$P_k^- = AP_{k-1}A^T + Q_k \quad (3.67)$$

$$K_k = P_k^- H^T (HP_k^- H^T + R)^{-1} \quad (3.68)$$

$$P_k = (1 - K_k H) P_k^- \quad (3.69)$$

Eşitlik (3.67)'de hata kovaryansının tahminiyle K_k parametresi güncellenir ve ardından yeni hata kovaryans değerleri ve de her bir k anındaki tahmin edilen çıkış sinyal değerleri güncellenmektedir (3.70).

$$\hat{X}_k = \hat{X}_k^- + K_k (Z_k - H\hat{X}_k^-) \quad (3.70)$$

Tüm bu ifade edilen denklemlerdeki A ve H parametreleri durum geçiş matris formlarındadır. A parametresi, (3.71) ve (3.72)'te görüldüğü gibi kontrol edilebilir kanonik formdadır.

$$\hat{X}_k^- = A\hat{X}_{k-1} \quad (3.71)$$

$$A = \frac{\partial F(\hat{X})}{\partial \hat{X}} \Big|_{\hat{X}_{k-1}} \quad (3.72)$$

Bu sistemde başlangıç değerleri $\hat{X}_0$ ve P_0 değerleri (0,0) olarak seçilmiştir. Ancak filtrenin doğru tahmin yapabilmesi için sistemde w_k ve v_k değerlerinin diğer bir deyişle işlem ve ölçüm gürültü parametrelerinin belirlenmesi gerekir. Bu sebeple deneklerin masseter ve temporal kasları kasılma durumlarında EMG ve akselerometre tabanlı MEMS sinyaller sisteme girilerek belirlenmiştir. İdeal şartlar altında kasın kasılı olmadığı durumlarda hiç bir sinyal olmaması gerekmektedir. Ancak sistemde çevresel kaslardan gelen gürültüler, deri teması kaynakları gürültüler, hareket kaynaklı gürültüler, kullanılan devre elemanlarından kaynaklı gürültüler ve de elektromanyetik gürültülerde dahil olmak üzere tüm frekans bölgelerinde bu gürültü sinyallerine rastlanılmaktadır. Matlab yazılımıyla yapılan denemeler neticesinde EMG ve MEMS sinyallerin w_k ve v_k parametreleri bir kez belirlendikten sonra sistemde tanımlanmıştır. Sonraki aşamada masseter ve temporal kasları kasılarak elde edilen gürültülü sinyaller rahatlıkla filtrelenebilmektedir [172].

BRUKSİZM TANILAMASINDA MAKİNE ÖĞRENME ALGORİTMALARIYLA YAPILAN ANALİZ ÇALIŞMALARI

Deneklerin alt çene kaslarından elde edilen EMG ve MEMS akselerometre tabanlı MMG sinyaller ile ilgili olarak Bölüm 3'te açıklanan ön işleme çalışmalarıyla dijital forma dönüştürülerek sinyallere ait genlik, frekans özellikleri, AR katsayıları ve de dalgacık dönüşümleriyle de sinyallere ait entropi özellikleri elde edilmiştir. Bu bölümde ise, elde edilen bu özellikler makine öğrenme algoritmalarıyla işlenerek bruksizm tanılması için yapılan uygulamalardaki analiz çalışmalarından bahsetmektedir.

4.1 EMG Sinyalleri Kullanılarak Yapılan Analiz Çalışmaları


EMG sinyallerinden 13 farklı genlik ve frekans bilgisini içeren (MNF, MDF, LOG, VAR, SSC, MAV, ZC, WAMP, WL, RMS, DASD, AAC ve SD) özelliklerin elde edilmesinde deneklerden elde edilen 160 veri kaydından oluşan toplamda $160 \times 13 = 2080$ veri giriş sınıflandırıcı algoritmalar için giriş verisini oluşturmaktadır. Çıkış olarak dört farklı çıkış değerleri giriş özelliklerine göre sınıflandırılmaktadır. Bu çıkışlar;

- Çene kasları gevşemiş (0),
- Çene kasları kapalı (sıkma) (1),
- Yorgunluk/ağrı (2),
- Ritmik diş gıcırdatma (3), olmaktadır.

İstatistiksel olarak en yüksek korelasyon ilişkilerinin belirlenmesinde bu çalışmada kullanılan zaman ve frekans özellikleri için YSA'lar kullanılmıştır. Bu şekilde seçilen özellikler kullanılarak ağ yapısının performansı test edilmiştir. Böylece çene aktivitelerinin sınıflandırılması ile sınıflandırma sorunları azaltılmaya çalışılmış ve en etkili bruksizm teşhisi yüksek doğrulukla gerçekleştirilmiştir. Oluşturulan YSA yapısı için sistemin gerçek zamanlı ölçümlerde doğru tepkiler

vermesi esastır. Başka bir deyişle, çene hareketi sırasında ortaya çıkan durumlar daha önce karşılaşılan durumlardan farklı olsa da özellikleri doğru ayırt etmelidir. Bu nedenle sınıflandırmada ileri beslemeli geri yayılım algoritmasına dayalı çok katmanlı algılayıcı yapısına dayalı YSA mimarisi kullanılmıştır. Ağın eğitiminde hızlı bir geri yayılımın gerçekleşmesi için Levenberg-Marquardt algoritması kullanılarak eğitilmiştir. YSA'da kullanılan verilerin %70'i eğitim, %15'i doğrulama ve kalan %15'i test için seçilmiştir. Oluşturulan yapının ara katmanı için nöron sayısı 10 olarak belirlenmiştir. Ağı eğitmek için Levenberg-Marquardt algoritmasını tercih etmemizin nedeni, bu algoritmanın ikinci dereceden bir türev gerektirdiğinden öğrenme hızının yüksek olmasıdır [150], [151]. Bu ağ yapılarında, girdi katmanından gelen veriler çıktı katmanında bir sonuç ürettiğinde, istenen sonuçla karşılaştırılır ve ortalama karesel hatayı (MSE) en aza indirmek için ağırlıklar geri yayılım yoluyla güncellenir. Ağın performans kriteri olarak R katsayıları ve MSE değerleri elde edilmiştir. Sınıflandırmadaki bruksizm tanılamaındaki performansın değerlendirilmesinde ise ROC eğrileri ve Karmaşıklık Matris tabloları kullanılmıştır. Ayrıca YSA'nın dışında diğer 5 farklı makine öğrenme algoritmaları (KNN, DT, NB, SVM ve LD) kullanılarak bruksizm tanılamaı için sınıflandırmada kullanılmıştır. Her bir sınıflandırıcı, Çapraz validasyon (k-fold:10) yapılarak sınıflandırmadaki performansları incelenmiştir.

EMG sinyalleriyle ilgili olarak yapılan diğer bir uygulama çalışması ise, aynı deneklerden alınan örnek sinyaller kullanılarak elde edilen 12 düzenli AR katsayıları ve de aynı sinyallerin dalgacık dönüşümleri ile elde edilen Shannon entropi özellikleri ile yapılan bruksizm tanılama çalışmaları olmaktadır. Çıkış özellikleri olarak yukarıda bahsedilen toplamda 4 farklı çıkış özelliği olmaktadır. Sistemin gerçek zamanlı ölçümlerde doğru tepkiler vermesi esastır. Başka bir deyişle, çene hareketi sırasında ortaya çıkan durumlar daha önce karşılaşılan durumlardan farklı olsa da özellikleri doğru ayırt etmelidir. Bu nedenle sınıflandırmada en yaygın kullanılan yapayzeka algoritması olan ileri beslemeli geri yayılım algoritmasına dayalı çok katmanlı YSA yapıları kullanılmıştır. Şekil 4.1'de YSA, AR katsayıları ve dalgacık entropisine dayalı bruksizm tanılama modeli gösterilmektedir.



Şekil 4.1 YSA, AR katsayıları ve dalgacık entropisine dayalı uygulama

Bu yapılan çalışmada özellikle YSA' nın tercih edilmesinin nedeni ise diğer yapayzeka algoritmalarına göre daha fazla sayıda değişken parametre sunma avantajına sahip olmasıdır. Dolayısıyla YSA kullanımında hızlı bir geri yayılım gerçekleştirmek için Levenberg-Marquardt geri yayılımı algoritması kullanılarak oluşturulan ağ yapıları eğitilmiştir. Aktivasyon fonksiyonu olarak sigmoid fonksiyonu bu çalışmada tercih edilmiştir.

Bu ağ yapılarında, girdi katmanından gelen veriler çıktı katmanında bir sonuç üretir ve ağırlıklar, istenen sonuçla karşılaştırılarak geri yayılım yoluyla ortalama ortalama kare hatasını (MSE) en aza indirecek şekilde güncellenmektedir. Ancak, MSE'yi en aza indirecek etkili bir yöntemin olmaması bu ağ yapısı için büyük bir dezavantajdır. Bu nedenle girdi verilerinin ağırlıklarının belirlenmesinde MATLAB yazılımı ile gizli katmandaki farklı nöron sayıları ve de farklı eğitim, validasyon ve test veri oranları ile birlikte kullanılmıştır. En yüksek regresyon katsayıların diğer bir deyişle sınıflandırmada kullanılacak en yüksek performans değerleri için sırasıyla 12 düzenli AR(12) katsayıları, dalgacık Shannon entropi özellikleri (WShEn) ve de her iki durum için giriş özellikleri olarak ağ yapılarında kullanılmıştır. Elde edilen sonuçlar sırasıyla Tablo 4.1, Tablo 4.2 ve Tablo 4.3'te gösterilmektedir. Tablolardan da görüldüğü ara katman nöron sayısı 10 olarak

seçildiğinde R katsayıları yüksek değerlerde olmaktadır. Bu sebeple oluşturulacak ara katman nöron sayısı 10 olarak belirlenmiştir.

Tablo 4.1 AR(12) giriş özellikleriyle oluşturulmuş YSA performansları

<i>Ara Katman Nöron Sayısı</i>	<i>Veriseti Oranları (%)</i>	<i>Regresyon Katsayısı (R)</i>
6	%70 ¹ %15 ² %15 ³	0,97 ¹ 0,97 ² 0,95 ³
10	%70 ¹ %15 ² %15 ³	0,99 ¹ 0,96 ² 0,95 ³
6	%60 ¹ %30 ² %10 ³	0,93 ¹ 0,91 ² 0,90 ³
10	%60 ¹ %30 ² %10 ³	0,98 ¹ 0,94 ² 0,97 ³
6	%50 ¹ %15 ² %35 ³	0,95 ¹ 0,90 ² 0,94 ³
10	%50 ¹ %15 ² %35 ³	0,96 ¹ 0,92 ² 0,95 ³

1/Eğitim Veriseti; 2/Validasyon Veriseti; 3/Test Veriseti

Tablo 4.2 Dalgacık entropisi giriş özellikleriyle oluşturulmuş YSA performansları

<i>Ara Katman Nöron Sayısı</i>	<i>Veriseti Oranları (%)</i>	<i>Regresyon Katsayısı (R)</i>
6	%70 ¹ %15 ² %15 ³	0,96 ¹ 0,92 ² 0,92 ³
10	%70 ¹ %15 ² %15 ³	0,98 ¹ 0,95 ² 0,85 ³
6	%60 ¹ %30 ² %10 ³	0,92 ¹ 0,86 ² 0,90 ³
10	%60 ¹ %30 ² %10 ³	0,96 ¹ 0,86 ² 0,91 ³
6	%50 ¹ %15 ² %35 ³	0,96 ¹ 0,90 ² 0,81 ³
10	%50 ¹ %15 ² %35 ³	0,97 ¹ 0,90 ² 0,82 ³


1/Eğitim Veriseti; 2/Validasyon Veriseti; 3/Test Veriseti

Tablo 4.3 Dalgacık entropisi ve AR(12) giriş özelliklerin birlikte kullanılmasıyla oluşturulmuş YSA performansları

<i>Ara Katman Nöron Sayısı</i>	<i>Veriseti Oranları (%)</i>	<i>Regresyon Katsayısı (R)</i>
6	%70 ¹ %15 ² %15 ³	0,97 ¹ 0,93 ² 0,92 ³
10	%70 ¹ %15 ² %15 ³	0,99 ¹ 0,95 ² 0,96 ³
6	%60 ¹ %30 ² %10 ³	0,97 ¹ 0,95 ² 0,96 ³
10	%60 ¹ %30 ² %10 ³	0,99 ¹ 0,97 ² 0,98 ³
6	%50 ¹ %15 ² %35 ³	0,96 ¹ 0,94 ² 0,91 ³
10	%50 ¹ %15 ² %35 ³	0,99 ¹ 0,95 ² 0,93 ³

1/ Eğitim Veriseti; 2/ Validasyon Veriseti; 3/ Test Veriseti


Dolayısıyla bu uygulama çalışmasında, ara katman sayısının 10 olarak belirlenmesiyle birlikte Şekil 4.2’de görüldüğü gibi giriş AR(12) ve dalgacık entropi özelliklerine göre, çıkış özellikleri olarak parafonksiyonel diş gıcırdatma, çene sıkma ve Bruksizm sırasında ortaya çıkan ağrı ve yorgunluk durumlarına göre iki farklı YSA yapısı oluşturulmaktadır.



Şekil 4.2 Giriş özelliklerine göre oluşturulmuş YSA mimari yapıları

4.2 MMG Sinyalleri Kullanılarak Yapılan Analiz Çalışmaları

Bu çalışmada sinyal analizlerinde deneklerden alınan 1sn periyodunda toplamda 100 adet MEMS akselerometre tabanlı MMG sinyallerinden 12 farklı genlik ve frekans özellikleri (MNF, MDF, LOG, MAV, RMS, MFL, WL, ZC, WAMP, AAC, VAR ve DASD) elde edilerek toplamda 1200 adet veri kullanılmıştır. Çıkış özellikleri olarak 3 farklı sınıf mevcuttur. Bu çıkış özellikleri alt çene kaslarının gevşek oluşu (1), çene kaslarının diş sıkma pozisyonunda kenetlenmesi (2) ve de ritmik diş gıcırdatma eylemi (3) olmaktadır. Şekil 4.3’de yapılan uygulamanın tüm aşamaları gösterilmektedir. Bu çalışmada 12 farklı özellik içerisinde istatistiksel analiz sonucu Tablo 3.2’de gösterilen en etkili 5 özellik MNF, MDF, MFL, ZC ve DASD kullanılarak MEMS tabanlı sistem için bruksizm tanılmasında giriş özellikleri olarak bu uygulamada kullanılmıştır.



Şekil 4.3 MEMS tabanlı sistemin uygulamasına ait blok şeması

Bu çalışmada KNN, SVM, LD, QD, DT ve NB algoritmaları çapraz validasyon oranları (k-fold:10) olarak eğitilmektedir. Çene kası eylemlerinin belirlenmesinde bu algoritmaların performansları sorgulanabilmekte, ayrıca aynı veriler kullanılarak veri setindeki verilerin %70’i eğitim, %15’i validasyon ve %15’i test verisi olarak seçilerek YSA yapısı oluşturulmuş ve de Levenberg-Marquardt

algoritmasıyla da oluşturulan ağ yapısı eğitilmiştir. Böylelikle bruksizmin teşhisi için bahsedilen bu farklı makine öğrenme algoritmaları ile etkin bir biçimde belirlenebilmektedir.

Kullanılan bu sınıflandırıcı algoritmaların sınıflandırmadaki doğruluk performansları için karmaşıklık matrisi tabloları bu çalışmada kullanılmaktadır. Ayrıca sınıflandırma performansının belirlenmesinde bu çalışmada önerilen sınıflandırıcı için ROC eğrileri kullanılmıştır.

4.3 EKF Filtreleme Modeliyle Adaptif Bir Yöntem Geliştirilmesi

Günümüzde kaslarda ortaya çıkan yorgunluk, kas zayıflığı, ağrı, titreme v.b. kas aktivitelerinin fiziksel durumların klinik olarak teşhisinde, rehabilitasyon alanlarında kullanılan harici veya giyilebilir robotik dış iskelet sistemlerinde EMG ve de MEMS tabanlı sinyaller kullanılabilmektedir. Deri üstünden invazif olmayan işlemlerle alınan bu işaretlerin kaydı sırasında deriye yapıştırılan elektrotların tam olarak temas etmemesi, istemsiz vücut hareketleri ve de çevresel kaslardan gelen gürültüler de eklendiğinde anlamlı sinyallerin bütünlüğü bozulabilmektedir. Ayrıca çevresel etkenlere bağlı olarak kişilerin yaş ve cilt durumları dikkate alındığında alınan sinyallerin bütünlüğünü bozabilmektedir. Tüm bu olumsuz etkenler göz önüne alınarak bu çalışmada, harici bir donanımsal analog filtre kullanmadan hem MEMS hem de EMG sinyallerin anlamlı frekans bileşenlerini ortaya koyan istenmeyen bileşenleri kendiliğinden ortadan kaldıran EKF tabanlı bir filtreleme yöntemi önerilmektedir. EMG tabanlı ve de MEMS tabanlı anlamlı sinyallerin anlamlı frekans aralıkları MEMS sinyaller için 5 ile 100 Hz aralığında [67], EMG sinyaller için 10 ile 500 Hz aralığındadır [75]. Dolayısıyla anlamlı frekans haricindeki istemsiz vücut hareket kaynaklı gürültüler, deri temasına bağlı empedans değişimlerinden dolayı oluşan gürültüler ve de elektromanyetik kaynaklı yüksek frekans gürültüleri önemli ölçüde kendiliğinden ortadan kaldırılabilir. Bunun için filtreleme de kullanılan işlem gürültüsü (Process Noise PN) ve Ölçüm Gürültüsü (Measurement Noise MN) parametreleri ortam koşullarına bağlı olarak kendiliğinden belirlenebilmektedir. Bu sebeple özel bir kalibrasyon metodu geliştirilmiştir. Bunun için EMG veya MEMS tabanlı

sinyallerin en etkin zaman ve frekans özellikleri regresyon analizi ile belirlenerek, MSE parametreleri her bir özellik için hesaplanmıştır. Ayrıca DT, SVM, NB, LD ve KNN algoritmalarıyla da sınıflandırılarak önerilen yöntemin performansı test edilmiştir. Önerilen bu yöntem ayrıca tüm iskelet kasları için uygun olmakla beraber, çalışmayı test etmede alt çenenin (mandibula) ve başın sürekli hareket halinde olmasından dolayı EMG sinyalleri masseter, MEMS sinyalleri ise temporal kaslarından elde edilerek etkin bir biçimde filtrelenebilmektedir. Dolayısıyla bu yöntem alt ve üst ekstremitte her türlü iskelet kaslarında oluşan EMG ve MEMS tabanlı sinyallerin etkin bir biçimde filtrelenmesinde adaptif bir yöntemdir. Ayrıca filtreleme için ilave donanımsal yapılara gereksinim duyulmamasından dolayı sistem boyutları minimum yer kaplaması ve de maliyetleri bakımından da ekonomik olmasıyla da kullanışlı olmaktadır.

Çalışmada ADXL335 MEMS accelerometer sensörün “z” eksenini kullanılmaktadır. Ayrıca bu çalışmada kullanılan EMG sensör propları AgCl bipolar elektrotlardır. Bu elektrotlardan alınan sinyaller ayarlanabilir kazançlı AD624 (kazanç:1000, CMMR>80dB) enstrümantasyon yükselteci ile yükseltilmiştir. Yükseltilen EMG sinyalleriyle birlikte MEMS sinyalleri saniyede 4500 örnek olacak şekilde (örnekleme frekansı fs: 4500Hz) sayılaştırılarak data kayıtları her bir denek için yapılmaktadır. Çalışmada bu sinyallerin sayısallaştırılmasında 32bit Atmel SAM3X8E ARM Cortex-M3 12bit A/D çeviricili işlemci kullanılmasıyla (Baud Rate: 250000bps) haberleşme hızında PC ortamına aktarılarak bu yaklaşımın analiz ve testlerinde Matlab R2019b yazılımı kullanılmaktadır. Ayrıca geliştirilen bu metodun geleneksel olarak günümüzde literatürde kullanılan analog filtreleme metoduyla performansının karşılaştırılabilmesi için kaslardan alınan EMG sinyalleri için anlamlı frekans aralığı 10-500 Hz gözönünde bulundurularak 2.ci derece Butterworth filtresi, MMG sinyalleri için istemsiz vücut hareketlerine karşı duyarlı olmasından dolayı anlamlı frekans aralığının 5-100 Hz olduğu gözönünde alınmasıyla 4.cü dereceden Butterworth filtresi kullanılmıştır.


Filtrelemede uygulama analizlerine geçmeden önce her bir deneğin alt çene kaslarından alınan sinyalin kalibrasyonu yapılmıştır. Her bireye ağız içi aparey her bir denek için MVC değerlerini belirlemek için deneklerden 3 saniye boyunca çenelerini maksimum düzeyde sıkmaları istenmiştir. Böylelikle denekler çenelerini

sıktılarında oluşan RMS değerleri belirlenmiştir. Sonraki aşamada farklı zamanlarda %10 MVC seviyelerinde çene kapama hareketleri tekrarlanmıştır. Bu tekrarlamalar 3sn aralıklar ile çene kapama (kasılma) ve açma (gevşeme) şeklinde gerçekleşerek tüm bu sinyaller PC ortamında kaydedilmiştir. Bu hareketlerde oluşan genlik değerleri %10 MVC olacak şekilde data kayıtları alınabilmektedir. MVC seviyelerinin belirlenmesinde sinyalin RMS değerleri kullanılmaktadır [16], [66], [104].


Diğer aşama sistemin kalibrasyonudur. EMG veya MEMS sensörlerin kullanılmasıyla her bir denekten %10 MVC değerinde alınan sinyallerin filtreleme öncesinde dış etmenlerden, çevresel kaslardan, kişilerin cilt dokusuna bağlı olarak sensörün yüzey teması ve de kişilerin istemsiz vücut hareket kaynaklı gürültüler gözönüne alınarak sistem adaptif olarak kendi içindeki parametrelerini ayarlayabilmesidir. Bu işlem için EKF ile filtreleme öncesinde PN ve MN parametreleri kendiliğinden en etkin şekilde belirlenmesini sağlayan adaptif bir yöntem önerilmektedir. Bu yöntemle göre her bir denekten alınan sinyallerin öncelikle MSE değerleri (4.1) eşitliğine göre belirlenmektedir.

$$MSE = \frac{1}{N} \sum_{k=1}^N (R_k - \hat{X}_k)^2 \quad (4.1)$$

(4.1)'de 1'den N'e kadar her bir k noktasındaki sinyal değerlerin farkının karesel toplamı göstermektedir. Bu denklemdeki R_k değeri referans sinyalin k noktasındaki değeri, $\hat{X}_k$ değeri ise EKF ile tahmin edilen sinyalin k noktasındaki değeri anlamına gelmektedir. Referans sinyal deneklerden alınmış harici bir analog band geçiren filtre yapıları kullanılarak elde edilmiş olmasını arzu ettiğimiz sinyali temsil etmektedir. Sistem MSE parametresinin minimum değerini elde edene kadar EKF'ye ait PN ve MN parametrelerini arttırıp veya azaltarak ayarlayabilmektedir. Değişim oranları PN, MN ve MSE ilişkisine bağlı olarak değişmektedir. Şekil 4.4 ve Şekil 4.5'te bu değişimler sırasıyla grafikler halinde gösterilmektedir.




Şekil 4.4 PN sabit tutulmasıyla MN değişikliklerinin MSE ile ilişkisi



Şekil 4.5 MN sabit tutulmasıyla PN değişikliklerinin MSE ile ilişkisi

MN ve PN parametreleri, EKF'nin adaptif yapıya kavuşması için MSE parametresinin minimum olduğu duruma göre sistem tarafından güncellenmektedir. Güncellenen bu değerler 3.cü bölümde anlatıldığı gibi Q_k ve R_k kovaryans matrisleri olarak ifade edilmektedir. Buradan R_k parametresinin bulmak kolaydır ancak Q_k parametresini hesaplamak kolay değildir. Bu

parametreden P_k hata kovaryansı hesaplanarak sürekli bir döngü içerisinde kendini bir önceki hata kovaryans değeri P_k^- (3.68) ve de k anındaki Kalman Gain K_k parametresi (3.69)'daki denkleme göre güncellenmektedir. Hata Kovaryansının güncellenmesi (3.70)'teki denklemden ifade edilmektedir [76], [171], [172]. Bu çalışmada EKF'yi kullanarak geliştirilen yöntemin block diagramı Şekil 4.6'da gösterilmektedir.



Şekil 4.6 Geliştirilen adaptif EKF modeli

Filtrenin performansının incelenmesinde Tablo 4.4'te görüldüğü gibi deneklerden alınan sinyallerden toplamda 13 farklı genlik ve frekans özellik parametreleri elde edilmiştir. Bu parametrelerin istatikel olarak regresyon analizi yapılarak Performans değerlendirmelerinde kullanılmak üzere çıkışa olan korelasyon ilişkisi belirlenmektedir. Çıkış olarak deneklerin çene kaslarındaki kasılma eylemleri esnasında elde edilen ham sinyaller 0, filtreleme sonrası elde edilen filtrelenmiş sinyaller 1 olarak belirlenerek bu iki durumu birbirlerinden ayırt edilebilmesinde hem ham, hemde filtrelendikten sonraki hesaplanmış özneliliklerin regresyon (R) ve anlamlılık (pearson değeri-P) değerleri Tablo 4.4'de gösterildiği gibidir. Bu

tablodan da görüldüğü gibi performansın ölçülmesiyle ilgili analizlerde en yüksek korelasyona sahip 6 özellik belirlenmiştir. Bu özellikler filtrenin performans analizlerinde MNF, ZC, WL, SSC, AAC ve DASD kullanılmıştır.

Tablo 4.4 Filtre performas analizlerinde kullanılan özellikler

	EMG Sinyalleri		MMG Sinyalleri	
	R katsayısı	P-değeri	R katsayısı	P-değeri
<i>MNF</i>	0,6132424	6,99085E-05	0,53710079	0,004665356
<i>MDF</i>	0,15029763	0,381603697	0,04469213	0,828374876
<i>MAV</i>	0,03513149	0,838812647	0,04786483	0,816387991
<i>RMS</i>	0,03488389	0,839933941	0,05888759	0,775070116
<i>ZC</i>	0,62563365	4,49751E-05	0,66687357	0,000198827
<i>WAMP</i>	0,13802858	0,422091874	0,33209995	0,097412567
<i>WL</i>	0,17677156	0,302377585	0,86994485	7,83561E-09
<i>SSC</i>	0,74396588	1,9925E-07	0,89064768	1,09298E-09
<i>LOGD</i>	0,10390503	0,546465969	0,040683	0,843575234
<i>VAR</i>	0,0369239	0,830704959	0,09724191	0,636516305
<i>SD</i>	0,05265391	0,760377134	0,09485256	0,644863222
<i>AAC</i>	0,15868415	0,35528899	0,95339391	5,45973E-14
<i>DASD</i>	0,16571861	0,334083513	0,96903198	4,3842E-16


İstatiksel olarak belirlenen en etkili MNF, ZC, WL, SSC, AAC ve DASD özellikler, her bir denekten alınan EKF ile filtrelenmiş sinyallerin sınıflandırma için giriş özelliklerini temsil etmektedir. Çıkış özellikleri ise sistemin her bir denek için adaptif olarak belirlediği ölçüm gürültüsü V_k parametreleridir. Bu aşamada proses gürültüsü W_k sabit tutulmaktadır. Analizlerde DT, SVM, NB, LD ve KNN algoritmaları farklı çapraz validasyon (k-fold) değerleri 2, 3, 4, 5 ve 10 olacak şekilde seçilerek incelenmiştir. Sınıflandırma başarılarını incelemeye karmaşıklık matrisi tabloları kullanılmıştır.

YAPILAN ANALİZLERİN SONUÇ VE BULGULARI

Tez çalışmasının bu bölümünde bruksizm rahatsızlığının etkin bir biçimde tanınmasında kullanılan EMG ve MEMS akselerometre sinyallerinden elde edilen özelliklerin makine öğrenme ve sınıflandırma algoritmalarıyla birlikte kullanılmasına dayalı yapılan detaylı analizlerin sonucunda elde edilen bulgular ve de performans sonuçların değerlendirmelerinden bahsetmektedir. Ayrıca EMG ve MEMS tabanlı akserometre sinyallerinin daha da etkin bir biçimde elde edilmesinde EKF'ye dayalı geliştirilen adaptif filtreleme yönteminin de performans analizlerinin sonuçları yine bu bölümde açıklanmaktadır.


5.1 EMG Sinyalleriyle Yapılan Analizlerin Sonuç ve Bulguları

Deneklerin sol ve sağ masseter kaslarından alınan EMG sinyallerine ön sinyal işleme yapılarak zamana bağlı olarak elde edilen grafikler Şekil 5.1'de gösterilmektedir. Bu grafikteki değerler %50 MVC durumunda elde edilmekle birlikte alt çene kaslarının kasılmasında ortalamada 10 kat potansiyel farkın artmasıyla $0.05 \text{ mV} \pm 0.01 \text{ mV}$, gevşeme pozisyonunda ise $0.005 \text{ mV} \pm 0.002 \text{ mV}$ olduğu görülmektedir.




Şekil 5.1 Bruksizm aktivitesi esnasında örnek bir denekten alınmış EMG sinyalleri

Şekil 5.1'deki örnek EMG sinyalleri 1sn'lik süredeki genlik değişimlerini göstermektedir. Ancak bu çalışmada, çene sıkma ve diş gıcırdatmaya ek olarak deneklerin masseter kası ortalama 60 ± 20 s süreyle kasılmış halde tutulmuştur. Bunun nedeni özellikle de uyku sırasında ortaya çıkan bruksizm bozukluğunda bu tür aktivitelerin minimum 8 saniye sürmesidir. Bu nedenle ısırma pozisyonu bu süreler boyunca devam ettiğinde, Şekil 5.2'de gösterildiği gibi alt çene kaslarında ağrı ve yorgunluk oluşana MNF ve MDF frekanslarında bir düşüş gözlenmektedir. Frekans değerlerindeki bu düşüş beklenen bir düşüştür. Çünkü kas yorgunluğu ortaya çıktığında frekans spektrumundaki MNF ve MDF parametreleri azalmaktadır [173], [174].




Şekil 5.2 Kasılma süresince MNF/MDF özelliklerin değişim grafikleri

Ayrıca deneklerin yorgun ve yorgun olmama durumlarından elde edilen MNF ve MDF parametrelerinin dağılımları Şekil 5.3'te gösterilmektedir. Bu şekil incelendiğinde bireylerin kas yorgunluğu durumlarını, yorgun olmayan durumlara göre kıyasladığımızda MNF ve MDF özelliklerinin daha düşük değerler alarak dağılım yaptığı gözlenmektedir.




Şekil 5.3 Alt çenedeki kas yorgunluğu durumlarındaki MNF/MDF dağılımları

Bruksizm tanısı için dört çıkış durumu belirlenmiştir. Bunlar alt çenenin gevşemesi için 0, çeneyi sıkma (masseter kasılma) durumu için 1, kas yorgunluğu ve ağrısı için 2 ve ritmik diş gıcırdatma eylemi için 3 olarak sayılarla etiketlenmiştir. Girdi olarak farklı genlik ve frekans bilgilerini içeren toplam 13 farklı genlik ve frekans bilgisini içeren öznitelikler kullanılarak YSA yapısı oluşturulmuş ve yapının girdi özniteliklerine bağlı olarak sınıflandırma problemlerini azaltmadaki analizleriyle ilgili olarak Şekil 5.4 ve Şekil 5.5'te sırasıyla YSA'nın R katsayıları ve ROC eğrilerine dayalı performans sonuçları gösterilmektedir.



Şekil 5.4 Giriş özellik sayılarının YSA performans analizi için R katsayıları



Şekil 5.5 Giriş özellik sayılarının YSA performans analizi için ROC eğrileri

Şekil 5.4'te kullanılan genlik ve frekans özelliklerine göre oluşturulmuş YSA yapısının performans sonuçları gösterilmektedir. Şekil 5.5 ise aynı özellikler kullanılmasıyla YSA sonucu elde edilen ROC eğrilerini göstermektedir. Bu genlik

ve frekans özellikleri Tablo 4.4'te gösterildiği gibi korelasyon değerleri yüksek olan özellikler seçilerek YSA kullanılarak elde edilmiş R katsayıları ilişkisi gösterilmektedir. Bu grafiklerde sırasıyla (a), ZC ve WAMP birlikte kullanılarak elde edilen sonuçları; (b) ZC, WAMP, DASD ve AAC birlikte kullanılarak elde edilen sonuçları; (c) ZC, WAMP, RMS, DASD ve AAC birlikte kullanılarak elde edilen sonuçları; (d) MNF, VAR, SSC, RMS, DASD ve AAC kullanılarak elde edilen sonuçları; (e) MNF, MAV, VAR, SSC, RMS, DASD, AAC, ZC ve SD birlikte kullanılarak elde edilen sonuçları; (f) ise 13 özelliğin tümünün (MNF, MDF, VAR, LOG, SSC, MAV, ZC, WAMP, WL, RMS, DASD, AAC, ve SD) sonuçlarını göstermektedir. Dolayısıyla Şekil 5.4 ve Şekil 5.5'deki grafikler incelendiğinde öznitelik sayısı arttıkça oluşturulan yapının performansının arttığını göstermektedir [106]. Ancak R katsayılarından ve ROC eğrilerinden de anlaşılacağı üzere en iyi performans 13 özelliğin tamamıyla gerçekleşmektedir. Diğer özelliklere baktığımızda (ZC, WAMP, RMS, DASD ve AAC) birlikte kullanıldığında da YSA'nın performansı yüksektir. Ayrıca bu beş özellik ile yapılan sınıflandırma, Şekil 5 ve Şekil 6'daki sonuçları doğrulamaktadır. Dolayısıyla bu 13 özelliğin tamamı kullanılmadan, sadece korelasyon ilişkisi yüksek 5 farklı özelliği (ZC, WAMP, RMS, DASD ve AAC) birlikte kullanılarak YSA ile yapılan sınıflandırmalarda bruksizm tanılamada %98,8 doğrulukla yüksek bir etkinliğe ulaşılabilmektedir. Bu doğruluk oranları Tablo 5.1'deki karmaşıklık matris sonuçları incelendiğinde açıkça görülmektedir.

Tablo 5.1 YSA kullanılmasıyla elde edilen karmaşıklık matrisi

2 Özellik (ZC, WAMP)						4 Özellik (ZC, WAMP, DASD, AAC)						5 Özellik (ZC, WAMP, RMS, DASD, AAC)					
<i>Hedef Sınıflar(%)</i>						<i>Hedef Sınıflar(%)</i>						<i>Hedef Sınıflar(%)</i>					
<i>0 1 2 3</i>						<i>0 1 2 3</i>						<i>0 1 2 3</i>					
<i>Çıkış Sınıfları(%)</i>	<i>0</i>	25	0	0,6	0	<i>Çıkış Sınıfları(%)</i>	<i>0</i>	24,3	0	0	0	<i>Çıkış Sınıfları(%)</i>	<i>0</i>	24,3	0	0	0
	<i>1</i>	0,6	39,4	0,6	0		<i>1</i>	0,6	41,3	0	0		<i>1</i>	0,6	41,9	0	0
	<i>2</i>	0	2,5	17,5	0		<i>2</i>	0,6	0,6	18,8	0		<i>2</i>	0,6	0	18,8	0
	<i>3</i>	0	0	0	13,8		<i>3</i>	0	0	0	13,8		<i>3</i>	0	0	0	13,8


0/Çene gevşek; 1/Diş sıkma; 2/Kas yorgunluğu; 3/Diş gıcırdatma

Tablo 5.1 YSA kullanılmasıyla elde edilen karmaşıklık matrisi (devamı)

6 Özellik(%) (MNF, VAR, SSC, RMS, AAC, DASD)					9 Özellik(%) (MNF, MAV, VAR, SSC, RMS, AAC, DASD, ZC, SD)					13 Özellik(%) (Tamamı)					
Hedef Sınıflar(%)					Hedef Sınıflar(%)					Hedef Sınıflar(%)					
0123					0123					0123					
Çıkış Sınıfları (%)	0	24,3	0	0	0	0	24,3	0	0	0	0	24,3	0	0	0
	1	0,6	41,9	0,6	0	1	0,6	41,9	0	0	1	0,6	41,9	0	0
	2	0,6	0	18,2	0	2	0,6	0	18,8	0	2	0,6	0	18,8	0
	3	0	0	0	13,8	3	0	0	0	13,80	3	0	0	0	13,8

0/Çene gevşek; 1/Diş sıkma; 2/Kas yorgunluğu; 3/Diş gıcırdatma

Ayrıca YSA'nın dışında 5 farklı (DT, KNN, LD, NB, SVM) sınıflandırıcı kullanılarak bruksizm rahatsızlığın tanınmasındaki performansların incelenmesinde karmaşıklık matrisleri (Şekil 5.6) oluşturulmuştur. Bu şekile ait karmaşıklık matrislerindeki [164] herbir kare kutu içindeki sayıları, ilgili kutu tarafından sınıflandırmada kullanılan veri sayısını göstermektedir.



Şekil 5.6 DT, KNN, LD, NB ve SVM'ye ait sınıflandırma performansları


Şekil 5.6'daki karmaşıklık matrislerinde 13 özelliğe ait verilerde, KNN ve SVM'nin 160 adet veriden sadece üçünü yanlış sınıflandırdığı görülebilmektedir. Bunlardan ikisi gerçek durumdaki kas yorgunluğu (2) yerine, diş sıkma (1) olarak sınıflandırılmış ve de kalan 1 adet veri ise gerçek durumda (1) olması gerekirken, (2) olarak sınıflandırılmıştır. Dolayısıyla KNN ve SVM'nin bu sonuçlara göre %98.1'lik doğrulukla bruksizm tanısı için alt çene aktivitelerini ayırt etmede diğer sınıflandırıcılara göre daha yüksek olmaktadır (Tablo 5.2).

Tablo 5.2 Özellik sayılarına göre sınıflandırmadaki doğruluk oranları


Kullanılan Özellikler	ZC WAMP	ZC WAMP DASD AAC	ZC WAMP RMS DASD AAC	MNF VAR SSC RMS DASD AAC	MNF VAR SSC MAV ZC RMS DASD AAC SD	MNF MDF VAR LOG SSC MAV ZC WAMP WL RMS DASD AAC SD
Kullanılan Algoritmalar	Doğruluk Oranları (%)					
Karar Ağacı (Fine)	%93.1	%92.5	%90.6	%90.6	%92	%94.4
Karar Ağacı (Medium)	%93.1	%92.5	%90.6	%90.6	%92	%94.4
Karar ağacı(Coarse)	%87.5	%88.1	%82.5	%88.1	%88.1	%91.3
Lineer Diskriminant	%78.1	%93.1	%88.8	%94.4	%94.4	%94.4
Naive Bayes(Gaussian)	%76.3	%78.8	%88.8	%76.3	%76.3	%79.4
Naive Bayes(Kernel)	%81.3	%82.5	%92.5	%83.8	%86.9	%87.5
Destek Vektör Makine (Linear)	%91.9	%89.4	%88.1	%90.6	%92.5	%93.1
Destek Vektör Makine(Quadratic)	%94.4	%92.5	%95	%94.4	%95	%98.1
Destek Vektör Makine(Fine Gaussion)	%94.4	%93.8	%95.6	%95.6	%96.9	%96.9
En Yakın Komşuluk (Fine)	%93.8	%94.4	%97.5	%94.5	%97.5	%98.1
En Yakın Komşuluk (Weighted)	%95	%95	%96.3	%96.3	%96.3	%96.3
Yapay Sinir ağları	%95.7	%98.2	%98.8	%98.2	%98.8	%98.8

Bu çalışmada kullanılan her bir sınıflandırıcının sonuçlara etkisi bakımından kullanılan özellik sayısı önemlidir. Tablo 5.2'den de görüldüğü gibi, Bruksizm rahatsızlığını tanılamada farklı sayılarda genlik ve frekans bilgisini içeren özellikler ile sınıflandırma yapıldığında, özellik sayısının artmasına bağlı olarak sınıflandırmadaki doğruluk oranları da arttığı görülmektedir. Ancak yüksek korelasyona (R katsayısı) sahip 5 özellik (ZC, WAMP, RMS, DASD ve AAC) kullanıldığında da, KNN algoritması ile Şekil 5.6'daki karmaşıklık matrislerinde görüldüğü gibi etkili bir şekilde 0, 1, 2 ve 3 olarak etiketlenen bruksizm ile ilgili alt çene aktivitelerinin de %97,5 doğrulukla sınıflandırılabilirdiği görülmektedir. Yinede işlem hızı ve kolaylığı bakımından 13 farklı genlik ve frekans özelliklerin tamamının yerine bu 5 farklı özelliğin sadece YSA ile birlikte kullanılmasıyla Tablo 5.1 ve Tablo 5.2'den görüldüğü gibi %98,8 olarak etkin bir biçimde Bruksizm tanınması için alt çene aktiviteleri ayırt edilebilmektedir.

Ayrıca bu tez çalışmasında sadece EMG sinyallerinin kullanımına yönelik olarak sınıflandırmadaki doğruluk oranlarının bir adım daha da öteye gidebilmesi adına, sinyallerin bu kez 12 düzenli AR katsayıları ve 8 seviyeli db4 dalgacık ayrıştırmasıyla elde edilen Shannon entropi özellikleri (WShEn) kullanılarak analizler yapılmıştır. Alt çenenin kapalı pozisyonda (diş sıkma), alt çeneye bağlı masseter kasında ortaya çıkan kas yorgunluğu durumları ve de uyku esnasında yapılan parafonksiyonel ritmik çene (diş gıcırdatma) hareketlerine bağlı olarak YSA yapıları ile etkin bir biçimde Bruksim rahatsızlığın teşhisi konulabilmektedir. Bu işlemde EMG sinyallerin tanıya yönelik sınıflandırılması için AR ve WShEn özellik parametreleri birlikte kullanıldığında nöral ağın performansı yüksek değerlerde çıkabilmektedir. Şekil 5.7'deki ortalama karesel hata (MSE) değerlerinin histogram grafiklerinde, verilerin büyük bir bölümündeki hata değerleri 0'a çok yakın değerlerde olabilmektedir. Dolayısıyla validasyon performansları açısından hatanın minimum değerlere yaklaştığı Şekil 5.8'de gösterildiği gibi gayet açıktır. Ayrıca Şekil 5.9'da gösterilen eğitim, validasyon ve test verilerin her üç özellik grafiklerindeki R parametreleri incelendiğinde, AR ve WShEn özellikleri ile birlikte kullanımıyla en iyi korelasyona sahip olduğu açıkça görülmektedir.




Şekil 5.7 YSA giriş özelliklerine göre elde edilen MSE histogram grafikleri



Şekil 5.8 YSA giriş özelliklerine göre elde edilen validasyon performansları

Dolayısıyla önceki bölümde bahsedilen Tablo 4.2'deki değerler incelendiğinde ağ parametresi olarak 10 gizli katman, eğitim verisi %60, validasyon %30 ve test %10 dataset oranlarıyla seçilerek oluşturulan YSA yapılarında hem AR hem de WShEn değerleri kullanılarak elde edilen giriş öznitelik parametreleriyle eğitimde R:0,99, testte R:0,98 olarak çok yüksek bir performans elde edildiği görülmektedir. Ayrıca bu durum Şekil 5.9'daki grafikler de gösterilmektedir. Bu grafiklerde (a), (b) ve (c) yalnızca WshEn ile oluşturulmuş ağ performanslarını; (d), (e) ve (f) ise AR(12) dereceli katsayılar ile oluşturulmuş ağ performanslarını; (g), (h) ve (j) ise her iki özellikler ile oluşturulmuş ağ performanslarını göstermektedir. AR ve WshEN ile birlikte değerlendirildiğinde ağın performansı bakımından eğitim, validasyon ve test verilerindeki R katsayıları (korelasyonlar) diğerlerine göre çok daha iyi değerlerde, diğer bir deyişle eğitim yaklaşık 45° R:1'e yakın değerlerdedir.



Şekil 5.9 YSA giriş özelliklerine göre yapılmış regresyon analizler

Sonuç olarak buraya kadar açıklanan ağın performansını belirlemeye yönelik çalışmalardan ibarettir. Bu bağlamda etkili bir sınıflandırma için ağın performans kriterleri bakımından R ve MSE değerlerine bakılarak karar verilmektedir. Maksimum R ve minimum MSE elde edilmesi için matlab yazılımını kullanarak deneklerden alınan veriler için farklı oranlarda AR ve WShEn öznelilikleriyle ayrı ayrı ve tümleşik olarak simüle edilerek en uygun ağ topolojisi olarak eğitim oranları, %60; validasyon oranları, %30; ve de test oranları, %10 olarak belirlenmektedir (Tablo 4.3). Çalışmadaki eğitim ve validasyon oranların yüksek olması ağın performansı için önemli bir kriterdir. Şekil 5.9'da açıkça

görülmektedir ki, AR ve WShEn parametreleri ile birlikte kullanıldığında çok daha yüksek bir performansta başarılı bir YSA yapısı oluşturabilmektedir. Dolayısıyla bu çalışmada, deneklerden alınan EMG verilerinin AR ve WShEn parametreleri ile kullanılarak oluşturulan YSA'lar ile tanıya yönelik sınıflandırılma çalışmaları yüksek doğruluk oranlarında yapılabilmektedir. Bu çalışmalardan elde edilen 4 farklı çıkış durumunu gösteren sınıflandırmadaki doğruluk performans sonuçları Tablo 5.3'de karmaşıklık matris tablolarında detaylandırılmıştır.

Tablo 5.3 AR ve WShEn özellikleriyle YSA'dan oluşan karmaşıklık matrisler

AR						WShEn						AR+WShEn					
<i>Hedef Sınıflar(%)</i>						<i>Hedef Sınıflar(%)</i>						<i>Hedef Sınıflar(%)</i>					
<i>0123</i>						<i>0123</i>						<i>0123</i>					
<i>Çıkış Sınıfları(%)</i>	<i>0</i>	31,2	0	0	0	<i>Çıkış Sınıfları(%)</i>	<i>0</i>	31,2	0	0	0	<i>Çıkış Sınıfları(%)</i>	<i>0</i>	31,2	0	0	0
	<i>1</i>	0	49,6	2,4	0		<i>1</i>	0	51,2	3,2	0		<i>1</i>	0	52	0	0
	<i>2</i>	0	2,4	8,8	0		<i>2</i>	0	0,8	8,0	1,6		<i>2</i>	0	0	11,2	0
	<i>3</i>	0	0	0	5,6		<i>3</i>	0	0	0	4		<i>3</i>	0	0	0	5,6

0/Çene gevşek; 1/Diş sıkma; 2/Kas yorgunluğu; 3/Diş gıcırdatma

Tablo 5.3'de gösterilen tabloya göre 0 nolu durum, çenenin açık durumudur. Bu durum için deneklerden toplanan 125 adet veri setimizin %23'ünü oluşturmaktadır. Geriye kalan %77 oranındaki verilerin tamamı bruksizm durumlarıyla ilgili verilerden oluşmaktadır. Bu veriler, bu tabloda gösterilen 1, 2 ve 3 nolu durumları ifade etmektedir. AR parametreleriyle yapılan sınıflandırmada %95,2 doğruluk oranıyla veriler sınıflandırılabilmiş, %4,8'lik kısmı yanlış sınıflandırılabilmiştir. WShEn parametreleriyle bu kez %94,4'lük bir başarıyla sınıflandırılabilmiştir. Ancak her iki parametre (AR+WShEn) kullanılarak yapılan sınıflandırmalarda verilerin tamamı %100 doğruluk ile sınıflandırılarak en yüksek performans değeri elde edilmektedir.

5.2 MMG Sinyalleriyle Yapılan Analizlerin Sonuç ve Bulguları

Bu çalışmada Bruksizmin etkin ve kolay bir şekilde tanınmasında, deneklerin sol ve sağ masseter kaslarından alınan mikro titreşim sinyalleri 5-100 Hz band geçiren 4.cü derece butterworth filtresiyle filtrelenerek, ortalama 4500 Hz örnekleme

frekansıyla sayısallaştırılarak analizler için veriler elde edilmiştir. Ölçüm değerlerinin alınmasında 32bit Atmel SAM3X8E ARM Cortex-M3 işlemci kullanılarak 250000 bps veri iletim hızında PC ortamına aktarılmıştır. İkinci bölümde gösterilmiş olan Şekil 2.10'daki grafiklerde görüldüğü gibi %10 MVC'de alt çene masseter kasının kasılması esnasında kasta var olan mikro titreşimlere ait genlik değerlerin 10 kat arttığı açıkça görülmektedir. Ayrıca parafonksiyonel dış gıcırdatma hareketlerinde ise genliklerdeki değişim miktarı fazladır. Bu sebeple bu çalışmayla ilgili yapılan analizlerde, MEMS tabanlı akselerometre MMG sinyallere ait genlik değerlerine ve frekansa bağlı özellikler tercih sebebi olmuştur. Dolayısıyla Tablo 3.2'de MEMS tabanlı sinyaller için 12 farklı özellik kullanılarak analizler yapılmıştır. Analizlerde 100 farklı veriseti ile toplamda 1200 veri kullanılmıştır. İstatiksel analizler sonucu elde edilen regresyon katsayıları dikkate alınarak MNF, MDF, MFL, ZC ve DASD özelliklerin ($p < 0,0001$) regresyon katsayıları diğer özelliklere kıyasla yüksek olduğu görülmektedir (Tablo 3.2). Dolayısıyla bu 5 farklı özellikler Bruksizm tanılaması için sınıflandırma çalışmalarında ayrıca kullanılmıştır (Tablo 5.4).


Tablo 5.4 Özellik sayısına göre sınıflandırma sonuçları

	MNF MDF LogD MAV RMS MFL WL ZC WAMP AAC VAR DASD	MNF MDF MFL ZC	MNF MDF MFL ZC DASD	MNF MDF RMS MFL ZC DASD
Karar Ağacı (Fine)	%87,00	%83,00	%87,00	%88,00
Karar ağacı (Medium)	%87,00	%83,00	%87,00	%88,00
Lineer Diskriminant	%97,00	%90,00	%93,00	%96,00
Kuadratik Diskriminant	--	%93,00	%97,00	%95,00
Naive Bayes (Gaussion)	%75,00	%88,00	%88,00	%89,00
Naive Bayes (Kernel)	%81,00	%90,00	%90,00	%91,00
Yapay Sinir Ağları	%100,00	%97,00	%99,00	%99,00

Tablo 5.4 Özellik sayısına göre sınıflandırma sonuçları (devamı)

	MNF MDF LogD MAV RMS MFL WL ZC WAMP AAC VAR DASD	MNF MDF MFL ZC	MNF MDF MFL ZC DASD	MNF MDF RMS MFL ZC DASD
Destek Vektör Makine (Linear)	%95,00	%89,00	%89,00	%91,00
Destek Vektör Makine (Quadratic)	%95,00	%90,00	%92,00	%92,00
Destek Vektör Makine (Fine Gaussion)	%84,00	%88,00	%87,00	%80,00
Destek Vektör Makine (Medium Gaussion)	%92,00	%96,00	%97,00	%97,00
En Yakın Komşuluk (Fine)	%95,00	%90,00	%91,00	%91,00
En Yakın Komşuluk (Weighted)	%92,00	%85,00	%85,00	%91,00

Tablo 5.4 incelendiğinde korelasyon değerleri yüksek olan bu 5 farklı özellikler ile yapılan (1/Çene gevşek, 2/Diş sıkma, 3/Diş gıcırdatma) sınıflandırmalardaki doğruluk oranları, QD ve SVM algoritmalarıyla %97 oranlarına erişmektedir (Şekil 5.10).



Şekil 5.10 MNF, MDF, MFL, ZC ve DASD kullanılmasıyla karmaşıklık matrisleri


Ayrıca YSA yapıları kullanılarak bruksizm tanılanmasındaki (1/Çene gevşek, 2/Diş sıkma, 3/Diş gıcırdatma) eylemlerin sınıflandırılmasında MNF, MDF, MFL, ZC ve DASD özelliklerin kullanılmasıyla %99 gibi çok yüksek bir doğruluk oranlarına ulaşabilmektedir (Şekil 5.11). Ancak çalışmadaki özellik sayısı 12 seçildiğinde sınıflandırmadaki performans oranları bakımından LD algoritmasıyla %97, YSA ile %99 etkinliktedir (Tablo 5.4).



Şekil 5.11 MNF, MDF, MFL, ZC ve DASD özelliklerin kullanılmasıyla YSA'dan elde edilen doğruluk oranlarını gösteren karmaşıklık matrisleri

Şekil 5.11'de görüldüğü gibi YSA kullanılmasıyla MEMS tabanlı akselerometreden elde edilen MMG sinyallerine ait en etkili 5 farklı genlik ve frekans özellikleri (MNF, MDF, MFL, ZC ve DASD) ile; 1, çene kasının gevşek oluşu; 2, çene kasının diş sıkma durumunda oluşu ve 3, diş gıcırdatma parafonksiyonel hareketlerine ait

durumlar, bruksizm tanılması için %99 doğrulukla etkin bir biçimde sınıflandırılabilir. Sadece 1 adet veri (çene sıkma), yanlış sınıflandırılmıştır. Bu bir adet verinin yanlış sınıflanması, ayrıca Şekil 5.12’de gösterilen YSA’dan elde edilen ROC analiz sonuçlarındaki yeşil renkteki grafik çizgisinde de açıkça gösterilmektedir.




Şekil 5.12 MNF, MDF, MFL, ZC ve DASD özelliklerin kullanılmasıyla YSA’dan elde edilen doğruluk oranlarını gösteren ROC eğrileri

Kullanılan bu YSA yapısı için deneklerden toplanan 100 farklı data verileri sırasıyla eğitim için %70, validasyon için %15 ve test için %15 olarak seçilerek, ayrıca ara katman nöron sayısı 10 adet olarak analizler yapılmış, Şekil 5.11 ve Şekil 5.12’de görüldüğü gibi sadece 5 farklı genlik ve frekans özellikleri (MNF, MDF, MFL, ZC ve DASD) ile %99 gibi çok yüksek bir etkinlikte bruksizm tanılması için sınıflandırma performansları elde edilebilmiştir. Ayrıca aynı YSA yapısının 12 özelliğin tamamının kullanılmasıyla da Tablo 5.4’te görüldüğü gibi aynı çıkış durumları %100 oranında doğruluk performansı ile sınıflandırılabilir.

5.3 EKF Filtre Modeliyle Adaptif Yöntemin Performans Sonuçları


Bu çalışmada deneklerden gerçek zamanlı olarak alınan alt çene aktiviteleriyle ilgili olarak diş sıkma hareketleri ve gevşeme hareketleriyle birlikte parafonksiyonel çiğneme hareketlerinden EMG sinyalleri için anlamlı frekans aralığı 10-500 Hz [75], MEMS sinyalleri için ise 5-100 Hz [67] aralıkları dikkate alınarak harici bandpass analog butterworth 2.ci ve 4.cü dereceden filtre yapıları kullanılarak referans sinyaller oluşturulmuş ve bu sinyallere karşılık çalışmamızda tasarlanan adaptif EKF modelinin filtreleme performansı incelenmiştir. Şekil 5.13 ve 5.14'te sırasıyla EMG ve MEMS tabanlı sinyaller için önerilen adaptif EKF modelimiz ile filtrelenmiş sinyallerin zamana bağlı olarak elde edilen genlik değişimlerine ait grafiksel sonuçlar gösterilmektedir.



Şekil 5.13 EMG sinyalin zaman domenindeki geliştirilen EKF modeliyle karşılaştırmalı filtrelenmiş grafikler

Şekil 5.13'teki grafiklerde örnek bir deneğe ait alt çene masseter kasından orjinal ham olarak alınan gürültülü EMG sinyali için, karşılaştırmalarda kullanılması için analog 2.ci derece Butterworth filtre kullanılarak 5-500Hz aralığında referans sinyal olarak filtrelenmiş grafiği ve de aynı sinyalin ayrıca bu çalışmada EKF


modeline dayalı geliştirilen adaptif filtresi 5-500 Hz aralığında filtrelenmiş grafiğinin zaman domenindeki genlik değişimleri gösterilmektedir. Bu grafiklerdeki sinyal örnekleri kasın gevşeme ve kasılma durumu ile birlikte toplamda 2 s genişliğinde olmaktadır. 1.ci saniye aralığına kadar alt çenenin gevşeme durumudur. 1 ile 2.ci saniye aralığında ise alt çenenin kasılarak diş sıkmasıyla elde edilen sinyallerin grafikleridir.



Şekil 5.14 MMG sinyalin zaman domenindeki geliştirilen EKF modeliyle karşılaştırmalı filtrelenmiş grafikler


Şekil 5.14'teki grafiklerde ise örnek bir deneğe ait rastgele diş gıcırdatma parafonksiyonel hareketlerine bağlı olarak alt çene kaslarından (masseter+temporal) alınmış bir MEMS akselerometre tabanlı MMG sinyalleri için, bu çalışmada hem gürültülü olarak elde edilerek bu şekilde gösterilmi, hem de bu sinyallerin önerilen adaptif EKF modeliyle 5-100 Hz band aralığındaki filtrelenmesiyle elde edilen zaman domenindeki genlik grafikleri gösterilmiştir. Her iki grafikte de sadece geçirme bandındaki frekanslara ait genlik değerleri filtrelendiği için diğer aralıklardaki sinyalleri geçirmediğinden dolayı sinyal genliklerindeki değişim miktarının azaldığı, diğer bir deyişle daha pürüzsüz olduğu bu grafiklerden açıkça görülmektedir.

Şekil 5.14'te MEMS akselerometre sinyalleri, parafonksiyonel diş gıcırdatma hareketlerine bağlı olarak alt çene kaslarının ritmik olarak kasılması ve gevşemesiyle oluşan sinyallerdir. Aynı şekil incelendiğinde, kasılma anında ritmik genlik patlamaları görülmektedir. Ayrıca bu durum uyku bruksizm rahatsızlıklarının tanısı için de önemli bir durum olmaktadır [15]. Ancak şekilde görüldüğü gibi filtrelenmemiş orjinal grafikte bu durum çok belirgin değildir. Sinyalin 5-100 Hz aralıklarında önerilen yöntemdeki EKF'nin tahmin ederek yapmış olduğu filtrelemelerde kasılma anında akselerometre MEMS sensörün algıladığı titreşim genlik patlamaları belirgin olmakla beraber, gevşeme anında ise titreşim genlik değerleri gürültüler yok edildiği için minimum değerlerde olup sıfıra çok yakın değerlerdedir. Dolayısıyla ham olarak görülen sinyal anlamlı hale dönüşmüştür. Filtrelenen bu sinyaller için hızlı Fourier dönüşümlerin (FFT) yapılmasıyla elde edilen frekans spektrumları Şekil 5.15 ve Şekil 5.16'da ayrıca gösterilmektedir.



Şekil 5.15 Filtrelenmiş ve filtrelenmemiş EMG sinyalin frekans spektrumları

Şekil 5.15'te görüldüğü gibi frekans spektrumları incelendiğinde EMG sinyallerinin anlamlı frekanslar 500 Hz kadar olabilmektedir [75]. Bu çalışmadaki Önerilen model EKF sistemi referans analog filtreden geçirilmiş referans sinyal ile karşılaştırıldığında anlamlı frekansları filtrelediği görülmektedir.



Şekil 5.16 Filtrenmiş ve filtrenmemiş MMG sinyalin frekans spektrumları

Şekil 5.16’da MEMS akseloremetre sinyallerine ait filtrenmiş ve de filtrenmemiş ham bir sinyalin spektrumu gösterilmiştir. Bu sinyallerin literatürdeki anlamlı frekans aralığı 5 Hz’den 100 Hz’e kadar olmaktadır [67]. Ancak 100 Hz’ten sonra yüksek frekanslı bileşenlere rastlanılmamakla birlikte, vücut hareket kaynaklı 5 Hz’e kadar oluşan gürültülere karşı MEMS akselerometre sistemleri oldukça duyarlıdır. Bu sebeple bu çalışmadaki önerilen yaklaşım ile kaslardaki mikrotitreşimler mümkün olduğunca kendiliğinden algılanmaktadır. Bununla birlikte hareket kaynaklı gürültüleri (5 Hz’e kadar) filtrelediği görülmüştür. Bu durum, analog filtrenmiş referans sinyal ile filtrenmemiş ham sinyallerin spektrumları karşılaştırıldıklarında açıkça görülmektedir.

Bu çalışmadaki filtrenen tüm sinyaller için EKF sistemi kullanılarak yapılan filtrelemelerde filtrenin gürültü parametreleri W_k ve V_k değerleri kendiliğinden ayarlanabilmektedir. Bu sebeple filtrenin performansını değerlendirme de ayrıca matlab yazılımı kullanılarak deneklerden elde edilen sinyaller, DT, SVM, NB, LD ve KNN olmak üzere 5 farklı makine öğrenme algoritmaları ile filtrenen

sinyallere karşılık sistemin kendiliğinden elde ettiği gürültü parametreleri bu yaklaşımın performansını değerlendirmede kullanılmıştır. Bu bağlamda giriş parametreleri, deneklerden alınan sinyaller (EMG + MEMS) toplamda 60 farklı filtrelenmiş sinyalleri temsil eden genlik ve frekans öznitelikleri olmaktadır. Bu öznitelikler istatistiksel olarak regresyon analizleriyle 13 özellik arasından belirlenen en yüksek korelasyona sahip olan MNF, ZC, WL, SSC, AAC ve DASD özellikler olarak belirlenmektedir (Tablo 4.4). Çıkış parametreleri ise ölçüm gürültüsü (V_k) değerlerini temsil etmektedir. Bu çalışmadaki 20 farklı denekten alınan 60 farklı sinyalin filtrelenmesinde sistemin kendiliğinden adaptif olarak hesapladığı 6 farklı V_k değeri kullanılmıştır. Bu çıkış V_k değerler 0.008, 0.01, 0.02, 0.1 ve 2 olmaktadır. Çalışmada işlem gürültüsü (W_k) değeri ise, EMG sinyalleri için 0.001, MEMS sinyalleri için 0.0001 olarak sistem tarafından belirlenerek bu değerler analiz süresince sabit olarak tutulmuştur. Bu nedenle sınıflandırma performansında V_k değerleri esas alınarak, farklı değerler alabildiğinden dolayı çıkış parametresi olarak belirlenmiştir. Sınıflandırmada performansı için kullanılan makine öğrenme algoritmaları için eğitim için farklı çapraz validasyon (k-fold) değerleri kullanılmıştır. Tablo 5.5'te sınıflandırmadan elde edilen doğruluk oranları farklı k-fold değerlerine göre gösterilmektedir. Bu değerler Matlab yazılımı kullanılarak elde edilen karmaşıklık matrislerinden elde edilmiştir. En yüksek performans, k-fold:10 değerinde LD algoritmasıyla %100 doğruluk oranlarında sağlanmıştır. Dolayısıyla önerilen sistemin bütün deneklerin sinyallerine göre hesapladığı ölçüm gürültüsü parametreleri tutarlı olmaktadır.


Tablo 5.5 Farklı (k-fold) değerleriyle elde edilen doğruluk oranları

Kullanılan Algoritmalar	Kfold:2	Kfold:3	Kfold:4	Kfold:5	Kfold:10
Karar Ağacı (Fine)	%85,20	%86,90	%88,50	%88,50	%82,00
Karar Ağacı (Medium)	%85,20	%86,90	%88,50	%88,50	%82,00
Karar Ağacı (Coarse)	%85,20	%86,90	%88,50	%88,50	%82,00

Tablo 5.5 Farklı (k-fold) değerleriyle elde edilen doğruluk oranları (devamı)


Kullanılan Algoritmalar	Kfold:2	Kfold:3	Kfold:4	Kfold:5	Kfold:10
Lineer Diskriminant	%96,70	%98,40	%98,40	%98,40	%100,00
Naive Bayes (Gaussian)	%88,50	%88,50	%88,50	%88,50	%86,90
Naive Bayes (Kernel)	%86,90	%88,50	%90,20	%95,10	%95,10
Destek Vektör Makine (Linear)	%96,70	%91,80	%96,70	%95,10	%93,40
Destek Vektör Makine (Quad.)	%96,70	%95,10	%93,40	%96,70	%93,40
En Yakın Komşuluk (Fine)	%90,20	%91,80	%93,40	%93,40	%93,40
En Yakın Komşuluk (Medium)	%68,90	%86,90	%85,20	%90,20	%83,60
En Yakın Komşuluk (Weighted)	%90,20	%90,20	%93,40	%95,10	%90,20

Çapraz validasyon (k-fold:10) değeri için 5 farklı makine öğrenme algoritmasından elde edilen karmaşıklık matrislerin sonuçları ayrıca Şekil 5.17’de gösterilmiştir. Bu şekildeki karmaşıklık matrisleri incelendiğinde deneklere ait olan 60 farklı sinyali temsil eden MNF, ZC, WL, SSC, AAC ve DASD özelliklerin tamamı LD algoritmasıyla %100 doğruluk oranıyla sınıflandırılabilir. Dolayısıyla EKF kullanılarak geliştirilen adaptif filtreleme sistemi, her bir sinyale karşılık gelen bu özellikler için en uygun parametreleri hesaplayabilmektedir. Diğer bir deyişle her bir sinyale karşılık gelen gürültü parametreleri, sistem performansı açısından sınıflandırmadaki doğruluk oranlarını incelediğimizde tutarlı olduğu anlaşılmaktadır (Şekil 5.17).



Şekil 5.17 Geliştirilen adaptif EKF sisteminin V_k değerlerinin makine öğrenme algoritmalarla sınıflandırmadaki performanslar için karmaşıklık matrisleri


Ayrıca Şekil 5.18 ve Şekil 5.19’da, deneklerin alt çene kaslarına yerleştirilen EMG ve MEMS sensörlerden alınan 60 adet sinyal ile ilgili olarak, geliştirilen bu yöntemin performansını belirlemeye yönelik, filtreleme öncesinde ve sonrasındaki bu sinyallerden elde edilen MNF, ZC, WL, SSC, AAC ve DASD özneliklerin dağılım ve standart hatalarını gösteren, dağılım grafikleri gösterilmektedir.



Şekil 5.18 Filtrenilmiş ve filtrenmemiş EMG sinyallerden elde edilen özelliklerin dağılımları

Şekil 5.18 ve Şekil 5.19’da görüldüğü gibi hem EMG hem de MEMS tabanlı sinyaller için geliştirilen bu filtre modeli kullanılarak elde edilen MNF, ZC, WL, SSC, AAC ve DASD öznelik değerleri, filtrenmemiş gürültülü ham sinyalden elde edilen öznelik değerlerine kıyasla daha düzgün bir dağılımı ifade etmektedir. Ayrıca aynı dağılım grafikleri incelendiğinde standart hatalardaki sapmalar filtrenmeden elde edilen değerlere kıyasla daha düşük olduğu bu

grafikler incelendiğinde görülmektedir. Dolayısıyla bu filtreleme modelini kullanarak elde edilen filtrelenmiş sinyallerden zaman ve frekans öznelik değerlerinin daha anlamlı hale geldiği açıktır. Bu sayede bruksizm davranışlarını etkin bir şekilde ortaya koymanın yanı sıra ayrıca insan vücudu kaslarından alınan sinyallerin etkin bir şekilde kullanımında, titreşim ve kasılma miktarlarının algılanması, dış iskelet sistemleri, rehabilitasyon robotları ve de insan robot etkileşimine bağlı kontrol sistemlerinde bu geliştirilen adaptif modelin de kullanılabileceğini ortaya koymaktadır.



Şekil 5.19 Filtrelenmiş ve filtrelenmemiş MEMS tabanlı MMG sinyallerden elde edilen özelliklerin dağılımları

Literatürde bruksizm rahatsızlığının tanınmasında EMG ölçümleri kullanılmaktadır. Ancak tek başına EMG ölçümleri yeterli olamamakla birlikte, alternatif olarak EMG ölçümleriyle birlikte EKG, EEG ve de polisomnografiye dayalı hastaların ses ve video kayıtları da ayrıca kullanılmaktadır. Ancak tüm bu süreçler uygulamada pratik olmamakla birlikte, uygulanışı zaman alıcı ve maliyetli olabilmektedir. Dolayısıyla bu tez çalışmasında, bireylerin alt çene masseter ve temporal kaslardan sadece tek bir sensör modeli olarak EMG veya MEMS tabanlı sensörlerden elde edilen sinyallerin bruksizm rahatsızlığının etkin bir şekilde tanınması için literatüden farklı olarak kas yorgunlukları da ayrıca dikkate alınarak farklı yöntemler geliştirilerek, farklı makine öğrenme ve sınıflandırma algoritmaları kullanılarak birbirlerine göre etkinlikleri incelenmiştir. Ayrıca bu iki tip sensör modeline bağlı olarak hem elektromiyografi hem de akselerometre tabanlı olarak kaslardan elde edilen bu sinyallerin etkin bir şekilde filtrelenmesiyle anlamlı sinyallerin elde edilmesinde genişletilmiş Kalman filtre modeline dayalı yeni bir adaptif yöntem geliştirilerek bu sayede düşük maliyetli, klinik bir ortama gereksinimi olmadan ev ortamında veri kaydına da olanak sağlayan, küçük boyutlu, taşınabilir bir veri kayıt cihazı tasarlanmıştır.

Sadece EMG sinyalleri ile yapılan bruksizm tanısında aktiviteler gerçek zamanlı olarak kayıt altına alınarak zamana bağlı genlik ve frekans bilgilerini içeren toplamda 13 farklı özellikler elde edilmiştir. Bu özelliklerin tamamı Tablo 3.1'de gösterilmiştir. En etkin özelliklerle çalışmak sistemin verimini, doğruluğunu ve algılama hızını arttırmaktadır. Dolayısıyla bu özellikler içerisinde en yüksek korelasyona sahip olan en etkili 5 farklı özellik (ZC, WAMP, RMS, DASD ve AAC) istatistiksel olarak regresyon analizleriyle ve de YSA ile belirlenerek, tüm bu özellikler ile birlikte bruksizm tanılama analizlerinde kullanılmıştır. Yapılan bu çalışmada deneklerden elde edilen EMG sinyallerin zaman ve frekans özellikleri giriş özellikleri olarak YSA yapıları ile analiz edildiğinde, diğer makine öğrenme

ve sınıflandırma algoritmalarına kıyasla yüksek bir performans elde ederek bruksizm tanılama da ortaya çıkan alt çenenin diş sıkma, parafonksiyonel ritmik diş gıcırdatma ve de kas yorgunluk/ağrı durumlarını Tablo 5.1'deki karmaşıklık matrislerinde görüldüğü gibi özelliklerin tamamı ve de en etkili 5 farklı özellik için %98,8 doğruluk oranıyla tanılamada yüksek bir performans elde etmektedir. Diğer makine öğrenme algoritmaları bakımından ele aldığımızda ise, özellikle de KNN ve SVM algoritmalarıyla ise bu oran %98,1 olabilmektedir.

Bruksizm tanısında alt çene kaslarındaki kas yorgunluğun da dikkate alınması bruksizm aktiviteleri bakımından önemli bir kriterdir ve uyku kalitesini doğrudan etkilemektedir. Kas yorgunluğunun ortaya çıkması ile frekans spektrumlarına ait medyan frekans (MDF) ve ortalama frekans (MNF) özelliklerinde Şekil 5.2 ve Şekil 5.3'teki grafiklerden de görüldüğü gibi azaldığı gözlenmiştir. Bu nedenle, deneklerin bruksizm aktiviteleri sırasında alt çene kaslarından alınan gerçek zamanlı sinyallerin zamana bağlı olarak genlik ve frekans özelliklerini incelediğimizde, kas yorgunluğunun bu çalışmada ayrıca göz önüne alınması özellikle de elektronik tabanlı uyarıcı biofeedback sistemlerin kas yorgunluğu ortaya çıktığında algılama yapmasıyla da bruksizmin terapisinde kullanımı önemlidir.

Sadece EMG ölçümlerine dayalı olarak bu tez çalışmasında elde edilen sinyallerin zamana bağlı genlik ve frekans giriş özelliklerinin yanı sıra ayrıca alınan bu sinyallerin bruksizm tanılmasında daha etkin olarak değerlendirilmesi için sinyallerin 12ci düzende AR katsayılarıyla birlikte aynı sinyallerden Wavelet dönüşümleri yapılarak elde edilen Shannon entropi değerleri (WShEn) elde edilerek, YSA ile birlikte bu çalışmada kullanılarak, deneklerin alt çene aktivitelerindeki diş sıkma, diş gıcırdatma ve kas yorgunlukları durumları Tablo 5.3'te görüldüğü gibi %100 doğruluk ile sınıflandırılarak, bruksizm tanılanmasındaki en etkin performans değerlerine ulaşılmıştır.

Bu tez çalışmasında Bruksizm tanılanmasında EMG sinyallerinin dışında MEMS tabanlı akselerometre kullanılarak alt çene kaslarının kasılmasıyla cilt yüzeyinde oluşan mikrotitreşim sinyalleri (MMG) elde edilerek bruksizm tanılamadaki

etkinliđi ayrıca incelenmiřtir. Bu inceleme sonucunda ivme ölçer tabanlı MEMS akselerometre sistemler istemsiz vücut hareketlerine karşı duyarlı olsa da akselerometre tabanlı MEMS kullanılmasıyla deri yüzeyinde çevresel kaslardan oluşan elektromiyogram sinyallerden etkilenmemesi, sadece temas ettiđi kasın bulunduđu deri yüzeyindeki mekanik titreřimlerin algılanmasıyla harici bir yükselteç ünitesine gerek duyulmaması, bu sayede sinyal gürültü oranı (SNR) kaynaklı gürültülerin oluşmamasından dolayı bu sistemin kullanılmasıyla harici donanımsal yükselteç ve analog filtreleme ünitelerine gereksinimi ortadan kaldırmaktadır. Ayrıca boyutsal bakımdan kullanışlı bir yapı olmaktadır. Dolayısıyla, EMG ölçümleri yerine alternatif olarak tercih edilen MEMS tabanlı bu sistemde, bu sinyallerin regresyon analizleriyle en etkili 5 farklı zamana bađlı genlik ve frekans özellikleri (MNF, MDF, MFL, ZC ve DASD) giriş özellikleri elde edilerek YSA ile yapılan sınıflandırma çalışmalarında Şekil 5.11'deki karmaşıklık matrislerinde de görüldüğü gibi %99 yüksek doğruluklu bir Bruksizm tanılması yapılabilmektedir. Ayrıca literature katkı açısından MEMS tabanlı geliştirilen sistemin performansı için diđer 6 farklı (KNN, DT, SVM, NB, LD ve QD) makine öğrenme algoritmalarıyla da sınıflandırma performansları (Şekil 5.10'da görüldüğü analiz edilmiştir. Bu çalışmadaki EMG'ye alternatif olarak önerilen MEMS tabanlı sistemin kullanılmasıyla boyutsal olarak dikkate aldığımızda giyilebilir veya taşınabilir sistemler için pratik bir yöntem olmakla birlikte, gelecek çalışmalar için tedaviye yönelik giyilebilir elektro uyarıcı sistemlerin etkin olarak kullanılabilmesi için uygun bir yaklaşım olmaktadır.

Bu tez çalışmasında buraya kadar bahsedilen sonuçlar tamamıyla EMG ve MEMS tabanlı deneklerden elde edilen sinyallerin bruksizm rahatsızlığının etkin olarak tanınmasına yönelik çalışmalardır. Ancak söz konusu bu sinyaller insan vücudundan elde edilen lineer olmayan biyolojik sinyaller olması sebebiyle, sinyallerin kolay ve etkin bir biçimde elde edilmesi önem arz etmektedir. Özellikle bruksizm teşhisindeki alt çene aktivitelerin elde edilmesinde kişilerin istemsiz vücut hareketleriyle oluşan gürültüler, farklı kas gruplarından oluşan gürültüler, kişilerin yaş ve cinsiyetine bađlı olarak sensörün temas ettiđi cilt yüzeyleri kaynaklı oluşan gürültüler dikkate alındığında ev ortamında da sinyallerin rahatlıkla elde

edilmesinde tüm bu olumsuz etkenler düşünülerek dijital ortamda EKF'ye dayalı adaptif bir filtre modeli geliştirilmiştir. Dolayısıyla önerilen yöntemin literatürde yapılan çalışmalardan farkı, hem Bruksizm alanında öncesinde uygulanmaması, hem de adaptif bir yapıya sahip bir filtre oluşudur. Adaptif yapının elde edilmesindeki yenilik ise EKF'de belirtilen W_k ve/veya V_k parametreleriyle birlikte minimum MSE değeri elde edilinceye kadar sistemin kendi içinde döngüde kalarak iteratif bir şekilde yapmış olduğu sistemin kalibrasyonudur. Bu sayede sistem gürültü parametrelerini kendiliğinden iteratif bir yaklaşımla ayarlamasıyla adaptif bir yapıya kavuşmaktadır. Diğer bir deyişle sistem farklı deneklerde veya farklı koşullar altındaki kas grupları için kendiliğinden adapte olabilmektedir. Dolayısıyla iskelet kaslarından elde edilebilecek biyolojik işaretlerde farklı sensör sistemleri için de bu modelin kullanılması önerilmektedir. Bu çalışmada, hem EMG hem de MEMS sensör sistemi kullanılarak başın ve çenenin sürekli hareketli oluşu ve de alt çenenin parafonksiyonel hareket kabiliyetinden dolayı masseter kasından elde edilen sinyaller, ritmik diş gıcırdatma hareketleri ile birlikte çene diş sıkma hareketleriyle elde edilen gürültülü sinyaller, harici bir donanımsal kaynaklı filtreden geçirilmesiyle referans sinyaller olarak elde edilmiştir. Ayrıca aynı sinyaller önerilen bu yaklaşım ile de filtrelenerek, tüm bu sinyallerden elde edilen özellikler ile beş farklı makine öğrenme algoritması (LD, DT, SVM, NB ve KNN) kullanılarak filtre performansları bakımından karşılaştırmalı olarak analiz edilmiştir. Performans sonuçları bakımından hem EMG, hem de MEMS tabanlı sinyaller için Şekil 5.18 ve Şekil 5.19' daki grafiklerden de görüldüğü gibi bu önerilen yeni yaklaşımın kullanılmasıyla, tüm bu sinyallere ait genlik ve frekans özelliklerinin standart hataları daha düşük düzeylerde olduğu görülmüştür. Ayrıca filtreleme sisteminin EMG ve MEMS tabanlı sinyaller için elde ettiği gürültü parametreleri LD algoritmasıyla %100 etkinlikle sınıflandırılabilirdiği Şekil 5.17'de açıkça görülmüştür.

Önerilen bu adaptif filtreleme yöntemi bruksizm rahatsızlığının teşhisinde kullanılabilir olmasının yanı sıra ayrıca alt ve üst ekstremité iskelet kaslarından elde edilebilecek EMG yada MMG sinyallerin filtrelenmesi için de uygundur. Dolayısıyla bu filtreleme sistemi rehabilitasyon amacıyla dış iskelet sistemlerinde,

parkinsona baęlı titreřimlerin etkin olarak algılanmasında, kaslarda oluřan yorgunluk/aęrı analizlerinin teřhisinde ve de insan robot etkileřimine dayalı robotik eklem açısı kontrol sistemlerinde ayrıca uygulanabilir bir yapı olmakla beraber; donanımsal olarak analog band geçiren, alçak geçiren veya yüksek geçiren filtrelemeler için harici donanımsal kaynaklara ihtiyaç duyulmamasıyla da düşük maliyetli ve de kapladığı boyut bakımından da az yer kaplayabilmektedir.

- [1] F. Lobbezoo, R. Jacobs, A. De Laat, G. Aarab, P. Wetselaar, D. Manfredini, "Chewing on bruxism. Diagnosis, imaging, epidemiology, aetiology," *Ned. Tijdschr. Tandheelkd.*, vol. 124, pp. 309-316, 2017.
- [2] F. Lobbezoo, J. Van Deer Zaag, M. Naeije, "Bruxism: its multiple causes and its effects on dental implants," *Journal of Oral Rehabilitation*, vol. 33, pp. 293-300. 2006.
- [3] F. Lobbezoo, J. Brouwers, M. Cune, M. Naeije, "Dental implants in patients with bruxing habits," *Journal of Oral Rehabilitation*, vol. 33, pp. 152-159, 2006.
- [4] G. J. Lavigne, T. Kato, A. Kolta, B. J. Sessle, "Neurobiological mechanisms involved in sleep bruxism," *Crit. Rev. Oral Biol. Med.*, vol. 14, pp. 30-46, 2003, doi:10.1177/154411130301400104.
- [5] E. Somtürk, "Temporomandibuler eklem hastalıklarında klinik bulgular ve ayırıcı tanı," *Türkiye Klinikleri Journal of Oral and Maxillofacial Radiology-Special Topics*, vol. 1, pp. 89-92, 2015.
- [6] C. A. Bulut, "Bruksizm vakalarında implant destekli 3 üyeli solid zirkonyum seramik ve metal-seramik restorasyonların kullanım süreleri ve kırılma dirençlerinin bruksizmi yansıtan çiğneme simülatöründe değerlendirilmesi," *Doktora Tezi, Kırıkkale Üniversitesi, Sağlık Bilimleri Enstitüsü, Protetik Diş Tedavisi Ana Bilim Dalı, Kırıkkale*, 2015.
- [7] R. V. Murali, P. Rangarajan, A. Mounissamy, "Bruxism: Conceptual discussion and review," *Journal of pharmacy & bioallied sciences*, vol. 7, 2015, doi: 10.4103/0975-7406.155948.
- [8] T. Kato, N. M. Thie, J. Y. Montplaisir, G. J. Lavigne, "Bruxism and orofacial movements during sleep," *Dent. Clin North Am.*, vol. 45, pp. 657-684, 2001.
- [9] K. Koyano, Y. Tsukiyama, R. Ichiki, T. Kuwata, "Assessment of bruxism in the clinic," *Journal of Oral Rehabilitation*, vol. 35, pp. 495-508, 2008.
- [10] Y. Amemori, S. Yamashita, M. Ai, H. Shinoda, M. Sato, J. Takahashi, "Influence of nocturnal bruxism on the stomatognathic system. Part 1: A new device for measuring mandibular movements during sleep," *J. Oral Rehabil.*, 28(10):9743-9, 2001, doi:10.1046/j.1365-2842.2001.00757.x.
- [11] J. Gao, L. Liu, P. Gao, Y. Zheng, W. Hou, J. Wang, "Intelligent occlusion stabilization splint with stress-sensor system for bruxism diagnosis and treatment," *Sensors (Basel)*, vol. 20, 2019, doi:10.3390/s20010089.
- [12] F. Lobbezoo, H. L. Hamburger, M. Naeije, "Etiology of bruxism," in *Bruxism. Theory and practice*. D. A. Paesani, Ed., New Malden U.K.: Quintessence Publishing Company Inc., pp. 53-65. 2010.

- [13] F. Lobbezoo, G. J. Lavigne, "Do bruxism and tempromandibular disorders have a cause-and-effect relationship?," *J. Orofac Pain*, vol-11, pp. 15-23, 1997.
- [14] G. J. Lavigne, H. Tuomilehto, G. Macaluso, "Pathophysiology of sleep bruxism," in *Sleep Medicine for Dentists. A Practical Overview*, G. J. Lavigne, P. A. Cistulli, and M. T. Smith, Eds. Hanover Park, IL, USA: Quintessence Publishing Company, Inc., pp. 117–124. 2009.
- [15] G. J. Lavigne, N. Huynh, T. Kato, K. Okura, K. Adachi, D. Yao, B. Sessle, "Genesis of sleep bruxism: motor and autonomic-cardiac interactions," *Atch. Oral Biol.*, vol. 52, pp. 381-384, 2007.
- [16] M. Farella, S. Palla, L. M. Gallo, "Time-frequency analysis of rhythmic masticatory muscle activity," *Muscle Nerve*, vol. 39, pp. 828-836, 2009.
- [17] T. Castroflorio, L. Mesin, G. M. Tartaglia, C. Sforza, D. Farina, "Use of electromyographic and electrocardiographic signals to detect sleep bruxism episodes in a natural environment," *IEEE Journal of Biomedical and Health Informatics*, vol. 17, 2013.
- [18] D. Lai, MD B. B. Heyat, F. I. Khan, Y. Zhang, "Prognosis of sleep bruxism using power spectral density approach on EEG signal of both EMG1-EMG2 and ECG1-ECG2 channels," *Special Section on Neural Engineering Informatics*, Vol. 7, 2019, doi: 10.1109/ACCES.2019.2924181.
- [19] C. Jonsgar, P. A. Hordvik, M. E. Berge, et al. "Sleep bruxism in individuals with and without attrition-type tooth wear: an exploratory matched case-control electromyographic study," *J. Dent.*, vol. 43, pp. 1504–1510. 2015.
- [20] W. Yachida, T. Arima, E.E. Castrillon, et al. "Diagnostic validity of self-reported measures of sleep bruxism using an ambulatory single-channel EMG device," *J Prosthodont Res.* 2016; 60(4):250–257, doi:10.1016/j.jpor.2016.01.001.
- [21] G. J. Lavigne, P. H. Rompré, J. Y. Montplaisir, "Sleep bruxism: validity of clinical research diagnostic criteria in a controlled polysomnographic study," *J Dent Res.*, vol. 75, pp. 546–552. 1996.
- [22] F. Lobbezoo, J. Ahlberg, A. G. Glaros, et al. "Bruxism defined and graded: an international consensus," *J. Oral Rehabil.*, vol. 40, pp. 2–4, 2013, doi: 10.1111/joor.12011.
- [23] Y. Taihiko, M. Saki, M. Masana, S. Taishi, et al. "Portable and wearable electromyographic devices for the assessment of sleep bruxism: A literature review," *The Journal of Craniomandibular & Sleep Practice*, 2020, doi: 10.1080/08869634.2020.1815392.
- [24] G. Bilgin, "Dinamik Kasılmalarda Kas Yorgunluğunun elektromiyogram ve mekanomiyogram ölçümleri ile analizi," *Doktora Tezi, Sakarya Üniversitesi, Fen Bilimleri Enstitüsü, Sakarya*, 2016.
- [25] E. L. Fox, R. W. Bowers, M. C. Foss, "The physiological basis of exercise sport," *Brown-Benchmark Pubs. New York*, 1993.

- [26] H. Kayıhan, G. Hazar, M. Uyanık, T. Dülger, "Büro çalışanlarında çalışma şartlarına bağlı ergonomik risk faktörlerinin değerlendirilmesi," 5. Ergonomi Kongresi, 1995, pp. 369-376.
- [27] J. Kimura, "Electrodiagnosis in disease of nerve and muscle: principles and practice," Philadelphia, 1983.
- [28] K. Masuda, T. Masuda, T. Sadoyama, M. Inaki, S. Katsuta, "Changes in surface EMG parameters during static and dynamic fatiguing contractions," J Electromyogr Kinesiol, vol. 9, pp. 39-46, 1999, doi:10.1016/s1050-6411(98)00021-2.
- [29] A. Luttman, M. Jager, J. Sokeland, W. Luring, "Electrographical study on surgeons in urology. ii. determination of muscular fatigue," Ergonomics, vol.39, pp. 298-313, 1996, doi:10.1080/00140139608964460.
- [30] P. Kondrad, "The abc of emg," Noraxon INC. USA, 2005.
- [31] G. Kim, M. A. Ahad, M. Ferdjallah, G. F. Harris, "Correlation of muscle fatigue indices between intramuscular and surface emg signals," SoutheastCon. Proceedings. IEEE, pp. 378-382, 2007.
- [32] T. Sakurai, M. Toda, S. Sakurazawa, J. Akita, K. Kondo, Y. Nakamura, "Detection of muscle fatigue by the surface electromyogram and its application," In Computer and Information Sciences, 9th IEEE/ICIS international conference, 2010, pp. 43-47.
- [33] B. Boashash, "Time-frequency signal analysis: Methods and applications," Longman, Cheshire, 1992.
- [34] G. Comi, L. Leocani, P. Rossi, B. Colombo, "Physiopathology and treatment of fatigue in multiple sclerosis," J. Neurol., vol. 248, pp. 174-179, 2001.
- [35] M. L. Latash, M. J. Yee, C. Orpett, A. Slingo, J. J. Nicholas, "Combining electrical muscle stimulation with voluntary contraction for studying muscle fatigue," Arch. Phys. Med. Reha., vol. 75, pp. 29-35, 1994.
- [36] A. Chaudhuri, P.O. Behan, "Fatigue and basal ganglia," journal of Neurological Sciences, vol. 179, pp. 34-42, 2000.
- [37] Y. Koçyiğit, M. Korürek, "EMG işaretlerini dalgacık dönüşümü ve bulanık mantık sınıflayıcı kullanarak sınıflama," itüdergisi/d mühendislik cilt:4, sayı:3, 2005.
- [38] K. Englehart, B. Hudgins, P. A. Parker, "A Wavelet-based continuous classification scheme for multifunction myoelectric control," IEEE Transactions on Biomedical Engineering, vol. 48, pp. 302-311, 2001.
- [39] B. Karlık, H. Pastacı, M. Korükek, "Myoelectric neural networks signal analysis," Proc. 7. Mediterranean Electrotech. Conference, 1994, pp. 262-264.
- [40] F. H. Y. Chan, Y. S. Yang, F. K. Lam, Y. T. Zhang, P. A. Parker, "Fuzzy EMG classification for prosthesis control," IEEE Transaction on Rehabilitation Engineering, vol. 8, pp. 305-311, 2000.

- [41] A. Subaşı, M. K. Kıymık, "Muscle fatigue detection in EMG using time frequency methods," ICA and Neural Networks," springer science, 2009.
- [42] A. Yüksel, M. Korurek, "EMG işaretlerinin genetik algoritmalar ve çok Katmanlı yapay sinir ağı ile Sınıflandırılması," Eleco, 2008.
- [43] M. A. Islam, K. Sundaraj, R. B. Ahmad, N. U. Ahamed, "Mechanomyogram for muscle function assesment: A review," PloS one, vol. 8, 2013.
- [44] K. Akataki, K. Mita, M. Watakabe, K. Itoh, "Mechanomyogram and force relationship during voluntary isometric ramp contractions of the biceps brachii muscle," Eur. J. App. Phys., vol. 84, pp. 19-25, 2001.
- [45] P. Madleine, H. Y. Ge, A. Jaskolska, D. Farina, A. Jaskolski, L. A. Nielsen, "Spectral moments of mechanomyographic signals recorded with accelerometer and microphone during sustained fatiguing contractions," Medical and Biological Engineering and Computing, vol. 44, pp. 290-297, 2006.
- [46] H. Han, S. Jo, J. Kim, "Comparative study of a muscle stiffness sensor and electromyography and mechanomyography under fatigue conditions," Medical and Biological Engineering and Computing, vol. 53, pp. 577-588, 2015.
- [47] C. Cescon, D. Farina, M. Gobbo, R. Merletti, C. Orizio, "Effect of accelerometer location on mechanomyogram variables during voluntary, constant-force contractions in three human muscles," Medical and Biological Engineering and Computing, vol. 42, pp. 121-127, 2004.
- [48] C. Orizio, M. Gobbo, B. Diemont, F. Esposito, A. Veicsteinas, "The surface mechanomyogram as a tool to describe the influence of fatigue on biceps brachii motor unit activation strategy. Historical basis and novel evidence," eur. J. App. Phys., vol. 90, pp. 326-36, 2003.
- [49] M. Shinohara, K. Sogaard, "Mechanomyography for studying force fluctuations and muscle fatigue," Exercise and sport sciences," vol. 34, pp. 59-64, 2006.
- [50] P. Madeleine, L. Arendt-Nielsen, "Experimental muscle pain increases mechanomyographic signal activity during sub-maximal isometric contractions," J. Electromyogr. Kinesiol., vol. 15, pp. 27-36, 2005.
- [51] H. B. Xie, Y. P. Zheng, J. Y. Guo, "Classification of mechanomyogram signal using a wavelet packet transform and singular value decomposition for multifunction prosthesis control," Physiological measurement, vol. 30, 2009.
- [52] M. Y. E. Martin, "MMG sensor for muscle activity detection-low cost design, implementation and experimentation," Master's Dissertation, Massey University, Aucland, 2009.
- [53] M. T. Tarata, "Mechanomyography versus electromyography, in monitoring the muscular fatigue," Biomed. Eng. Online, vol. 2, 2003.
- [54] J. Marusiak, A. Jaskolska, K. Sajewicz, G. H. Yue, A. Jaskolski, "EMG and MMG activities of agonist and antagonist muscles in parkinson's disease patients

during absolute submaximal load holding,” J. Electromyogr. Kinesiol., vol. 19, pp. 903-914, 2009.

- [55] L. Qi, J. M. Wakeling, A. Green, K. Lambrecht, M. Ferguson Pell, “Spectral properties of electromyographic signals during isometric ramp and step contractions in biceps brachii,” J. Electromogr.Kinesiol., vol. 21, pp. 128-135, 2011.
- [56] G. Wei, F. Tian, G. Tang, C. Wang, “A wavelet-based method to predict muscle forces from surface electromyography signals in weightlifting,” Journal of Bionic Engineering, vol. 9, pp. 48-58, 2012.
- [57] M. R. Bozkurt, “EMG işaretlerinin modern yöntemlerle önışlemesi ve sınıflandırılması,” Sakarya Üniv., Fen Bilimleri Enstitüsü, Doktora Tezi, 2007.
- [58] X. Guo, P. Yang, L. Chen, X. Wang, L. Li, “Study of the control mechanism of robot prothesis based on the emg processed,” In intelligent Control and Automation. WCICA, pp. 9490-9493, 2006.
- [59] J. Z. Wang, R. C. Wang, M. W. Jiang, D. W. Jin, “Emg signal classification for myoelectric teleoperating a dexterous robot hand,” IEEE-EMBS, 27th Annual International Conference of the IEEE, 2006, pp. 5931-5933.
- [60] K. Lorenz, G. H. Ulrich, “Comparison of algorithms to quantify muscle fatigue in upper limb muscles based on sEMG signals” Medical engineering and Physics, vol. 38, pp. 1260–1269, 2016.
- [61] P. A. Karthick, D. M. Ghosh, S. Ramakrishnan, “Surface electromyography based muscle fatigue detection using high resolution time-frequency methods and machine learning algorithms,” Computer Methods and Programs in Biomedicine, vol. 154, pp. 45–56, 2017, doi:10.1016/j.cmpb.2017.10.024.
- [62] A. Greco, G. Valenza, A. Bicchi, M. Bianchi, E. P. Scilingo, “Assessment of muscle fatigue during isometric contraction using autonomic nervous system correlates” Department of Information Eng. and Research Center, Biomedical. Signal Processing and Control vol. 51, pp. 42–49, 2019.
- [63] P. A. Parker, K. B. Enlehart, B. S. Hudgins, “Control of powered upper limb prostheses, in Electromyography: Physiology, engineering, and noninvasive applications,” IEEE Press, vol. 18, pp. 453-475, 2004.
- [64] M. Asghari Oskoei, H. Hu, “Myoelectric control systems-A survey,” Biomed. Signal Process. Control, vol. 2, pp. 275-294, 2007.
- [65] Z. Tang, K. Zhang, S. Sun, Z. Gao, L. Zhang, Z. Yang, “An upper-limb power-assist exoskeleton using proportional myoelectric control,” Biomedical Sensors and Systems, vol. 14, pp. 6677-6694, 2014, doi:10.3390/s140406677.
- [66] L. Kahl, U. G. Hofmann, “Comparison of algorithms to quantify muscle fatigue in upper limb muscles based on sEMG signals,” Med. Engineering and physics, vol. 38, pp. 1260-1269, 2016, doi:10.1016/j.medengphy.2016.09.009.
- [67] F. Mokaya, R. Lucas, H. Y. Noh, P. Zhang, “Burnout: A Wearable System for Unobtrusive Skeletal Muscle Fatigue Estimation,” 15th ACM/IEEE

International Conference on Information Processing in Sensor Networks, 2016, doi:10.1109/IPSIN.2016.7460661.

- [68] J. Jakubowski, K. Kwiatos, A. Chwaleba, S. Osowski, "Higher order statistics and neural network for tremor recognition," IEEE transaction on Biomed. Engineering, vol. 49, pp. 152-159, 2002, doi:10.1109/10.979354.
- [69] J. A. Burne, M. W. Hayes, V. S. C. Fung, C. Yiannikas, D. Boljevac, "The contribution of tremor studies to diagnosis of Parkinsonian and essential tremor: A statistical evaluation," Journal of Clinical Neuroscience, vol. 9, pp. 237-242, 2002, doi:10.1054/jocn.2001.1017.
- [70] P. Bonato, D. M. Sherrill, D. G. Standaert, S. S. Salles, M. Akay, "Data mining techniques to detect motor fluctuations in parkinson's disease," The 26th annual International Conference of the IEEE Engineering in Med. And. Biol. Society, USA, 2004, doi:10.1109/IEMBS.2004.1404319.
- [71] T. Sonmezocak, S. Kurt, "Detection of EMG signals by neural networks using autoregression and wavelet entropy for bruxism diagnosis," Elektronika IR Elektrotehnika, Vol. 27, pp. 11-21, 2021, doi:10.5755/j02.eie.28838.
- [72] E. M. Scheeren, E. Krueger-Beck, G. Nogueira-Neto, P. Nohama, V. L. S. Nantes Button, "Wrist movement characterization by mechanomyography technique," Journal of Medical and Biological Engineering, vol. 30, pp. 373-380, 2010. doi:10.5405/jmbe.757.
- [73] M. Harrington, R. Daniel, P. Kyberd, "A measurement system for the recognition of arm gestures using accelerometers," Proc. Inst. Mech. Eng. Part: H, Journal of Engineering in Medicine, pp. 129-134, 1995, doi: 10.1243/PIME_PROC_1995_209_330_02.
- [74] C. T. Pan, C. C. Chang, Yu S. Yang, C. K. Yen, Yu H. Kao, Y. L. Shiue, "Development of MMG sensors using PVDF piezoelectricelectro spinning for lower limb rehabilitation exoskeleton," Sensors and Actuators, vol. 301, 2020, doi: 10.1016/j.sna.2019.111708.
- [75] H. Tankisi, D. Burke, L. Cui, M. de Carvalho, S. Kuwabara, S. D. Nandedkar, S. Rutkove, E. Stalberg, M. J.A.M. yan Putten, A. Fuglsang-Frederiksen, "Standards of instrumentation of EMG," Clinical Neurophysiology, vol. 131, pp. 243-258, 2020, doi:10.1016/j.clinph.2019.07.025.
- [76] S. Gaamouri, M. B. Salah, R. Hamdi, "Denoising ECG signals by using extended Kalman filter to train multi-layer perceptron neural network," Auto. Cont. & Com. Sci., vol. 52, 2018, doi:10.3103/S0146411618060044.
- [77] B. R. Manju, M. R. Sneha, "ECG denoising using Wiener filter and Kalman filter," Third International Conference on Computing and Network Communications, pp. 273-281. 2020, doi:10.1016/j.procs.2020.04.029.
- [78] T. Trwiyanto, O. Wahyunggoro, H. A. Nugroho, H. Herianto, "Evaluating the linear regression of Kalman filter model on elbow joint angle estimation using electromyography signal," International Conf. on Sci. and App. Sci., 2018, doi:10.1063/1.5054408.

- [79] T. Triwiyanto, B. G. Iranto, D. G. Hari Wiasana, H. G. Ariswati, et. al. "A modeling of extendend kalman filter to to improve accuracy in elbow joint angle estimation," Journal of Critical Reviews, vol 7, pp. 886-892, 2020, doi:10.31838/jcr.07.12.156.
- [80] T. Triwiyanto, O. Wahyunggoro, H. A. Nugroho, H. Herianto, "Evaluating the performance of Kalman filter on elbow joint angle prediction based on electromyography," International Journal of Precision Engineering And Manufact., vol. 18, pp. 1739-1748, 2017, doi:10.1007/s12541-017-0202-5.
- [81] L. Luciano, Menegaldo, "Real-time muscle state estimation from EMG signals during isometric contractions using Kalman filters," Biological cybernetics, vol. 111, pp. 335-346, 2017, doi:10.1007/s00422-017-0724-z.
- [82] E. İspirgil, "Bruksizme eşlik eden miyofasyal ağrılı bireylerde splint tedavisinin masseter kasındaki hemodinamik değişiklikler üzerine etkilerinin incelenmesi," Doktora Tezi, İstanbul Üniv., Sağlık Bilimleri Ens., Protetik Diş Tedavisi Ana Bilim Dalı, İstanbul, 2014.
- [83] G. Ozcan, "Bruksizmi ve kassal temporomandibular düzensizliği olan bireylerde masseter ve temporal kaslarının ultrasonografik olarak değerlendirilmesi," Uzmanlık Tezi, Erciyes Üniv., Diş Hekimliği Fak., Ağız, Diş ve Çene Radyolojisi Ana Bilim Dalı, Kayseri, 2016.
- [84] K. Arıncı , A. Elhan, "Anatomi," 2. Basım, Güneş Kitabevi, Ankara, 1997.
- [85] Y. Ide, K. Nakazawa, K. Kamimura, "Anatomical Atlas of the Temporomandibular Joint," Chicago: Quintessence Publishing Co. Inc., 1991.
- [86] M. Yıldırım, "Klinik anatomi," Nobel Tıp Kitapevleri, April, 3. Baskı, İstanbul, 37-38, 1998.
- [87] J. Okeson, "Management of temporomandibular disorders and occlusion," 6th. Ed. St. Louis: Mosby, Inc., 2008.
- [88] C. McNeill, "Temporomandibular disorder: Guidelines for classification, assessment and management," 2nd ed. Chicago: Quintessence Publishing Co, Inc, 1993.
- [89] G. Özmen, "Sevkiyal bölgede oluşan kas yorgunluğunun yüzey elektromiyogram bilgileri ile değerlendirilmesi," Yüksek Lisans Tezi, Selçuk Üniv., Fen Bilimleri Ens., Elektrik-Elektronik Müh. Ana Bilim Dalı, Konya, 2013.
- [90] R. S. Snell, "Clinical Neuroanatomy," Lippincott Williams & Wilkins, 7th Edition, 2010.
- [91] B. Biçer, "Sporcularda erektor spinae kas yorgunluğunun işlevsel yakın kızılaltı spektroskopisi ve yüzeysel elektromiyografi ile değerlendirilmesi," Doktora Tezi, Marmara Üniv., Beden Eğitimi ve Spor Ana Bilim Dalı, İstanbul, 2011.
- [92] R. M. Rangayyan, "Biyomedical signal analaysis: A case study approach," IEEE, 2002.

- [93] E. Yazgan, M. Korurek, "Tıp elektroniği," İstanbul Teknik Üniv., Elektrik-Elektronik Fakültesi, 1996.
- [94] V. B. Mountcastle, "Medical physiology," 14th ed. St. Louis, C.V. Mosby, 1980.
- [95] J. D. Bronzino, "Biomedical engineering fundamentals" CRC Press, 2006.
- [96] U. Özyılmaz Uğur, "Yüzücülerde kas yorgunluğunun skapular kinematiğe ve fonksiyonelliğe etkisi," Yüksek Lisans Tezi, Hacettepe Üni., Sağlık Bilimleri Ens., Ankara, 2018.
- [97] K. Coşkun, "Evaluation of muscle fatigue using surface electromyogram and mechanomyogram signals." MSc Thesis, Fatih Univ. Institute of Biomedical Engineering, Istanbul, 2014.
- [98] Mems Gyroscope[çevrimiçi]Available: <https://howtomechatronics.com/how-it-works/electrical-engineering/mems-accelerometer-gyroscope-magnetometer-arduino/> (20.06.2021 tarihinde erişilmiştir).
- [99] T. Castroflorio, D. Farina, A. Bottin, M. G. Piacino, P. Bracco, R. Merletti, "Surface EMG of jaw elevator muscles: effect of electrode location and inter-electrode distance," J. Oral Rehabil., vol. 32, pp. 411– 417, 2005, doi:10.1111/j.1365-2842.2005.01442.x.
- [100] B. Afsharipour, S. Soedirdjo, R. Merletti, "Two-dimensional surface EMG: The effects of electrode size, interelectrode distance and image truncation," Biomedical Signal Processing and Control, vol. 49, pp. 298–307, 2019, doi:10.1016/j.bspc.2018.12.001.
- [101] Analog Devices, Inc., 1999, "AD624 Precision Instrumentation Amplifier," Datasheet.
- [102] I. Fadlollah, A. Mechaqrane, A. Ahaitouf, "Butterworth lowpass filter design using evolutionary algorithm," IEEE 2017 International conference on Wireless Tech., Embedded and Intelligent Systems (WITS) 978-1-5090-6681-0/17, 2017.
- [103] W. M. Laghari, M. U. Baloch, M. A. Mengal, S. J. Shah, "Performance analysis of analog Butterworth lowpass filter as compared to Chebyshev type-I filter, Chebyshev type-II filter and elliptical filter," Circuits and Systems, 2014, pp. 209-216.
- [104] H. J. Hwangi, J. M. Hahne, K. R. Muller, "Real-time robustness evaluation of regression based myoelectric control against arm position change and donning/doffing," J. Plos ONE 12(11), 2017, doi:10.1371/journal.
- [105] S. F. Dworkin, "Research diagnosis criteria for temporomandibular disorder: Current status & future relevance," J. Oral Rehabil., vol. 37, pp.734-743, 2010, doi:10.1111/j.1365-2842.2010.02090.x.
- [106] A. Phinyomark, P. Phukpattaranont, C. Limsakul, "Feature reduction and selection for EMG signal classification," Expert Systems with App., vol. 39, pp. 7420-7431, 2012, doi:10.1016/j.eswa.2012.01.102.

- [107] M. Zecca, S. Micera, M. C. Carrozza, P. Dario, "Control of multifunctional prosthetic hands by processing the electromyographic signal," *Critical Reviews in Biomedical Engineering*, pp. 459-485, 2002.
- [108] A. Pinyomark, F. Quaine, S. Charbonnier, C. Serviene, F. Tarpin-Bernanrd, Y. Laurilleu, "EMG feature evaluation for improving myoelectric pattern recognition robustness," *Expert Systems with Appl.*, pp. 4832-4840, 2013.
- [109] C. J. M. Miller, "Real-time feature extraction and classification of prehensile EMG signals," Yüksek Lisans Tezi, Department of Computer Science, San Diego State University, San Diego, 2008.
- [110] A. Phinyomark, C. Limsakul, P. Phutpattaranont, "Application of wavelet analysis in EMG feature extraction for pattern classification," *Meas. Sci. Rev.* vol. 11, pp. 45-52, 2011, doi:10.2478/v10048-011-0009-y.
- [111] K. S. Kim, H. H. Choi, C.S. Moon, C. W. Mun, "Comparison of k-nearest neighbor, quadratic discriminant and linear discriminant analysis in classification of electromyogram signals based on the wrist-motion directions," *Current App. Phys.*, vol. 11, pp. 740-745, 2011. 10.1016/j.cap.2010.11.051.
- [112] B. Hudgins, P. A. Parker, R. N., "A new strategy for multifunction myoelectric control," *IEEE Transactions on Biomed. Engineering*, vol. 40, pp. 82-94, 1993.
- [113] T. Sonmezocak, S. Kurt, "Machine learning and regression analysis for diagnosis of bruxism by using EMG signals of jaw muscles," *Biomedical Signal Processing and Control*, vol. 69, 2021, doi:10.1016/j.bspc.2021.102905.
- [114] A. Datteo, F. Luca, G. Busca, "Statistical pattern recognition approach for longtime monitoring of the G. Meazza stadium by means of AR models and PCA," *Eng. Struct.*, vol. 153, pp. 317-333, 2017, doi:10.1016/j.engstruct.2017.10.022.
- [115] P. Saha, S. Ghorai, B. Tudu, R. Bandyopadhyay, N. Bhattacharyya, "Tea quality prediction by autoregressive modeling of electronic tongue signals," *IEEE Sens. J.*, vol. 16, pp. 4470-4477, 2016, doi: 10.1109/JSEN.2016.2544979.
- [116] A. Datteo, G. Busca, G. Quattromani, A. Cigada, "On the use of AR models for SHM: A global sensitivity and uncertainty analysis framework," *Reliab. Eng. Syst. Safe.*, vol. 170, pp. 99-115, 2018, doi: 10.1016/j.ress.2017.10.017.
- [117] M. Shannon, H. Zen, W. Byrne, "Autoregressive models for statistical parametric speech synthesis," *IEEE. Trans. on Audio, Speech, and Language Processing*, vol. 21, pp. 587-597, 2013, doi: 10.1109/TASL.2012.2227740.
- [118] L. F. Sommer, C. Barreira, C. Noriega, F. Camargo-Junior, R. T. Moura, A. Forner-Cordero, "Elbow joint angle estimation with surface electromyography using autoregressive models," in *Proc. of 2018 40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, USA, 2018, pp. 1472- 1475, doi:10.1109/EMBC.2018.8512512.
- [119] A. M. Khan, Y. K. Lee, T. S. Kim, "Accelerometer signal-based human activity recognition using augmented autoregressive model coefficients and artificial

neural nets,” in Proc. of 30th Annual International IEEE EMBS Conference, Vancouver, British Columbia, Canada, 2008, pp. 5172–5175, doi: 10.1109/IEMBS.2008.4650379.

- [120] B. Karlık, Y. Koçyiğit, B. C. Fidan, “EMG işaretlerin sınıflamada kullanılan işaret işleme tekniklerinin karşılaştırılması, SIU2005, 2005, Kayseri.
- [121] E. Yazgan, M. Korurek, “Tıp Elektronik,” İstanbul Teknik Üniversitesi, Elektrik Elektronik Fakültesi, 1996.
- [122] S. Ertürk, S., “Sayısal işaret işleme,” Birsen yayınevi, 2005.
- [123] J. L. Semmlow, “Biosignal and biomedical image processing matlab-based applications,” Marcel Dekker Inc., 2004.
- [124] İ. Türkoğlu, “Durağan olmayan işaretler için zaman-frekans entropilerine dayalı akıllı örüntü tanıma,” Doktora Tezi, Fırat Üniversitesi Fen Bilimleri Enstitüsü, 2002.
- [125] N. Arı, Ş. Özen, Ö. H. Çolak, “Dalgacık Teorisi (Wavelet),” Palme yayıncılık, Ankara, pp. 23-50, 2008.
- [126] J. L. Semmlow, “Biosignal and biomedical image processing matlab-based applications,” Marcel Dekker Inc., 2004.
- [127] M. Mansouri, A. Al-khazraji, M. Hajji, M. F. Harkat, H. Nounou, M. Nounou, “Wavelet optimized EWMA for fault detection and application to photovoltaic systems,” Solar Energy, vol. 167, pp. 125–136, 2018.
- [128] U. Libal, Z. Hasiewicz, “Risk upper bound for a NM-type multiresolution classification scheme of random signals by Daubechies wavelets,” Eng. App. of Artificial Intelligence, vol. 62, pp. 109–123, 2017, doi: 10.1016/j.engappai.2017.04.005.
- [129] Y. Qin, Y. Mao, and B. Tang, “Multicomponent decomposition by wavelet modulus maxima and synhronous detection,” Mech. Systems and Signal Processing, vol. 91, pp. 57-80, 2017, doi: 10.1016/j.ymssp.2017.01.002.
- [130] R. V. Fonseca, A. Pinheiro, “Wavelet estimation of the dimensionality of curve time series”, Annals of the Institute of Statistical Mathematics, vol. 72, no. 5, pp. 1175–1204, 2020, doi: 10.1007/s10463-019-00724-4.
- [131] I. Daubechies, “Ten lectures on wavelets,” Society for Industrial and Applied Mathematics, Pennsylvania, 1992, doi:10.1137/1.9781611970104.
- [132] S. Mallat, “A theory for multiresolution signal decomposition: The wavelet representation. Pattern analysis and machine intelligence,” IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 11, no. 7, pp. 674–693, 1989, doi:10.1109/34.192463.
- [133] C. Busch, “Wavelet based texture segmentation of multi modal tomographic images,” Computers & Graphics, vol. 21, no. 3, pp. 347–358, 1997, doi:10.1016/S0097-8493(97)00012-5.

- [134] Z. Gao, S. Li, Q. Cai, W. Dang, Y. Yang, C. Mu, P. Hui, "Relative wavelet entropy complex network for improving EEG-based fatigue driving classification," *IEEE Trans. on Inst. and Meas.*, vol. 68, no. 7, pp. 2491–2497, 2019, doi:10.1109/TIM.2018.2865842.
- [135] J. Chen, G. Li, "Tsallis wavelet entropy and its application in power signal analysis," *Entropy*, vol. 16, pp. 3009–3025, 2014, doi:10.3390/e16063009.
- [136] J. Chen, Y. Dou, Y. Li, J. Li, "Application of Shannon wavelet entropy and Shannon wavelet packet entropy in analysis of power system transient signals," *Entropy*, vol. 18, 2016, doi:10.3390/e18120437.
- [137] E. Öztemel, "Yapay Sinir Ağları," Papatya Yayıncılık, İstanbul, 2003.
- [138] W. S. McCulloch, W. A. Pitts, "A logical calculus of the ideas immanent in nervous activity," *The Buttetin of Mathematical Biophysics*, 5(4), 115-133, 1943.
- [139] D. O. Hebb, "The first stage of perception: Growth of the assembly. The organization of behaviour," vol. 60-78, 1949.
- [140] J. J. Hopfield, "Neural networks and physical systems with emergent collective computational abilities," *Proceedings of the National Academy of Sciences*, vol. 79, pp. 2554-2558, 1982.
- [141] M. Ö. Efe, O. Kaynak, "Yapay Sinir Ağları ve Uygulamaları," Boğaziçi Üniversitesi Yayınevi, İstanbul, 2000.
- [142] Ç. Elmas, "Yapay Sinir Ağları," Seçkin Yayıncılık, İstanbul, 2003.
- [143] S. Haykin, S., N. Network, "Neural Networks," A Compherensive foundation, Prentice Hall, 2004.
- [144] Z. Man, H. R. Wu, S. Liu, X. Yu, "A new adaptive backpropagation algorithm based on Lyapunov stability theory for Neural Networks," *Neural Networks, IEEE Transaction on*, vol. 17, pp. 1580-1591, 2006.
- [145] C. M. Bishop, "Neural Networks for Pattern Recognition," Oxford University Press, 1995.
- [146] T. L. Fine, "Feedforward neural network methodology," Springer Science & Business Media, 2006.
- [147] N. Nazmi, M. A. Abdul Rahman, S. I. Yamamoto, and S. A. Ahmad, "Walking gait event detection based on electromyography signals using artificial neural network," *Biomedical Signal Processing and Control*, vol. 47, pp. 334–343, 2019, doi: 10.1016/j.bspc.2018.08.030.
- [148] A. Graves, M. Liwicki, S. Fernandez, R. Bertolami, H. Bunke, J. Schmidhuber, "A novel connectionist system for unconstrained handwriting recognition," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 31, pp. 855–868, 2009, doi:10.1109/ TPAMI. 2008.137.
- [149] N. Wang, E. Ambikairajah, N. H. Lovell, B. G. Celler, "Accelerometry based classification of walking patterns using time-frequency analysis," in *Proc, of*

2007 29th Annual IEEE International Conference on Engineering in Medicine and Biol. Society, 2007, pp. 4899–4902, doi:10.1109/IEMBS.2007.4353438.

- [150] B. M. Wilamowski, H. Yu, “Improved computation for Levenberg–Marquardt training,” *IEEE Transactions on Neural Networks*, vol. 21, pp. 930–937, 2010, doi:10.1109/TNN.2010.2045657.
- [151] M. A. Cavuslu, S. Sahin, “FPGA implementation of ANN training using Levenberg and Marquardt algorithms,” *Neural Network World*, vol. 2, pp. 161–178, 2018, doi:10.14311/NNW.2018.28.010.
- [152] L. S. Ngia, J. Sjoberg, “Efficient training of neural nets for nonlinear adaptive filtering using a recursive Levenberg-Marquardt algorithm,” *Signal Processing, IEEE Trans. on*, vol. 48, pp. 1915-1927, 2000.
- [153] E. Alpaydin, “Introduction to machine learning,” MIT press, 2014.
- [154] Y. Özkan, “Veri madenciliği yöntemleri,” Papatya Yayıncılık, 2008.
- [155] J. Yang, J. Y. Yang, “Why can LDA be performed in PCA transformed space?,” *Pattern Recognition*, vol. 36, pp. 563-566, 2003.
- [156] B. Karlik, “Machine learning algorithms for characterization of EMG signals,” *International Journal of Information and Elec. Eng.*, vol. 4, pp. 189-194, 2014.
- [157] M. Coşkun, “Dört rotorlu insansız hava aracı ile sürekli uyarlamalı ortalama kayma algoritması,” *Yüksek Lisans Tezi, Fırat Üniv. Fen Bilimleri Enst., Elektrik-Elektronik Müh. Ana Bilim Dalı, Elektronik Prog.*, 2015.
- [158] M. O. Akı, “Sürücü uykuğunun gerçek zamanlı görüntü işleme ve makine öğrenmesi teknikleri ile tespitine yönelik bir sistem tasarımı ve uygulaması,” *Doktora Tezi, Trakya Üniv., Fen Bilimleri Enst., Bilgisayar Müh. Ana Bilim Dalı*, 2017.
- [159] P. D. H. Akpınar, Akpınar, “Data veri madenciliği veri analizi,” Papatya Yayıncılık, 2014.
- [160] A. McCallum, K. Nigam, “A comparison of event models for native Bayes text classification,” *AAAI-98 workshop on learning for text categorization*, pp. 41-48, 1998.
- [161] I. Rish, “An empirical study of the native Bayes classifier,” *IJCAI 2001 workshop on empirical methods in artificial intelligence*, pp. 41-46, 2001.
- [162] G. H. John, P. Langley, “Estimating continuous distributions in Bayesian classifiers,” *Proceedings of the Eleventh conference on Uncertainty in artificial intelligence*, pp. 338-345, 1995.
- [163] E. Dönmez, “Designing controllers for path planning applications to mobile robots with head-cameras,” *Ph.D. Thesis, İnönü Univ., Graduate School of Science and Tech., Computer Engineering Department*, 2018.
- [164] J. Too, A.R. Abdullah, N. M. Saad, W. Tee, “EMG feature selection and classification using a pbest-guide binary particle swarm optimization,” *Computation*, 2019, doi:3390,7,12,2019.

- [165] D. Kaya, M. Turk, "Interpretation of disorder Diagnosis in bioelectrical signals," Science & Eng. J of Firat Univ., vol. 29, pp. 263-269, 2017.
- [166] M. Maeda, T. Yamaguchi, S. Mikami, W. Yachida, T. Saito, T. Sakuma, H. Nakamura, M. Mizuno, K. Yamada, K. Satoh, "Validity of single-channel masseteric electromyography by using an ultraminiature wearable electromyographic device for diagnosis of sleep bruxism," journal of prosthodontic research, vol. 64, pp. 90–97, 2020, doi:10.1016/j.jpor.2019.04.
- [167] M. V. Artega, J. C. Castiblanco, I. F. Mondragon, J. D. Colorado, C. Alvarado-Rojas, "EMG-driven hand model based on the classification of individual finger movements," Biomedical Signal Processing and Control, 101834, 58(2020). doi:10.1016/j.bspc.2019.101834.
- [168] J. Dohnal, "Using of Levenberg-Marquardt method in identification by neural networks," Student EEICT 2004, pp. 361-365, 2004.
- [169] R. Sameni, M. B. Shamsollahi, C. Jutten, M. Babaie-Zadeh, "Filtering noisy ECG signals using the extended Kalman filter based on a dynamic ECG model," Computers in Cardiology:1017-1020, 2005.
- [170] R. A. Sayyad, K. Mundada, "Enhancement and denoising of ECG signal using extended Kalman filter and extended Kalman smoother," J. Innovation Electron. Commun. Eng., vol. 6, pp. 22-26, 2016.
- [171] V. P. Rachim, S.C. Kang, W. Y. Chung, T. H. Kwon, "Implementation of extended Kalman filter for realtime noncontact ECG signal acquisition in android-based mobile monitoring system," J. Sensor Sci. Technol., vol. 23, pp. 7-14, 2014.
- [172] T. Sonmezocak, S. Kurt, "Filtering accelerometer and electromyography signals using extended Kalman filter on lower jaw muscle activities," 1st. International Congress on Engineering Sciences and Multidisciplinary Approaches, E-ISBN: 978-605-7594-91-4, 23-24 February 2021, pp. 383-389.
- [173] M. Hagberg, "Work load and fatigue in repetitive arm elevations," Ergonomics, vol. 24, pp. 543–555, 1981, doi:10.1080/00140138108924875.
- [174] S. Petrofsky, R. M. Glaser, C. A. Phillips, A. R. Lind, C. Williams, "Evaluation of amplitude and frequency components of the surface EMG as an index of muscle fatigue," Ergonomics, vol. 25, pp. 213–223, 1982, doi:10.1080/00140138208924942.

A

ETİK KURUL RAPORU



T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
Araştırma ve Planlama Rektör Yardımcılığı

Sayı : 73613421-604.01.02-E.2009030417
Konu : Etik Kurul Kararı 2020/7

Tarih: 03.09.2020

Sn. Temel Sönmezocak

YTÜ Etik Kurulu, Üniversitemiz doktora öğrencisi olarak hazırlanmış olduğunuz **“Kas Yorgunluğu Algılama ve Destek Sistem Tasarımı”** başlıklı projenizi etik açıdan incelemiştir. Sunulan dosya ve bu dosyaya göre yapılacak olan veri toplama araç ve yöntemlerine konu olan bilgiler hakkında etiğe aykırı herhangi bir bulguya rastlanmamıştır. Bilgilerinize rica ederim.

Prof. Dr. Bestami ÖZKAYA
Rektör a.
Rektör Yardımcısı

Eki: Temel Sönmezocak.pdf (Elektronik Ek)



YILDIZ TEKNİK ÜNİVERSİTESİ
Akademik Etik Kurul

Toplantı Tarihi: 01.09.2020

Toplantı No:2020/07

AKADEMİK ETİK KURUL TOPLANTI KARARI

Yürütücülüğünü Üniversitemiz Elektrik Elektronik Fakültesi öğretim üyelerinden Dr. Öğr. Üyesi Serkan Kurt'un danışmanlığında doktora öğrencisi Temel Sönmezocak'ın yapacağı "Kas Yorgunluğu Algılama ve Destek Sistem Tasarımı" adlı çalışma ve bu çalışmada kullanılacak veri toplama araçları ve yöntemlerine ilişkin bilgilerde etige aykırı herhangi bir bulguya rastlanmamıştır.

Akademik Kurul Üyeleri

Prof. Dr. Abdürrezzak E. BOZDOĞAN
Başkan

Prof. Dr. Nihan ÇETİN DEMİREL
Başkan Yardımcısı

Prof. Dr. Kenan AYDIN
Üye

Prof. Dr. Adem BAKKALOĞLU
Üye

Prof. Dr. Erhan ALTAN
Üye

Bu belge 5070 sayılı elektronik imza kanununa göre güvenli elektronik imza ile imzalanmıştır.
<http://ebys.yildiz.edu.tr/Dogrulama/Index?EvrakNo=E.2009030417&ErisimKodu=01f7ea9>

Konferans Bildirileri

1. T. Sonmezocak, S. Kurt, "Filtering accelerometer and electromyography signals using extended Kalman filter on lower jaw muscle activities," 1st. International Congress on Engineering Sciences and Multidisciplinary Approaches, E-ISBN: 978-605-7594-91-4, 23-24 February 2021, pp. 383-389.

Makaleler

1. T. Sonmezocak, S. Kurt, "Machine learning and regression analysis for diagnosis of bruxism by using EMG signals of jaw muscles," Biomedical Signal Processing and Control, vol. 69, 2021, doi:10.1016/j.bspc.2021.102905.
2. T. Sonmezocak, S. Kurt, "Detection of EMG signals by neural networks using autoregression and wavelet entropy for bruxism diagnosis," Elektronika IR Elektrotehnika, Vol. 27, pp. 11-21, 2021, doi:10.5755/j02.eie.28838.

Projeler

1. Bruksizm Tanı ve Tedavi Sistem Geliştirilmesi isimli Yıldız Teknik Üniversitesi Teknopark Projesi, Proje Kodu: G022020, Proje Geçerlilik Tarihi: 01.02.2020-25.01.2021, Projedeki Görevi: AR-GE araştırma faaliyetleri.