



**T.C.
ONDOKUZ MAYIS ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANA BİLİM DALI**

**MYO BİLEKLİK KULLANILARAK ALINAN PARMAK
HAREKETLERİNE AİT EMG İŞARETLERİNİN MAKİNE
ÖĞRENME YÖNTEMLERİ İLE SINIFLANDIRILMASI**

Yüksek Lisans Tezi

Muhammed ERDİM

Danışman
Dr. Öğr. Üyesi Cengiz TEPE

SAMSUN
2021

T.C.
ONDOKUZ MAYIS ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANA BİLİM DALI



**MYO BİLEKLİK KULLANILARAK ALINAN PARMAK
HAREKETLERİNE AİT EMG İŞARETLERİNİN MAKİNE
ÖĞRENME YÖNTEMLERİ İLE SINIFLANDIRILMASI**

Yüksek Lisans Tezi

Muhammed ERDİM

Danışman
Dr. Öğr. Üyesi Cengiz TEPE

SAMSUN
2021

TEZ KABUL VE ONAYI

Muhammed ERDİM tarafından, Dr. Öğr. Üyesi Cengiz TEPE danışmanlığında hazırlanan “Myo Bileklik Kullanılarak Alınan Parmak Hareketlerine Ait EMG İşaretlerinin Makine Öğrenme Yöntemleri İle Sınıflandırılması” başlıklı bu çalışma, jürimiz tarafından 02.02.2021 tarihinde yapılan sınav sonucunda oy birliği ile başarılı bulunarak Yüksek Lisans Tezi olarak kabul edilmiştir.

	Unvanı Adı Soyadı Üniversitesi Ana Bilim/Ana Sanat Dalı	İmza	Sonuç
Başkan	Dr. Öğr. Üyesi İlyas EMİNOĞLU		<input checked="" type="checkbox"/>
	Ondokuz Mayıs Üniversitesi Elektrik Elektronik Mühendisliği Anabilim Dalı		Kabul <input type="checkbox"/> Ret
Üye (Danışman)	Dr. Öğr. Üyesi Cengiz TEPE		<input checked="" type="checkbox"/>
	Ondokuz Mayıs Üniversitesi Elektrik Elektronik Mühendisliği Anabilim Dalı		Kabul <input type="checkbox"/> Ret
Üye	Dr. Öğr. Üyesi Ahmet TURAN		<input checked="" type="checkbox"/>
	Samsun Üniversitesi Biyomedikal Mühendisliği Anabilim Dalı		Kabul <input type="checkbox"/> Ret

Bu tez, Enstitü Yönetim Kurulunca belirlenen ve yukarıda adları yazılı jüri üyeleri tarafından uygun görülmüştür.

ONAY

... / ... / ...

Prof. Dr. Ali BOLAT
Enstitü Müdürü

BİLİMSEL ETİĞE UYGUNLUK BEYANI

Hazırladığım yüksek lisans/doktora/sanatta yeterlik tezinin bütün aşamalarında bilimsel etiğe ve akademik kurallara riayet ettiğimi, çalışmada doğrudan veya dolaylı olarak kullandığım her alıntıya kaynak gösterdiğimi ve yararlandığım eserlerin Kaynaklar'da gösterilenlerden oluştuğunu, her unsurun enstitü yazım kılavuzuna uygun yazıldığını ve TÜBİTAK Araştırma ve Yayın Etiği Kurulu Yönetmeliği'nin 3. bölüm 9. maddesinde belirtilen durumlara aykırı davranılmadığını taahhüt ve beyan ederim.

İmza

... / ... / 20...

Muhammed ERDİM

TEZ ÇALIŞMASI ÖZGÜNLÜK RAPORU BEYANI

Tez Başlığı : Myo Bileklik Kullanılarak Alınan Parmak Hareketlerine Ait EMG İşaretlerinin Makine Öğrenme Yöntemleri İle Sınıflandırılması

Yukarıda başlığı belirtilen tez çalışması için şahsım tarafından 25.12.2020 tarihinde intihal tespit programından alınmış olan özgünlük raporu sonucunda;

Benzerlik oranı : % 5

Tek kaynak oranı : % 1 çıkmıştır.

İmza

... / ... / 20...

Dr. Öğr. Üyesi Cengiz Tepe

ÖZET

MYO BİLEKLİK KULLANILARAK ALINAN PARMAK HAREKETLERİNE AİT EMG İŞARETLERİNİN MAKİNE ÖĞRENME YÖNTEMLERİ İLE SINIFLANDIRILMASI

Muhammed ERDİM

Ondokuz Mayıs Üniversitesi

Lisansüstü Eğitim Enstitüsü

Elektrik-Elektronik Mühendisliği Ana Bilim Dalı

Yüksek Lisans, Şubat/2021

Danışman: Dr. Öğr. Üyesi Cengiz TEPE

Kaslar hareket yapabilmemizi sağlayan temel yapı taşlarından biridir. Kasların kasılması ve gevşemesi sonucunda biyoelektriksel işaretler oluşmakta ve biyoelektriksel işaretler hareket oluşumunu sağlamaktadır. Bu işaretler elektrotlar ile ölçülerek yüzey Elektromiyogram (EMG) işareti elde edilmektedir. Yüzey EMG işaretlerinin işlenmesiyle insan hareketleri taklit edilebilmekte ve birçok farklı alanda kullanılabilir. Bu çalışmada bu görüş ön planda tutularak parmak hareketlerinin bağımsız hareket edebilmesi amacıyla işaretler çevrimdışı ve gerçek zamanlı sınıflandırılarak modeller önerilmiştir. Yüzey EMG ve jiroskop işaretleri myo bileklik kullanılarak alınmıştır. Veri seti 10 kişiden alınan 6 parmak hareketinden oluşturulmuştur. Bu 6 hareket başparmak, işaret parmak, orta parmak, serçe parmak, yüzük parmak ve dinlenme hareketidir. Veri seti filtrelenmiş, hareketin yapıldığı kısım belirlenmiş ve pencereleme işlemi uygulanmıştır. Öznitelik matrisinde 17 adet öznitelik kullanılmıştır. Ardışıl ileri yönlü öznitelik seçimi yöntemi ile en yüksek başarımlı gösteren öznitelik grubu belirlenmiştir. Matlab® içerisinde bulunan sınıflandırma öğreticisi uygulaması ve sinir ağı örüntü tanıma aracı kullanılarak sınıflandırma yapılmıştır. Çevrimdışı sınıflandırmada dört model önerilmiştir. İlk modelde yüzey EMG verileri ile CSVM sınıflandırıcısı kullanılarak %91.56 başarımlı elde edilmiştir. İkinci modelde yüzey EMG ve jiroskop verileri ile CSVM sınıflandırıcısı kullanılarak %92.56 başarımlı elde edilmiştir. Üçüncü modelde yüzey EMG verileri ile YSA'nın CGB eğitim algoritması kullanılarak yapılan sınıflandırmada %94.4 başarımlı elde edilmiştir. Son modelde yüzey EMG ve jiroskop verileri ile YSA'nın SCG eğitim algoritması kullanılarak yapılan sınıflandırmada %96.3 başarımlı elde edilmiştir. Gerçek zamanlı sınıflandırmada eğitim seti için çevrimdışı olarak sınıflandırılan model seçilmiştir. Test seti için myo bileklikten anlık veriler alınarak sınıflandırma yapılmıştır. Tüm veri setini kullanarak oluşturulan modelde başarımlı %90.36'dır. Bireysel veri seti kullanılarak oluşturulan modelde başarımlı %98.33'dür.

İnsan eli, parmakların farklı hareket kabiliyetleri sayesinde birçok el hareket kombinasyonu gerçekleştirebilmektedir. Bu nedenle protez ellerde parmakların birbirinden bağımsız hareket edebilmesiyle farklı el hareketlerini yapabilmeleri kolaylaşabilecektir. Bu çalışmada bu görüş ön planda tutularak parmak hareketlerinin bağımsız hareket edebilmesi amacıyla işaretler çevrimdışı ve gerçek zamanlı sınıflandırılarak modeller önerilmiştir. Yüzey EMG ve jiroskop işaretleri myo bileklik kullanılarak alınmıştır. Veri seti 10 kişiden alınan 6 parmak hareketinden oluşturulmuştur. Bu 6 hareket başparmak, işaret parmak, orta parmak, serçe parmak, yüzük parmak ve dinlenme hareketidir. Veri seti filtrelenmiş, hareketin yapıldığı kısım belirlenmiş ve pencereleme işlemi uygulanmıştır. Öznitelik matrisinde 17 adet öznitelik kullanılmıştır. Ardışıl ileri yönlü öznitelik seçimi yöntemi ile en yüksek başarımlı gösteren öznitelik grubu belirlenmiştir. Matlab® içerisinde bulunan sınıflandırma öğreticisi uygulaması ve sinir ağı örüntü tanıma aracı kullanılarak sınıflandırma yapılmıştır. Çevrimdışı sınıflandırmada dört model önerilmiştir. İlk modelde yüzey EMG verileri ile CSVM sınıflandırıcısı kullanılarak %91.56 başarımlı elde edilmiştir. İkinci modelde yüzey EMG ve jiroskop verileri ile CSVM sınıflandırıcısı kullanılarak %92.56 başarımlı elde edilmiştir. Üçüncü modelde yüzey EMG verileri ile YSA'nın CGB eğitim algoritması kullanılarak yapılan sınıflandırmada %94.4 başarımlı elde edilmiştir. Son modelde yüzey EMG ve jiroskop verileri ile YSA'nın SCG eğitim algoritması kullanılarak yapılan sınıflandırmada %96.3 başarımlı elde edilmiştir. Gerçek zamanlı sınıflandırmada eğitim seti için çevrimdışı olarak sınıflandırılan model seçilmiştir. Test seti için myo bileklikten anlık veriler alınarak sınıflandırma yapılmıştır. Tüm veri setini kullanarak oluşturulan modelde başarımlı %90.36'dır. Bireysel veri seti kullanılarak oluşturulan modelde başarımlı %98.33'dür.

Parmak verileri işlenerek protez kol ve sanal el kontrolü için yüksek başarımlı veren modeller önerilmiştir. Bu modeller protez kollar ve sanal el kontrolleri için uygulanabilir bir yapıdadır. Parmak verilerinin işlenmesiyle protez kol işlevselliğinin artırılacağı tahmin edilmektedir.

Anahtar Sözcükler: Yüzey EMG, Jiroskop, Myo Bileklik, Veri İşleme ve Sınıflandırma, Parmak Hareketleri

ABSTRACT

CLASSIFICATION USING MACHINE LEARNING METHODS OF FINGER GESTURE EMG SIGNALS ACQUIRED WITH MYO ARMBAND

Muhammed ERDİM

Ondokuz Mayıs University

Institute of Graduate Studies

Department of Electric Electronic Engineering

Master, February/2021

Supervisor: Asist. Prof. Dr. Cengiz TEPE

Muscles are one of the basic building blocks that enable us to move. As a result of the contraction and relaxation of the muscles, bioelectrical signals are formed and the bioelectrical signals provide the formation of movement. Surface Electromyogram (EMG) signal is obtained by measuring these marks with electrodes. Human gestures can be imitated by processing surface EMG signals and can be used in many different areas.

The human hand can perform many hand gesture combinations thanks to the different mobility of the fingers. For this reason, it will be easier for the fingers to move independently of each other in prosthetic hands and to perform different hand gestures. In this study, by keeping this view in the foreground, models are proposed by classifying the signals offline and in real time in order to make finger gestures move independently. Surface EMG and gyroscope signals were received using the myo armband. The data set consists of 6 finger gestures taken from 10 people. These 6 movements are the thumb, index finger, middle finger, ring finger, little finger and rest. The data set was filtered, the part where the gesture was made was determined and the windowing process was applied. 17 features are used in the feature matrix. The most successful feature group was determined with the sequential forward feature selection method. Classification was made using the Classification Learner App and Neural Network Pattern Recognition Tool in Matlab®. Four models have been proposed for offline classification. In the first model, 91.56% performance was achieved by using surface EMG data and CSVM classifier. In the second model, 92.56% performance was achieved by using surface EMG and gyroscope data and CSVM classifier. In the third model, a 94.4% performance was achieved in the classification made by using surface EMG data and ANN's CGB training algorithm. In the last model, a performance of 96.3% was achieved in the classification made using the surface EMG and gyroscope data and the SCG training algorithm of ANN. In real-time classification, the offline classified model was chosen for the training set. For the test set, instant data was taken from the myo armband and classified. The performance is %90.36 in the model created by using the whole data set. In the model created using the individual data set, the performance is 98.33%.

High performance models have been proposed for prosthetic arm and virtual hand control by processing finger data. These models are applicable for prosthetic arms and virtual hand controls. It is estimated that prosthetic arm functionality will be increased by processing finger data.

Keywords: Surface EMG, Gyroscope, Myo Armband, Data Processing and Classification, Finger Gestures

TEŞEKKÜR

Bu tez çalışmasında, her türlü yardımını esirgemeyen, myo bilekliği tedarik etmemi sağlayan, planlama, araştırma ve yürütme aşamalarında bilgi ve tecrübelerinden yararlandığım, danışmanlığımı yürüten değerli hocam Dr. Öğr. Üyesi Cengiz TEPE'ye, çalışmalarım da bana yardımcı ve destek olan değerli arkadaşım Mehmet Can DEMİR'e en içten saygı ve teşekkürlerimi sunarım.

Hayatımın her aşamasında mutluluklarımı ve hüznlerimi paylaşan sevgili aileme maddi ve manevi desteklerinden dolayı içtenlikle teşekkür ederim.

Muhammed ERDİM



İÇİNDEKİLER

1. GİRİŞ.....	1
1.1. Tezin Amacı.....	1
1.2. Tezin Kapsamı.....	1
2. KURAMSAL TEMELLER VE KAYNAK ÖZETLERİ.....	2
2.1. Kaynak Özetleri.....	2
2.2. Yüzeysel Elektromiyogram İşareti Yapısı.....	7
2.2.1. Kaslarının Yapısı.....	7
2.2.2. Kasların Çeşitleri ve Kasılması.....	8
2.2.2.1. Çizgili Kaslar.....	8
2.2.2.2. Düz Kaslar.....	9
2.2.2.3. Kalp Kası.....	9
2.2.3. Motor Ünite ve Motor Hareketi.....	9
2.2.4. Kaslarda Servo Mekanizması.....	10
2.2.5. Kas Hareketleri Sonucunda Biyolojik İşaretin Oluşumu.....	11
2.2.6. Ön Koldaki Kaslar.....	12
3. MATERYAL VE YÖNTEM.....	13
3.1. Myo Bileklik.....	13
3.2. İşaretlerin Ölçülmesi ve Kaydedilmesi.....	14
3.3. İşaretlerin Filtrelenmesi.....	16
3.4. Ön İşleme.....	17
3.4.1. Hareketin Yapıldığı Kısımın Belirlenmesi.....	17
3.4.2. Pencereleme Bölme.....	19
3.4.2.1. Örtüşen pencereleme ayırma yöntemi.....	19
3.4.2.2. Bitişik pencereleme ayırma yöntemi.....	20
3.5. Öznitelik Çıkarma.....	20
3.5.1. Ortalama Mutlak Değer.....	21
3.5.2. Geliştirilmiş Ortalama Mutlak Değer.....	22
3.5.3. Modifiye Edilmiş Ortalama Mutlak Değer 1.....	23
3.5.4. Modifiye Edilmiş Ortalama Mutlak Değer 2.....	23
3.5.5. Eğim İşareti Değişikliği.....	24
3.5.6. Sıfır Geçiş Sayısı.....	25
3.5.7. Dalga Formu Uzunluğu.....	25
3.5.8. Geliştirilmiş Dalga Boyu.....	26
3.5.9. Etkin Değer.....	27
3.5.10. Ortalama Genlik Değişimi.....	27
3.5.11. Mutlak Standart Sapma Değerlerinin Farkı.....	28
3.5.12. Log Detektör.....	29

3.5.13. Miyopülse Yüzde Oranı	29
3.5.14. Basit Kare İntegral	30
3.5.15. Varyans	31
3.5.16. Willison Genliği	31
3.5.17. Maksimum Fraktal Uzunluk	32
3.6. Ardışıl İleri Yönlü Öznitelik Seçimi Yöntemi	33
3.7. İşaretlerin Sınıflandırılması.....	33
3.7.1. Karar Ağaçları.....	34
3.7.2. Diskriminant Analizi.....	34
3.7.3. Destek Vektör Makineleri.....	34
3.7.4. K-En Yakın Komşu Sınıflandırıcıları	35
3.7.5. Yapay Sinir Ağları	36
3.7.5.1. Yapay Sinir Hücresinin Yapısı	37
3.7.5.2. YSA'nın Yapısı	37
3.7.5.3. Yapay Sinir Ağlarının Eğitilmesi.....	38
4. BULGULAR.....	41
4.1. CLA Kullanılarak Yapılan Sınıflandırmanın Bulguları.....	41
4.2. YSA Kullanılarak Yapılan Sınıflandırmanın Bulguları.....	59
4.3. Gerçek Zamanlı Veriler İle Yapılan Sınıflandırmanın Bulguları.....	76
5. TARTIŞMALAR.....	80
6. SONUÇLAR.....	85
KAYNAKLAR	88

SİMGELER VE KISALTMALAR

SİMGELER

mm	Milimetre	ms	Milisanıye
Hz	Hertz	kHz	Kilohertz
µm	Mikrometre	Na	Sodyum
K	Potasyum	Cl	Klor
Ag	Gümüş	AgCl	Gümüş Klorür
mV	Milivolt		

KISALTMALAR

YSA	Yapay Sinir Ağları	LSTM	Uzun Kısa Süreli Bellek
IMU	Atalet Ölçü Birimi	EMG	Elektromiyogram
MAV	Ortalama Mutlak Değer	RMS	Etkin Değer
SSC	Eğim İşareti Değişimi	ZC	Sıfır Geçiş
WL	Dalga Formu Uzunluğu	EWL	Geliştirilmiş Dalga Boyu
LOG	Log Detektor	MYOP	Miyopüle Yüzde Oranı
SSI	Basit Kare İntegral	VAR	Varyans
WAMP	Willison Genliği	DNN	Derin Sinir Ağı
SVM	Destek Vektör Makineleri	KNN	K-En Yakın Komşu
DA	Diskriminant Analizi	FT	Hassas Ağaç
MT	Orta Ölçekli Tree	CT	Kaba Ağaç
LD	Doğrusal Diskriminant	QD	Kuadratik Diskriminant
LSVM	Doğrusal SVM	QSVM	Kuadratik SVM
CSVM	Kübik SVM	FQSVM	Hassas Gauss SVM
MGSVM	Orta Ölçekli Gauss SVM	CGSVM	Kaba Gauss SVM
FKNN	Hassas KNN	MKNN	Orta Ölçekli KNN
Coar.KNN	Kaba KNN	Cos.KNN	Kosinüs KNN
Cu.KNN	Kübik KNN	WKNN	Ağırlıklı KNN
Bo.T	Hızlandırılmış Ağaç	Ba.T	Bağlı Ağaç
RF	Rastgele Orman	LR	Lojistik Regresyon
SD	Altuzay Diskriminant	SKNN	Altuzay KNN
RUST	RUSBoosted Ağaç	TP	Doğru Pozitif
TN	Doğru Negatif	FP	Yanlış Pozitif
FN	Yanlış Negatif	OSS	Tek Adımlı Sekant
SCG	Ölçekli Eşlenik Gradyan	GD	Dereceli Alçalma
LM	Levenberg-Marquardt	BR	Bayes Düzenlemesi
BFG	BFGS Quasi-Newton	NRP	Esnek Geri Yayılım
IEMG	Birleşik EMG	STD	Standart Sapma
SS	Çarpıklık	AR	Otomatik Regresyon
MAD	Ortalama Mutlak Sapma	MLP	Çok Katmanlı Algılayıcı
KURT	Basıklık	M	Ortalama
LIBSVM	SVM Kütüphanesi	THR	Eşik
EEG	Elektroensefalogram	EOG	Elektrookülografi
F1	EMAV	F2	EWL
F3	MAV	F4	WL
F5	ZC	F6	SSC
F7	RMS	F8	AAC
F9	DASDV	F10	LOG

F11	MMAV1	F12	MMAV2
F13	MYOP	F14	SSI
F15	VAR	F16	WAMP
F17	MFL	H	Hjorth
GYRO	Jiroskop	K1	Katılımcı 1
K2	Katılımcı 2	K3	Katılımcı 3
K4	Katılımcı 4	K5	Katılımcı 5
K6	Katılımcı 6	K7	Katılımcı 7
K8	Katılımcı 8	K9	Katılımcı 9
K10	Katılımcı 10	CNN	Evrişimli Sinir Ağları
MSE	Ortalama Kare Hata		
MFL	Maksimum Fraktal Uzunluk		
SRELM	Spektral Regresyon Ekstrem Öğrenme Makinesi		
PNM	Performans Ölçüm Endeksi		
CSP-PE	Ortak Uzamsal Modeller Orantılı Tahmincisi		
ELM	Aşırı Öğrenme Makinesi		
LDA	Doğrusal Diskriminant Analizi		
PCA	Temel Bileşenler Analizi		
LPC	Doğrusal Tahmin Katsayısı		
PNN	Olasılıksal Sinir Ağı		
GRNN	Genel Regresyon Sinir Ağı		
RBFNN	Radyal Temel Fonksiyon Sinir Ağı		
LDR	Levinson Durbin Özyinelemesi		
CGB	Eşlenik Gradyan ile Powell/Beale Yenilemesi		
CGF	Fletcher-Powell Eşlenik Gradyan		
CGP	Polak-Ribière Eşlenik Gradyan		
GDX	Değişken Öğrenme Oranı Eşlenik Gradyan		
GDM	Momentum ile Gradyan İniş		
ANFIS	Uyarlanabilir Nöro-Bulanık Çıkarım Sistemi		
AAC	Ortalama Genlik Değişimi		
DASDV	Mutlak Standart Sapma Değerlerinin Farkı		
EMAV	Geliştirilmiş Ortalama Mutlak Değer		
MMAV1	Modifiye Edilmiş Ortalama Mutlak Değer 1		
MMAV2	Modifiye Edilmiş Ortalama Mutlak Değer 2		
OFNDA	Ortogonal Bulanık Komşuluk Ayrımcı Analizi		
CLA	Sınıflandırma Öğreticisi Uygulaması		
nprtool	Sinir Ağı Örüntü Tanıma Aracı		

ŞEKİLLER DİZİNİ

Şekil 2.1. Çizgili kasların yapısı (Obuş, 2019).....	9
Şekil 2.2. Kasların kasılmasının artması ile motor ünite hareketleri (Taşar, 2016).....	10
Şekil 2.3. Kaslardaki servo sisteminin akış diyagramı (Taşdemir, 2018)	11
Şekil 2.4. Kas kasılması sonucunda biyolojik işaretin oluşumu (Tepe, 2014)	12
Şekil 2.5. Ön koldaki kaslar A)1. Bölüm, B)2. Bölüm, C)3. Bölüm, D)4. Bölüm(Moore et al., 2015)12	
Şekil 3.1. Çalışmada kullanılan ana metodlar	13
Şekil 3.2. Myo bileklik (Tepe et al., 2020).....	13
Şekil 3.3. EMG elektrotları (A) İğne elektrot (B) Yüzey elektrot(Taşar, 2016)	14
Şekil 3.4. Çalışmada kullanılan hareketler	15
Şekil 3.5. Kaydedilen yüzey EMG işareti	15
Şekil 3.6. Filtrelenmemiş yüzey EMG işaretinin frekans düzleminde gösterimi	16
Şekil 3.7. Filtrelenmiş yüzey EMG işaretinin frekans düzleminde gösterimi	17
Şekil 3.8. Sınırları belirlenmiş yüzey EMG işareti.....	18
Şekil 3.9. Yüzey EMG işaretinin eşik noktaları ve zarfının alınmış hali	18
Şekil 3.10. Sınırları belirlenmiş jiroskop işareti	19
Şekil 3.11. Örtüşen pencereleme gösterimi (Englehart and Hudgins, 2003).....	20
Şekil 3.12. Bitişik pencereleme gösterimi (Englehart and Hudgins, 2003).....	20
Şekil 3.13. Başparmak yüzey EMG verisinin gösterimi	21
Şekil 3.14. MAV özneliğinin gösterimi	22
Şekil 3.15. EMAV özneliğinin gösterimi	22
Şekil 3.16. MMAV1 özneliğinin gösterimi.....	23
Şekil 3.17. MMAV2 özneliğinin gösterimi.....	24
Şekil 3.18. SSC özneliğinin gösterimi	24
Şekil 3.19. ZC özneliğinin gösterimi	25
Şekil 3.20. WL özneliğinin gösterimi	26
Şekil 3.21. EWL özneliğinin gösterimi.....	26
Şekil 3.22. RMS özneliğinin gösterimi.....	27
Şekil 3.23. AAC özneliğinin gösterimi.....	28
Şekil 3.24. DASDV özneliğinin gösterimi.....	28
Şekil 3.25. LOG özneliğinin gösterimi	29
Şekil 3.26. MYOP özneliğinin gösterimi	30
Şekil 3.27. SSI özneliğinin gösterimi.....	30
Şekil 3.28. VAR özneliğinin gösterimi	31
Şekil 3.29. WAMP özneliğinin gösterimi	32
Şekil 3.30. MFL özneliğinin gösterimi	32
Şekil 3.31. Özneliklerin birlikte gösterimi	33
Şekil 3.32. Destek vektör makinaları sınıflandırma sistemi(Bağcı, 2016).....	35
Şekil 3.33. KNN sınıflandırıcısının gösterimi (Bağcı, 2016)	36
Şekil 3.34. Yapay sinir hücresinin yapısı (Taşar, 2016).....	37
Şekil 3.35. YSA'nın yapısı (Kaynar et al., 2011).....	38
Şekil 4.1. Ardışıl ileri yönlü öznelikler seçimi ve başarımları	51
Şekil 4.2. SCG eğitim algoritması ile sınıflandırma başarımları	59
Şekil 4.3. LM eğitim algoritması ile sınıflandırma başarımları.....	60
Şekil 4.4. BR eğitim algoritması ile sınıflandırma başarımları	60
Şekil 4.5. BFG eğitim algoritması ile sınıflandırma başarımları	61
Şekil 4.6. NRP eğitim algoritması ile sınıflandırma başarımları	61
Şekil 4.7. CGB eğitim algoritması ile sınıflandırma başarımları	62
Şekil 4.8. CGF eğitim algoritması ile sınıflandırma başarımları	62
Şekil 4.9. CGP eğitim algoritması ile sınıflandırma başarımları	63
Şekil 4.10. OSS eğitim algoritması ile sınıflandırma başarımları	63
Şekil 4.11. GDX eğitim algoritması ile sınıflandırma başarımları	64
Şekil 4.12. GDM eğitim algoritması ile sınıflandırma başarımları	64
Şekil 4.13. GD eğitim algoritması ile sınıflandırma başarımları	65
Şekil 4.14. Jiroskop verileri eklenerek SCG eğitim algoritması ile sınıflandırma	65
Şekil 4.15. Jiroskop verileri eklenerek NRP eğitim algoritması ile sınıflandırma	66
Şekil 4.16. Jiroskop verileri eklenerek CGB eğitim algoritması ile sınıflandırma	66
Şekil 4.17. Jiroskop verileri eklenerek CGF eğitim algoritması ile sınıflandırma	67
Şekil 4.18. Jiroskop verileri eklenerek CGP eğitim algoritması ile sınıflandırma	67

Şekil 4.19. Jiroskop verileri eklenerek OSS eğitim algoritması ile sınıflandırma.....	68
Şekil 4.20. Jiroskop verileri eklenerek GDX eğitim algoritması ile sınıflandırma	68
Şekil 4.21. Jiroskop verileri eklenerek GDM eğitim algoritması ile sınıflandırma.....	69
Şekil 4.22. Jiroskop verileri eklenerek GD eğitim algoritması ile sınıflandırma	69
Şekil 4.23. SCG eğitim algoritması ile bireysel sınıflandırma başarımları	72
Şekil 4.24. Farklı pencere boyutlarında sınıflandırma başarımları.....	72
Şekil 4.25. Katmanlar ve nöron sayıları	73
Şekil 4.26. YSA sınıflandırmanın karmaşıklık matrisi ile gösterimi.....	73
Şekil 4.27. CSVM modeli ile gerçek zamanlı sınıflandırma başarımları	76
Şekil 4.28. RMS özneliğiyle farklı sınıflandırıcılardaki başarımlar.....	77
Şekil 4.29. Farklı veriler kullanarak tekrarlanan gerçek zamanlı sınıflandırma 1	78
Şekil 4.30. Farklı veriler kullanarak tekrarlanan gerçek zamanlı sınıflandırma 2	78
Şekil 4.31. Katılımcıların gerçek zamanlı sınıflandırmaları.....	79



TABLolar DİZİNİ

Tablo 3.1. YSA ile sınıflandırmada kullanılan etiketler.....	40
Tablo 4.1. EMaV, EWL, MAV, WL ve ZC öznitelikleri ile sınıflandırma.....	41
Tablo 4.2. SSC, RMS, AAC ve DASDV öznitelikleri ile sınıflandırma.....	42
Tablo 4.3. MMAV1, MMAV2, MYOP ve LOG öznitelikleri ile sınıflandırma.....	42
Tablo 4.4. SSI, VAR, WAMP ve MFL öznitelikleri ile sınıflandırma.....	43
Tablo 4.5. Ardışıl ileri yönlü öznitelik seçimi 2. Aşama.....	44
Tablo 4.6. Ardışıl ileri yönlü öznitelik seçimi 3. Aşama.....	44
Tablo 4.7. Ardışıl ileri yönlü öznitelik seçimi 4. Aşama.....	45
Tablo 4.8. Ardışıl ileri yönlü öznitelik seçimi 5. Aşama.....	45
Tablo 4.9. Ardışıl ileri yönlü öznitelik seçimi 6. Aşama.....	46
Tablo 4.10. Ardışıl ileri yönlü öznitelik seçimi 7. Aşama.....	46
Tablo 4.11. Ardışıl ileri yönlü öznitelik seçimi 8. Aşama.....	47
Tablo 4.12. Ardışıl ileri yönlü öznitelik seçimi 9. Aşama.....	47
Tablo 4.13. Ardışıl ileri yönlü öznitelik seçimi 10. Aşama.....	47
Tablo 4.14. Ardışıl ileri yönlü öznitelik seçimi 11. Aşama.....	48
Tablo 4.15. Ardışıl ileri yönlü öznitelik seçimi 12. Aşama.....	49
Tablo 4.16. Ardışıl ileri yönlü öznitelik seçimi 13. Aşama.....	49
Tablo 4.17. Ardışıl ileri yönlü öznitelik seçimi 14. Aşama.....	50
Tablo 4.18. Ardışıl ileri yönlü öznitelik seçimi 15. Aşama.....	50
Tablo 4.19. Ardışıl ileri yönlü öznitelik seçimi 16. Aşama.....	50
Tablo 4.20. Ardışıl ileri yönlü öznitelik seçimi 17. Aşama.....	51
Tablo 4.21. Seçilen öznitelikler ile bireysel sınıflandırma başarımları.....	52
Tablo 4.22. Jiroskop verileri eklenerek yapılan sınıflandırma başarımları.....	52
Tablo 4.23. Farklı pencere boyutlarında sınıflandırma başarımları.....	53
Tablo 4.24. Karmaşıklık matrisi.....	53
Tablo 4.25. Başparmak için TP, TN, FP, FN gösterimi.....	54
Tablo 4.26. İşaret parmak için TP, TN, FP, FN gösterimi.....	55
Tablo 4.27. Orta parmak için TP, TN, FP, FN gösterimi.....	55
Tablo 4.28. Yüzük parmak için TP, TN, FP, FN gösterimi.....	55
Tablo 4.29. Serçe parmak için TP, TN, FP, FN gösterimi.....	56
Tablo 4.30. Dinlenme hareketi için TP, TN, FP, FN gösterimi.....	56
Tablo 4.31. Başparmağın başarımların yüzdelerinin hesaplanması.....	57
Tablo 4.32. İşaret parmağın başarımların yüzdelerinin hesaplanması.....	57
Tablo 4.33. Orta parmağın başarımların yüzdelerinin hesaplanması.....	58
Tablo 4.34. Yüzük parmağın başarımların yüzdelerinin hesaplanması.....	58
Tablo 4.35. Serçe parmağın başarımların yüzdelerinin hesaplanması.....	58
Tablo 4.36. Dinlenme hareketinin başarımların yüzdelerinin hesaplanması.....	58
Tablo 4.37. Eğitim algoritmalarının en yüksek başarımları.....	70
Tablo 4.38. SCG eğitim algoritması ile bireysel sınıflandırma başarımları.....	71
Tablo 4.39. Başparmağın başarımların yüzdelerinin hesaplanması.....	74
Tablo 4.40. İşaret parmağın başarımların yüzdelerinin hesaplanması.....	74
Tablo 4.41. Orta parmağın başarımların yüzdelerinin hesaplanması.....	74
Tablo 4.42. Yüzük parmağın başarımların yüzdelerinin hesaplanması.....	75
Tablo 4.43. Serçe parmağın başarımların yüzdelerinin hesaplanması.....	75
Tablo 4.44. Dinlenme hareketinin başarımların yüzdelerinin hesaplanması.....	75
Tablo 5.1. Literatürde myo bileklikle yapılan çalışmalar.....	81
Tablo 5.2. Literatürde myo bileklik kullanılmadan yapılan çalışmalar.....	83
Tablo 5.3. Literatürde gerçek zamanlı sınıflandırma yapılan çalışmalar.....	84

1. GİRİŞ

İnsanlar, vücudu kaplayan kas dokularından oluşmaktadır. Kasların kemik ve eklemlerin hareket ettirilmesi, ısı üretilmesi, iç ve dış organların desteklenmesi gibi birçok farklı görevleri bulunmaktadır. Kasların kasılması sonucunda biyoelektriksel işaret üretilir ve bu işaretlere yüzey Elektromiyogram (EMG) denir. Yüzey EMG işaretleri işlenerek insan hayatını kolaylaştırma adına robot kontrolleri (Ülker et al., 2017), protez kontrolleri (Said et al., 2019; Tepe et al., 2020), sanal el kontrolleri (Ganiev et al., 2016), işaret dili sınıflandırma (Z. Zhang et al., 2019), uzaktan kontrollü cihazlar (Kristof et al., 2019) gibi birçok alanda çalışma yapılmaktadır. Bu çalışmada myo kol bandı ile yüzey EMG ve jiroskop işaretleri alınarak veri seti oluşturulmuş ve parmak hareketleri çevrimdışı ve gerçek zamanlı sınıflandırılarak modeller oluşturulmuştur. Ardışıl ileri yönlü öznitelik seçimi ile 17 farklı öznitelikten en yüksek başarıyı veren öznitelik grubu seçilmiştir. Jiroskop verilerinin sınıflandırma başarımına etkisi incelenmiştir. Elde edilen sınıflandırma başarımları göstermiştir ki gerçek zamanlı sınıflandırmalarda ve protez kontrollerinde kullanılabilir yapıdadır.

Tezin ikinci bölümünde kuramsal temeller ve kaynak özetlerine yer verilmiştir. Üçüncü bölümünde materyal ve yöntem anlatılmıştır. Dördüncü bölümde bulgulara ve yapılan çalışmalara değinilmiştir. Beşinci bölümde tartışmalar ve son bölümde sonuçlara yer verilmiştir.

1.1. Tezin Amacı

10 kişiden 5 parmak ve 1 el dinlenme hareketi için myo kol bandı ile alınan yüzey EMG ve jiroskop işaretleri ile veri seti oluşturmaktır. Parmak verilerinin sınıflandırılması zordur. Kol kasları birbirleri üzerinde sarmal şeklindedir. Bir parmak hareket ettiğinde diğer parmak da kasılabilmektedir. Bu çalışmada parmak verileri çevrimdışı ve gerçek zamanlı yüksek başarımla sınıflandırılarak protez ve sanal el kontrollerinin daha iyi yapılması için bir model önerimi amaçlanmaktadır.

1.2. Tezin Kapsamı

Veri setinin oluşturulması, filtrelenmesi, pencereleme bölünmesi, özniteliklerinin çıkartılması, çevrimdışı ve gerçek zamanlı sınıflandırılması gibi işlemlerin gerçekleştirilerek parmak verilerinin incelenmesinde yüksek başarımlı sonuç elde edilerek model oluşturulması çalışmanın kapsamını oluşturmaktadır.

2. KURAMSAL TEMELLER VE KAYNAK ÖZETLERİ

2.1. Kaynak Özetleri

Literatürde işaretlerinin sınıflandırılması ile ilgili birçok çalışma yapılmıştır. Myo bileklik kullanılarak alınan parmak hareketlerinin sınıflandırılması ile ilgili çalışmalar şunlardır:

Castiblanco vd. (2016), 7 kişiden 5 parmak hareketi için 4 tekrar olarak myo bileklikle veri almışlardır. IEMG, MAV, SSI, VAR, RMS, WL, AAC, DASDV, MYOP, WAMP ve SSC öznitelikleri kullanılmış ve normalizasyon yapılmıştır. SVM ve karar ağaçları ile sınıflandırma yapılmıştır. Sınıflandırmada en yüksek başarıımı SVM sınıflandırıcısı göstermiştir. Sınıflandırma başarıımı %92.00 olarak elde edilmiştir.

Caesarendra vd. (2018), 1 kişiden 5 parmak hareketini 10 tekrar olarak myo bileklik ile almışlardır. IEMG, MAV, MAV1, MAV2, SSI, VAR, RMS, WL, DASDV, H1, H2 ve H3 öznitelikleri kullanmışlardır. Verileri %50 eğitim ve %50 test olarak bölmüşlerdir. ANFIS mimarisini kullanarak 5 parmak hareketini %72.00 başarıım ile sınıflandırmışlardır. ANFIS, YSA'nın uyarlanabilir kabiliyetini ve bulanık mantığın kalitatif yaklaşımını birleştiren spesifik bir nöro-bulanık sınıflandırma yaklaşımı türüdür.

Naseer vd. (2018), yaptıkları çalışmada 5 parmak hareketi ve bir dinlenme hareketi için 10 kişiden 20 kez tekrarlanarak myo bileklik ile veri almışlardır. STD, RMS, WL ve WAMP öznitelikleri kullanılmıştır. PCA ve genetik algoritma kullanılarak öznitelikler azaltılmıştır. Veri seti LDA, KNN, SVM ve DNN kullanılarak sınıflandırılmıştır. Ayrıca gerçek zamanlı sınıflandırma işlemi de yapılmıştır. Sınıflandırma başarıımı %95 ve gerçek zamanlı sınıflandırma başarıımı %92.00 olarak elde edilmiştir. Bu başarıımı DNN sınıflandırıcısı vermiştir.

Singhvi vd. (2018), 6 parmak hareketi için (başparmak ve işaret parmağın farklı hareketleri) 6 kişiden 6 tekrar olarak myo bileklik ile veri seti oluşturmuşlardır. Verilerin %80'i eğitim için %20'si test için ayrılmıştır. MAV, STD, VAR, RMS, WL, ZC ve IEMG öznitelikleri kullanılmış, KNN ve SVM gibi makine öğrenme teknikleri ile sınıflandırılmıştır. KNN modelinde başparmak ve işaret parmak hareketi için sınıflandırma başarıımı %80.00 -%86.00 aralığındadır.

Srinivasan vd. (2018), 5 parmak ve 1 dinlenme hareketini myo kol bandı kullanarak almışlardır. Hareketler 10 kişiden alınmış ve 20 kez tekrarlanmıştır. M,

STD, VAR ve RMS öznitelikleri kullanılmıştır. SVM, RF, LR ve YSA kullanılarak sınıflandırılmıştır. YSA olarak CNN mimarisi kullanılmıştır. Sınıflandırma başarımı %72.50 olarak verilmiştir.

Stephenson vd. (2018), 12 parmak hareketi için 4 kişiden 20 kez tekrarlanarak myo bileklik ile veriler alınmıştır. Veri seti %70 eğitim, %15 test ve %15 doğrulama için bölünmüştür. RMS özniteliği kullanılmıştır. CNN mimarisi kullanılarak sınıflandırma yapılmıştır. Sınıflandırma başarımı %94.90 olarak verilmiştir.

Altan vd. (2019), 1 kişiden myo kol bandı ile veri olarak veri seti oluşturmuşlardır. Veri setinde 37 Hz kesim frekansına sahip alçak geçiren filtre kullanmışlardır. VAR özniteliğini kullanarak 7 parmak hareketini sınıflandırmışlardır. Karar ağaçları, SVM ve KNN sınıflandırıcılarını kullanarak %94.00 civarında başarımler elde etmişlerdir.

Krishnan vd. (2019), 8 parmak hareketini sınıflandırmak için myo kol bandı ile veri almışlardır. Veri seti 1 kişiden hareketler 4 kez tekrarlanarak oluşturulmuştur. Veri seti %50 eğitim ve %50 test olarak ayrılmıştır. 200 ms'lik pencere boyutu seçilmiş ve 60 ms'lik örtüşme kullanılmıştır. RMS, enerji, medyan, ZC, SSC, VAR, MAV, SS, KURT ve AR öznitelikleri kullanılmıştır. SVM, LDA ve MLP yöntemleri ile sınıflandırılmıştır. En yüksek başarımler LDA sınıflandırıcısı %97.70 ile verilmiştir.

Arozi vd. (2020), 1 kişiden 6 tekrar olmak üzere myo bileklik ile veri almışlardır. RMS özniteliğini kullanmışlardır. Veri setinin %70'i eğitim ve %30 test seti olarak kullanılmıştır. 7 parmak hareketini Uyarlamalı Nöro-Bulanık Çıkarım Sistemini (ANFIS) kullanarak sınıflandırmışlardır. Sınıflandırma başarımı %98.09 olarak elde edilmiştir.

Millar vd. (2020), myo bileklik kullanarak veri setini oluşturmuşlardır. Veriler 1 kişiden alınmış ve 12 parmak hareketi için 70 kez tekrarlanmıştır. Pencere boyutu 200 ms olarak seçilmiş ve 20 ms'lik örtüşen pencere kullanılmıştır. MAV, WL, VAR, SSC, AR, ZC, WAMP, RMS, STD, MAD, KURT öznitelikleri kullanılmıştır. Verilerin %80'i eğitim ve %20'si test için kullanılmıştır. LSTM yapay sinir ağı kullanılarak veriler sınıflandırılmıştır ve %90.00 başarımler elde edilmiştir.

Tepe vd. (2020), 5 parmak hareketi ve 1 dinlenme hareketini myo kol bandı ile almışlardır. Hareketler 4 kişiden 10 kez tekrarlanarak alınmıştır. Veriler 100 ms'lik pencerelere bölünmüştür. Örtüşen pencere kullanılmış örtüşme oranı %50 olarak belirlenmiştir. EWL, RMS, MMAV, DASDV ve MFL öznitelikleri kullanılmıştır. SKNN, FKNN, CSVM, WKNN ve QSVM yöntemleri ile sınıflandırılmıştır. En

yüksek başarımı EWL özneliği ve SKNN yöntemi ile sınıflandırılan model vermiştir. Sınıflandırma başarımı 95.83 olarak verilmiştir.

Farklı veri alım yöntemleri kullanılarak alınan parmak verilerinin sınıflandırılması ile ilgili yapılan çalışmalar aşağıda gösterilmektedir.

Peleg vd. (2002), genetik algoritma ile parmak hareketlerini sınıflandırmayı amaçlamışlardır. 4 kişiden 5 parmak hareketlerini sınıflandırmak için 30 kez tekrar ile veri alınmıştır. 2 kanal kullanılmış ve örnekleme frekansı 500 Hz'dir. Ortalama, AR ve VAR öznelikleri kullanılmıştır. Veri seti KNN yöntemi ile sınıflandırılmıştır. Sınıflandırma başarımı %98.00'dir.

Jiang vd. (2006), dalgacık dönüşümü kullanarak parmak hareketlerini sınıflandırmayı amaçlamışlardır. Verileri 16 kanallı işaret algılama sistemi ile almışlardır. Örnekleme frekansı 2000 Hz'dir. 6 parmak hareketi için 10 kişiden veri alınmıştır. VAR, maksimum ve MAV öznelikleri kullanılmıştır. YSA ile sınıflandırılmış ve başarımı %80.00'in üzerindedir.

Tenore vd. (2008), 1 ampute 5 sağlıklı bireyden 32 kanallı bir cihaz ile veri almışlardır. 2000 Hz örnekleme frekansı kullanılmış ve 500 Hz alçak geçiren filtre uygulanmıştır. 12 parmak hareketi 25-30 kez tekrarlanmıştır. 25 ms'de bir örtüşen 200 ms'lik pencere kullanılmıştır. MAV, VAR, WL ve WAMP öznelikleri kullanılmıştır. MLP yapay sinir ağı kullanılarak sınıflandırılmıştır. Veri seti %50 eğitim, %25 test ve %25 doğrulama olarak bölünmüştür. Bireysel sınıflandırma yapılmış başarımlar ortalama olarak hesaplanmıştır. Başarımlar %90.00 civarındadır. Sağlıklı ve ampute bireylerde sınıflandırma başarımlarında önemli bir fark olmadığı sonucuna varılmış ve bu çalışmada paylaşılmıştır.

Cipriani vd. (2011), robot eli gerçek zamanlı kontrol etmek için sınıflandırma yapmışlardır. 5 ampute ve 5 sağlam bireyden 7 parmak ve 1 dinlenme hareketini sınıflandırmak için 8 çift yüzey yüzey EMG sensörü kullanarak veri alınmıştır. Örnekleme frekansı 10 kHz'dir. MAV özneliği kullanılmıştır. Her hareket 3 kez tekrarlanmıştır. Denetimli öğrenme ile veri eğitilmiştir. Sınıflandırma başarımı ampute bireylerde %79.00 sağlıklı bireylerde %89.00 olarak belirlenmiştir.

Kanitz vd. (2011), 12 parmak ve 1 dinlenme hareketini sınıflandırmışlardır. Veriler 5 sağlıklı ve 1 ampute bireyden alınmış ve hareketler 5 kez tekrarlanmıştır. 16 kanaldan veri alınmıştır. Örnekleme frekansı 1.6 kHz'dir. 10 Hz ile 500 Hz arasında Butterworth bant geçiren filtre ve 50 Hz için çentik filtre kullanılmıştır. 250 ms'lik pencere boyutu seçilmiş ve 25 ms'lik örtüşen pencere kullanılmıştır. ZC, WL, SSC ve

MAV öznitelikleri kullanılmıştır. LDA, KNN ve SVM yöntemleri ile veri setini sınıflandırmışlardır. Sınıflandırma başarımı %80.00'dir. Bu çalışmada kanal sayısını azaltarak sınıflandırma yapılmış ve sınıflandırma başarımını çok az azalmıştır.

Khushaba vd. (2012), parmak hareketlerini doğru ayırt etmeye yönelik bir çalışma yapmışlardır. İki yüzey EMG elektrot kullanılarak 8 kişiden 10 parmak hareketi 6 kez tekrarlanarak için veri alınmıştır. Örnekleme frekansı 4000 Hz'dir. 20-450 Hz arasında bant geçiren filtre ve 50 Hz çentik filtre yapılmıştır. Verilerin %67'si eğitim %33'ü test için kullanılmıştır. SSC, ZC, WL, Hjort parametreleri, SS ve AR öznitelikleri kullanılmıştır. Bayes füzyon yaklaşımı kullanılarak LIBSVM ve KNN yöntemleri ile sınıflandırma yapılmıştır. Pencere boyutu 50, 100 ve 150 ms arasında seçilmiştir. LIBSVM sınıflandırıcı ve Bayes yaklaşımı ile çevrimdışı %92.00 gerçek zamanlı %90 sınıflandırma başarımı elde edilmiştir.

Al-Timemy vd. (2013), 10 kişiden 15 parmak hareketi için 6 tekrar ve 6 dirsek altı ampute bireyden 12 parmak hareketi için 6 tekrar olarak veri almışlardır. Veri alınırken sağlam bireylerde 12 elektrot ampute bireylerde 11 elektrot kullanılmıştır. 2000 Hz örnekleme frekansında veri alınarak 20-450 Hz aralığında bant geçiren filtre uygulanmıştır. Öznitelik olarak AR, boyut azaltmak için OFNDA ve sınıflandırma için LDA yöntemi kullanılmıştır. Sağlıklı bireylerde 15 parmak hareketinin sınıflandırma başarımı %98 ve ampute bireylerde 12 parmak hareketinin sınıflandırma başarımı %90.00 olarak elde edilmiştir. Bu çalışmada protez kontrolü için parmak hareketlerini sınıflandırarak çok kanallı yüzey EMG kullanımı amaçlanmıştır.

Birdwell vd. (2014), 7 kişiden 6 parmak hareketi için 12 kez tekrar ile veri almışlardır. Veriler kas içi nikel alaşımli bipolar ince telli elektrotlar ile alınmıştır. Örnekleme frekansı 1000 Hz'dir. 20-450 Hz arasında bant geçiren filtre kullanılmıştır. 250 ms'lik pencere ve 25 ms'lik örtüşme kullanılmıştır. MAV özniteliği kullanılmıştır. Sanal el kontrolü yapılmıştır. Örüntü tanıma ile sınıflandırılmış ve başarıım %85.00 olarak verilmiştir.

Anam vd. (2015), yüzey EMG işaretlerini 2 kanal yüzey elektrot kullanarak almışlardır. Örnekleme frekansı 2000 Hz'dir. 10 parmak hareketini için 8 kişiden veri alınmıştır. 100 ms'lik pencere kullanılmıştır. AR, MAV, WL, SSC, ZC ve Hjorth parametreleri öznitelikleri kullanılmıştır. ELM ve SRELM yöntemleri kullanılarak sınıflandırma yapılmıştır. SRELM ile yapılan sınıflandırmada parmak hareketlerinin farklı sınıflandırma gruplarında %95.67 ile %86.73 arasında değişen başarıım elde edilmiştir.

Castro vd. (2015), 5 parmak ve 5 el hareketini 4 kişiden 30 tekrar alınarak veri seti oluşturmuşlardır. Veri alımında 5 yüzey elektrot kullanılmış ve 1000 Hz örnekleme frekansında veri alınmıştır. Öznitelik olarak güç spektral yoğunluk ortalaması seçilmiştir. Veriler LDA ile sınıflandırılmıştır. 10 hareketin başarıımı %80 olarak elde edilmiştir. PNM yöntemi ile her sınıfın performansı elde edilmiş sınıflar başarımlarına göre sınıflandırılmıştır. Düşük başarıım gösteren sınıflar tek tek çıkarılarak tekrar sınıflandırılmıştır. 4 hareket sınıflandırmadan çıkarılarak 6 hareketle yapılan sınıflandırmada doğruluk %96.50, hassasiyet %96.50 ve özgünlük %99.30 olarak elde edilmiştir. Protez el kontrolü için yüksek başarıımlı hareketlerin seçilmesi amaçlanmıştır.

Celadon vd. (2016), 8 parmak ve 1 dinlenme hareketini sınıflandırmışlardır. Yüzey EMG işaretleri ELSCH064NM 3–3, OT Bioelettronica (192 kanal elektrot) cihazı kullanılarak alınmıştır. Örnekleme frekansı 2048 Hz'dir. Pencere boyutu 200 ms ve %50 örtüşme kullanılmıştır. Regresyon, LDA, CSP-PE ve THR kullanılarak çevrimiçi ve çevrimdışı sınıflandırma yapılmıştır. Kanal sayısı azaltılarak sınıflandırma yapılmıştır. Çevrimdışı sınıflandırmada 9 kişiden 10 kez tekrarlanarak veri alınmıştır. RMS ve MSE öznitelikleri kullanılmıştır. Veri seti %70 eğitim ve %30 test olarak ayrıştırılmıştır. LDA kullanılarak 192 kanal sayısı ile yapılan sınıflandırmada %97.00 başarıım elde edilmiş kanal sayısı azaldıkça başarıım azalmıştır. 8 kanal ile yapılan sınıflandırmada %92.00 başarıım elde edilmiştir. Gerçek zamanlı sınıflandırmada CSP-PE ve LDA %91.00 olarak verilmiştir.

Çerçi (2017), hazır veri seti kullanmıştır. 4 kişiden 6 tekrar olarak 8 parmak hareketini 2 yüzey elektrotu ile 4000 Hz örnekleme frekansında veri alınmıştır. 20-450 Hz aralığında bant geçiren filtre uygulanmıştır. Sıfır geçiş noktası sayısı, dalga formu uzunluğu, eğim işareti değişikliği, ortalama mutlak değer, willison genliği, çarpıklık, varyans, karekök ortalama değeri ve Hjorth zaman bölgesi parametreleri, değişkenlik ve karmaşıklık öznitelikleri kullanılmıştır. KNN yöntemi ile sınıflandırmada başarıım %88.00'dir. YSA ile sınıflandırıldığında başarıım %93.00 civarındadır.

Emayavaramban vd. (2020), 12 parmak hareketini sınıflandırmışlardır. Veriler 5 Ag-AgCl katotları ile alınmıştır. 10 kişi her hareketi 10 kez tekrar ederek veri alımı gerçekleştirilmiştir. Örnekleme frekansı 400 Hz'dir. AR Burg, AR Yule-Walker, AR Covariance, AR Modified Covariance, LDR ve LPC öznitelik çıkarma yöntemleri kullanılmıştır. GRNN, PNN ve RBFNN 'de sınıflandırılmıştır. En yüksek başarıımı AR Burg özniteliği ve RBFNN sınıflandırıcısı %94.04 ile vermiştir.

Zhang vd. (2020), protez el kontrolü için parmak hareketlerini sınıflandırmışlardır. 5 kişiden 11 parmak hareketi için 36 kez tekrarlanarak veri alınmıştır. Veriler 8 kanallı Ag-AgCl yüzey elektrotları ile alınmıştır. Örnekleme frekansı 1500 Hz'dir. Veri setinin %67'si eğitim ve %33'ü test için kullanılmıştır. 20-450 Hz aralığında bant geçiren filtre kullanılmıştır. 200 ms'lik pencere boyutu seçilmiş ve 50 ms'lik artış miktarı ile diğer pencereye geçiş yapılmıştır. RMS, ZC, WL, SSC ve MAV öznitelikleri kullanılarak YSA, SVM ve KNN yöntemleri ile sınıflandırılmıştır. 8 kanallı sınıflandırmada en yüksek başarıyı YSA yöntemi vermiş ve başarı %91.10'dur. 7 kanal kullanılarak yapılan sınıflandırmada en yüksek başarıyı YSA vermiş ve başarı %90.52 olarak elde edilmiştir. Kanal sayısını azaltarak sınıflandırma başarımına etkisini gözlemlemiş ve yüksek başarı elde etmeyi amaçlamışlardır.

2.2. YüzeY Elektromiyogram İşareti Yapısı

YüzeY EMG işaretlerinin ana kaynağı kaslarda kasılma ve gevşeme ile meydana gelen elektrokimyasal olaylardır. Kas hücreleri serbest durumdayken bile biyoelektriksel potansiyele sahiptir. Bu potansiyele dinlenme potansiyeli adı verilmektedir. Kas hücreleri kasıldıklarında ise aksiyon potansiyeli adı verilen biyoelektriksel potansiyel artar ve yüzeY EMG işaretleri oluşur. Aksiyon potansiyeli ile kas aktivitesi sağlanır. Kas aktiviteleri ile oluşan işaretlerin kaydedilmesi için kullanılan yöntem Elektromiyografi yöntemi denir. Elektromiyografi yönteminde kas aktivitelerinin algılanması ve kaydedilmesi için yüzeY elektrotları ve iğne uçlu elektrotlar kullanılmaktadır (Taşar, 2016).

2.2.1. Kaslarının Yapısı

Kaslar kimyasal enerjiyi mekanik enerjiye dönüştürme yeteneğine sahip uyarılabilen hücrelerden oluşmaktadır. Kaslar kasılma, uyarılma, uzama, kısalma ve normal boyuna dönme özelliklerine sahiptir. Kaslar kimyasal, elektriksel ve mekanik olarak hareket ettirilebilir ve bu hareket sonucunda aksiyon potansiyeli oluştururlar (Taşdemir, 2018). Kas hücreleri kaslar boyunca uzanan lif yapısını oluştururlar. Lifler 1-50 mm uzunluğunda ve 10-100 µm çapındadır. Vücut ağırlığının yaklaşık %40'ı kaslardan oluşmaktadır. 600'den fazla kas iskelet sisteminde bulunmaktadır. Kaslar iskelet sistemine destek olarak hareketlerin yapılmasını, organların dış faktörlerden korunmasını ve organların görevlerini yerine getirmesine yardımcı olmaktadır. Kaslar çekme işlemini yapabilirken itme işlemini yapamazlar. İtme işlemini yapabilmek için zıt yöndeki kaslar çekme işlemini yaparlar. Bu işlemler sonucunda hareket ve ısı

oluşumu gerçekleşmektedir (Obuş, 2019).

2.2.2. Kasların Çeşitleri ve Kasılması

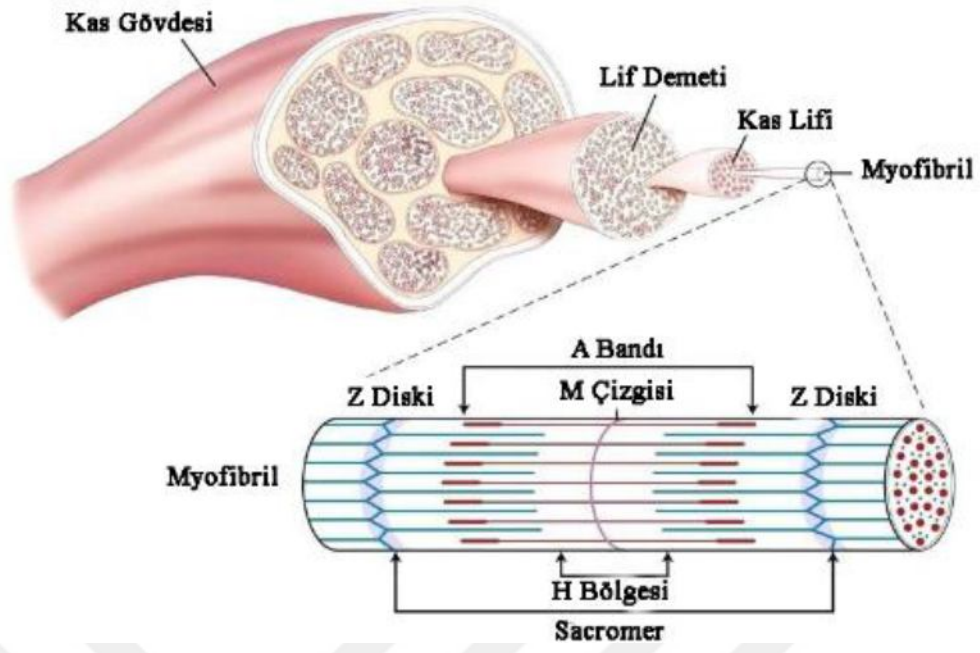
Kaslar yapılarına ve çalışmalarına göre iki sınıfa ayrılır. Çalışma şekillerine göre istemli olarak çalışan kaslar ve istemsiz olarak çalışan kaslar olarak ayrılır. İskelet kasları istemli kaslardan oluşmaktadır. Kalp kası ve düz kaslar istemsiz olarak çalışan kaslardır. Yapılarına göre kaslar düz kaslar, çizgili kaslar ve kalp kası olmak üzere 3'e ayrılmaktadır.

2.2.2.1. Çizgili Kaslar

Çizgili kaslar iskelet etrafını sardığı ve hareketlerin oluşmasını sağladığı için iskelet kasları olarak da adlandırılmaktadır. İskelete yapışık halde bulunurlar ve vücut şeklini oluştururlar. İstemli olarak çok hızlı kasılıp gevşerler ve çabuk yorulurlar. İskelet kasları uzun silindirik bir yapıya ve enine çizgilerden oluşmaktadır (Bağcı, 2016).

Kas dokuları miyofibril adı verilen çok küçük liflerden oluşmaktadır. Miyofibriller miyofilamentlerden ince ve kalın uzantılardan oluşmaktadır. Miyofilamentler boyut değiştirebilen proteinler olan Aktin, Myozin, Tropomiyozin ve Troponin (Troponin I, Troponin T, Troponin C) oluşmaktadır (McGinnis, 2013). Çizgili kaslar demetlerden oluşmaktadır. Miyofibriller kas lifini, kas lifleri, lif demetini, lif demetleri kas gövdesini oluşturmaktadır.

Çizgili kaslar açık ve koyu renkli bantlardan oluşmaktadır. Açık renkli bantlar I bandı ve koyu renkli bantlar A bandıdır. A bandının ortasında H bandı, I bandının ortasında ise Z bandı bulunmaktadır. İki Z bandı arasındaki bölgeye sakromer adı verilmektedir. Kas kasılmasında I ve H bandı kısalır, A bandı sabit kalır. Böylece kas boyu kısalmakta ve kasılma gerçekleşmektedir. Gevşemeyle birlikte kas eski haline geri döner. Çizgili kasların yapısı Şekil 2.1'de gösterilmektedir (Çerçi, 2017). Kas kasılması dinamik ve statik olmak üzere iki şekilde gerçekleşmektedir. Statik kasılmada kas boyu sabit kalır ve kas şişer. Dinamik kasılmada ise kas boyu kısalır ve kas şişer. Kas kasılırken glikojen depoları boşalır ve oksijenle kullanımıyla karbondioksit oluşur. Glikojen pruvik asitle parçalanarak ATP molekülü oluşur ve enerji açığa çıkar. Oksijen yetersizliğinde laktik asit üretilir ve enerji oluşur. Laktik asidin bir kısmı oksitlenerek karbondioksit ve su ile enerji oluşur. Oluşan enerji ile laktik asidin kalan kısmı glikojene dönüştürülür. Kas kasıldığında enerjinin bir kısmı mekanik enerjiye diğer kısmı ısıya dönüşür. Kalp kasları enerjilerinin yağlardan karşılarlar. Kan içerisindeki glikoz dengesini etkilemezler (Taşar, 2016).



Şekil 2.1. Çizgili kasların yapısı (Obuş, 2019)

2.2.2.2. Düz Kaslar

İstemsiz olarak yani kendiliğinden çalışan kaslardır. Sindirim, solunum, üreme, içi boş organların duvarlarında ve kalp damarlarında bulunmaktadır. Az enerji ile uzun süre kasılabilmektedir. İğçik şeklinde lif yapısına sahiptir (Taşdemir, 2018).

2.2.2.3. Kalp Kası


Kalp kası yapı olarak çizgili kaslara benzemektedir. İstemsiz olarak kendiliğinden çalışan çok gelişmiş bir kastır. Sinir sisteminden uyarım olmadan kasılabilirler. Sinir sistemindeki uyarım sadece kasılma zamanını etkiler. Düz bir lif yapısına sahip kalın ve kısa liflerden yoğun bir ağ yapısı oluşturmaktadır. Kalp kası diğer kaslardan daha çok oksijen ve enerjiye ihtiyaç duymaktadır (Taşar, 2016).

2.2.3. Motor Ünite ve Motor Hareketi

Kas hareketlerinin biyolojik üniteleri motor ünitelerdir. Motor ünitesinde, sinir sisteminden başlayıp motor uç plakalarına kadar uzanan bir motor sinir bulunmaktadır. Uç plakalar bir kas lifi ile eşleşir ve plakaların uyarılması ile kas lifleri de uyarılmış olur. Motor ünitesi sayısı kasların yoğunluğuna göre farklılık göstermektedir. Kas büyüdükçe motor ünitesi sayısı da artar. Motor ünitesinde 0.1-250 gram arasında kuvvet üretilmektedir. Motor ünitesinde 25-2000 arasında kas lifi bulunmaktadır. Kas lifleri birçok motor ünitesi ile etkileşim halindedir (Taşdemir, 2018; Verma et al. 2017).

Motor sinirleri sinir hücrelerinden oluşmaktadır. Bu hücreler motor uç plakalarına iki bilgi yani var ya da yok bilgisini vermektedir. Bu nedenle motor

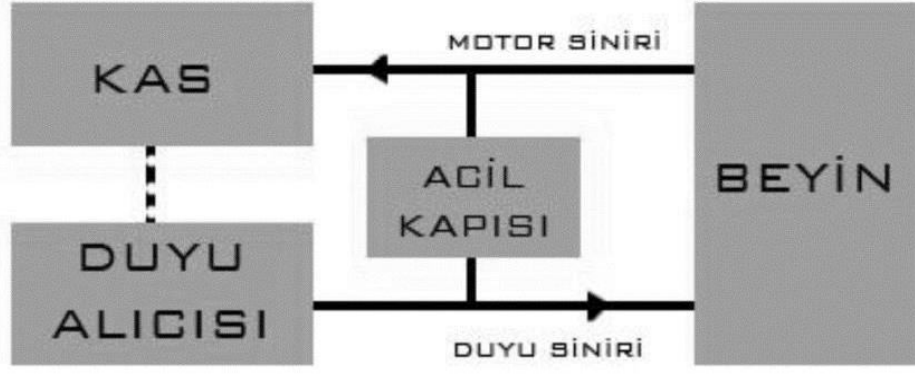
sinirleri dinlenme veya aktif durumda olabilir. Kas hareketleri yumuşak, devamlı ve hassastır. Bunun nedeni kasların birçok motor ünitesinden oluşmasından kaynaklanmaktadır. Kasın kasılması ile birçok motor ünitesi harekete geçer. Kasılma kuvvetli ise tüm motor üniteleri faal olur ve kas hareketlerinde düzgünlük sağlanır. Motor üniteler tek bir kas lifinin kasılmasını sağlar. Birim zamandaki kasılma sayısı kas liflerinin güçlenmesini sağlar. Kas hareketinin düzgünlüğü uyarılan motor ünitelerinin sayısına ve motor ünitelerinin uyarılma hızına bağlıdır. Kas hareketlerinin değişimi ile gerçekleşen motor ünitesi hareketleri Şekil 2.2’de gösterilmektedir. Kas kasılması artması ile daha fazla motor ünitesi aktif olmaktadır (Taşar, 2016).



Şekil 2.2. Kasların kasılmasının artması ile motor ünite hareketleri (Taşar, 2016)

2.2.4. Kaslarda Servo Mekanizması

Kaslardaki servo sistemi çalışma şu şekilde açıklanmaktadır. Duyu alıcısı bir hız veya konum işareti üreterek bu işareti duyu siniri yoluyla beyne aktarmaktadır. Beyin bu bilgi ile hafızada bulunan bilgileri işleyerek bir kontrol işaret üretmektedir. Bu kontrol işareti motor sinirler aracılığıyla kas hücrelerine aktarılmaktadır. Servo sistemi bir kontrol yapısıdır ve akış diyagramı Şekil 2.3’de gösterilmektedir (Taşdemir, 2018).




Şekil 2.3. Kaslardaki servo sisteminin akış diyagramı (Taşdemir, 2018)

Acil çıkış kapısı olarak adlandırılan bölüm normal durumlarda oluşmaz. Bu durum genellikle acil durumlarda meydana gelir. Refleksler duyu alıcılarının kuvvetli bir işaret algılaması ile tetiklenir. Bu durumda acil çıkış kapısı beyinden gelen işareti bloke ederek kasın hızlı ve aniden hareket etmesine neden olur. Refleksler acil çıkış kapılarının kullanılması sonucu oluşmaktadır (Taşar, 2016).

2.2.5. Kas Hareketleri Sonucunda Biyolojik İşaretin Oluşumu


Kasları hareketleri sonucunda + ve – yüklü moleküller bir bölgeden başka bir bölgeye hareket ederler. Böylece iki bölge arasında iyon konsantrasyon farkından dolayı bir potansiyel oluşur. Dinlenme potansiyeli -50mV ile – 100mV arasında değişmektedir. Bu ortamın yapısına göre farklılık gösterebilir. Hücre zarı dinlenme potansiyelinde Na, K ve Cl iyonlarına karşı az geçirgendir. Hücre içi dışarıya karşı negatiftir. Aksiyon potansiyelinde iyonlar hızla hücre içine hareket eder ve negatiflik değişir. Hücre içi pozitif bile olabilir. Kasılmanın bitimi ile kas hücreleri eski konumuna tekrar döner ve iyon konsantrasyonu eski halini alır. Biyolojik işaretin oluşumu Şekil 2.4’de gösterilmektedir (Tepe, 2014).



Şekil 2.4. Kas kasılması sonucunda biyolojik işaretin oluşumu (Tepe, 2014)

2.2.6. Ön Koldaki Kaslar

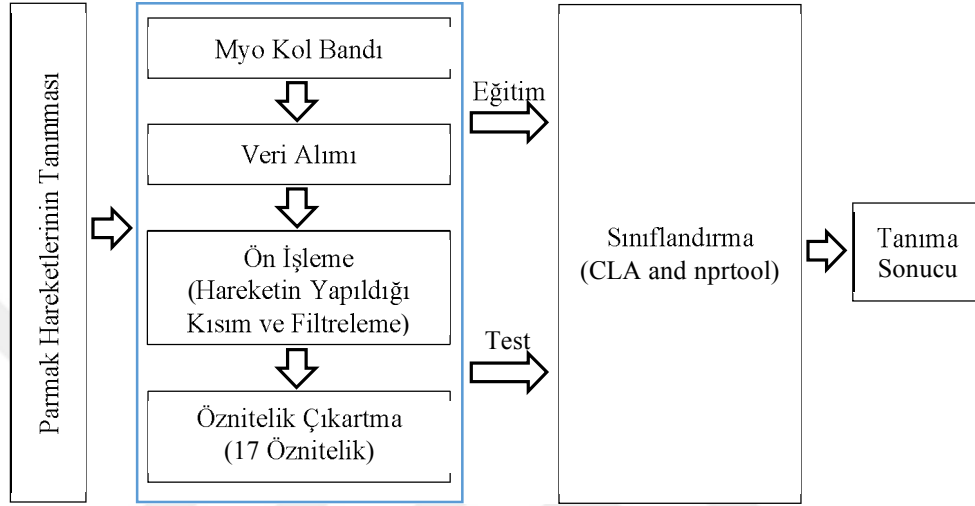
Kol kasları aynı anda ve birbirinden bağımsız olarak birçok hareketi (dönme, bükme, kavrama vb.) yapabilmektedir. Ön koldaki kaslar sarmal şeklinde birbirinin üstündedir ve 4 bölümden oluşur. Şekil 2.5’de ön koldaki kasları ve bölümlü yapı gösterilmektedir. Fleksör kasları ile bükme, ekstansör kasları ile germe hareketleri yapılabilmektedir. Kasların birbiri içerisinde ve katmanlı yapıda olması nedeniyle kas hareketlerinin incelenmesi zorlaşmaktadır.



Şekil 2.5. Ön koldaki kaslar A)1. Bölüm, B)2. Bölüm, C)3. Bölüm, D)4. Bölüm(Moore et al., 2015)

3. MATERYAL VE YÖNTEM


Myo kol bandı ile yüzey EMG ve jiroskop işaretleri alınarak veri seti oluşturulmuştur. Oluşturulan veri setine filtreleme, ön işleme ve öznitelik çıkartma işlemleri uygulanmıştır. Sonra veri seti sınıflandırıcıya gönderilerek sınıflandırma işlemleri uygulanmıştır. Bu çalışmada yapılan işlemler Şekil 3.1’de gösterilmektedir.



Şekil 3.1. Çalışmada kullanılan ana metodlar

3.1. Myo Bileklik

Myo bileklik giyilebilir teknolojik bir cihazdır. Düşük maliyetli, yüksek performanslı ve açık kaynak kodlu bir cihazdır. Myo kol bandı içerisinde 8 adet yüzey EMG sensörü, 9 eksenli IMU (Atalet Ölçüm Birimi) ve bir adet bluetooth modülü bulunmaktadır. IMU içerisinde 3 eksenli jiroskop sensörü, 3 eksenli manyetometre sensörü ve 3 eksenli ivmeölçer sensörü bulunmaktadır. yüzey EMG elektrotları insan ön kolundaki kas hareketlerini algılayarak myo bileklikte gömülü bluetooth modülü ile oluşturulan sisteme aktarabilmektedir (Visconti et al., 2018). Myo bileklik Şekil 3.2’de gösterilmektedir.



Şekil 3.2. Myo bileklik (Tepe et al., 2020)

Yüzey EMG işaretleri 200 Hz ve IMU verileri 50 Hz örnekleme frekansında alınabilmektedir (Srinivasan et al., 2018). Myo bileklik 93 gram ağırlığında ve 1,14 santimetre kalınlığındadır. Myo bileklik dairesel bir yapıdadır ve 34 ile 79 santimetre arasında genişletilebilmektedir. İşlemcisi ARM Cortex M4 ve pili lityum iyon pildir (Abreu et al., 2016).

3.2. İşaretlerin Ölçülmesi ve Kaydedilmesi

Yüzey EMG işaretleri yüzey elektrotlar ve iğne uçlu elektrotlar ile ölçülmektedir. Koldaki deri üzerinden yüzey EMG işaretleri ölçmek için yüzey elektrotları kullanılmaktadır. Yüzey elektrotları deriye yapıştırılır ve herhangi bir yara, acı veya ağrıya neden olmaz. Deri üzerine yerleştirildiğinden kas dokusunun üst kısmından veri alınmaktadır. Altta bulunan kaslardan bilgi alınmaz. İç içe geçmiş, sarmal ve bitişik kaslardan toplama bilgi alınabilmektedir. Tek bir kas hareketinden bilgi alınmaz (Farina et al., 2004).

Eğer işaret kol içindeki kaslardan alınacak ise iğne uçlu elektrotlar kullanılmaktadır. Yüzey EMG işaretlerinin alınması için konsantrik iğne, monopolar iğne ve doğrudan tek bir kas içine sokulmuş fiber iğne elektrotlar kullanılmaktadır. Deri içerisindeki kaslardan verileri almaktadır. Bu işlemde acı, ağrı ve yara oluşabilmektedir. Kas içerisinde uygun bir yere yerleştirilmeleri zor olabilmektedir. Kasa batırıldığında iğne hareket edebilmekte ve verimli sonuçlar alınamamaktadır (Çerçi, 2017). Yüzey elektrot ve iğne elektrot Şekil 3.3'de gösterilmektedir.



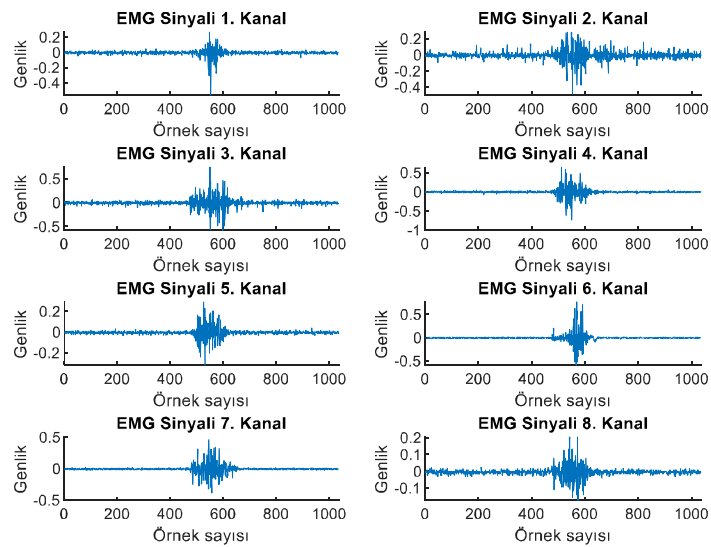
Şekil 3.3. EMG elektrotları (A) İğne elektrot (B) Yüzey elektrot(Taşar, 2016)

EMG işaretleri yüzey elektrot kullanan myo kol bandı ile alınmıştır. Veri seti 5 parmak hareketi ve 1 dinlenme hareketinden oluşmaktadır. Hareketler 30 kez tekrarlanmıştır. Çalışmada kullanılan hareketler Şekil 3.4'de gösterilmektedir. Sağlıklı 5 kadın ve 5 erkek katılımcıdan veri alınmıştır. Yaşları 15 ile 60 arasında değişmektedir. Veriler alınırken myo bileklik sağ kola takılmış ve katılımcılar sandalyeye oturmuşlardır. Kol yere dik olacak şekilde konumlandırılmıştır. Veriler 5

saniye boyunca alınmıştır. 5 saniye içerisinde katılımcılardan hareketi 1 saniye boyunca yapması ve hareketi yaptıktan sonra eli başlangıç pozisyonuna yani dinlenme haline getirmeleri istenmiştir. Oluşturulan yazılım ile işaretin genliği -1 ile +1 aralığında ve 8 kanallı olarak kaydedilmiştir. Yüzeysel EMG işaretleri ile oluşturulan veri seti 1800×8 boyutundadır. 10 kişi 6 hareket 30 tekrardan 1800 satırdan ve myo bileklikten 8 kanallı yüzeysel EMG verisi alındığı için 8 sütundan oluşan veri seti oluşturulmuştur. Ayrıca jiroskop verileri 3 kanal olarak alınmış ve veri setine eklenmiştir. Böylece veri seti 1800×11 olmuştur. 11 sütunda 8 yüzeysel EMG ve 3 jiroskop verisi bulunmaktadır.



Başparmak verisinin kaydedilen yüzeysel EMG işareti Şekil 3.5'de gösterilmektedir.




Şekil 3.5. Kaydedilen yüzeysel EMG işareti

Verilerin işlenmesinde MATLAB® R2018b programı ve 1.70 GHz Intel Core İ5-4210U CPU, 8 GB ram ve 64 bit işletim sistemi özelliklerine sahip bir dizüstü bilgisayar kullanılmıştır.


3.3. İşaretlerin Filtrelenmesi

Yüzey EMG işaretleri kaydedilirken oluşan gürültülerin giderilmesi ve daha iyi sınıflandırma başarımı gerçekleştirilebilmesi için filtreleme işlemi uygulanması gerekmektedir. Yüzey EMG işaretlerinin anlamlı frekans aralığı 10 Hz ile 400 Hz aralığında değişmektedir. 400 Hz'den yüksek frekanslar elektronik bileşenler tarafından üretilmekte ve yüzey EMG işaretinin etkisi azdır (Merlo and Campanini, 2010). Yüzey EMG işareti myo kol bandı ile 200 Hz örnekleme frekansı ile veri alınmıştır. Nyquist teoremine göre frekans bileşeni 100 Hz olmalıdır. Bu nedenle 10 Hz kesim frekansında yüksek geçiren filtre kullanılarak filtreleme gerçekleştirilmiştir. Ayrıca myo kol bandı içerisinde şebeke gürültüsü engellemek amacıyla 50 Hz kesim frekansına sahip çentik filtre kullanılmıştır (Pizzolato et al., 2017). Filtrelenmemiş yüzey EMG işaretinin frekans düzleminde gösterimi Şekil 3.6'da gösterilmektedir.



Şekil 3.6. Filtrelenmemiş yüzey EMG işaretinin frekans düzleminde gösterimi

Filtrelenmiş yüzey EMG işaretinin frekans düzleminde gösterimi Şekil 3.7'de gösterilmektedir. Bu grafikte 0-10 Hz aralığı filtrelendiği görülmektedir. Ayrıca 50 Hz şebeke frekansı da filtrelenmiştir. Veri seti oluşturulduktan sonra bu filtreleme işlemi uygulanmıştır.



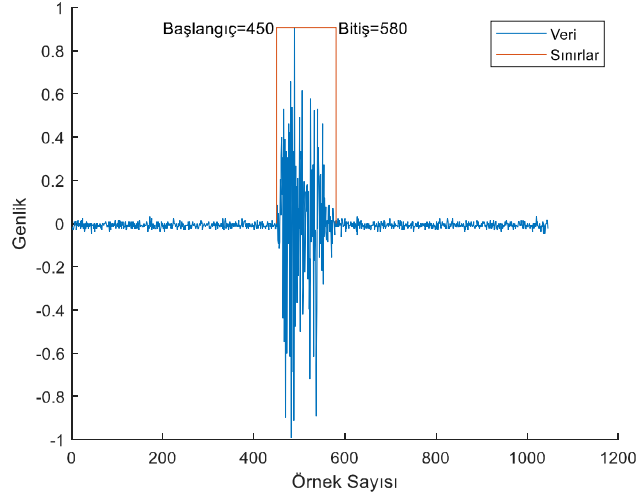
Şekil 3.7. Filtrelenmiş yüzey EMG işaretinin frekans düzleminde gösterimi

3.4. Ön İşleme

Hareketler 5 saniye uzunluğundaki kayıtlar içerisinde yaklaşık olarak 1 saniyelik bölümlerden oluşmaktadır. Bu nedenle işaret içerisinde hareketin yapıldığı kısım belirlenmesi gerekir. Ön bölümde hareketin yapıldığı kısmı belirleme ve pencerelere ayırma kısımları anlatılmıştır.

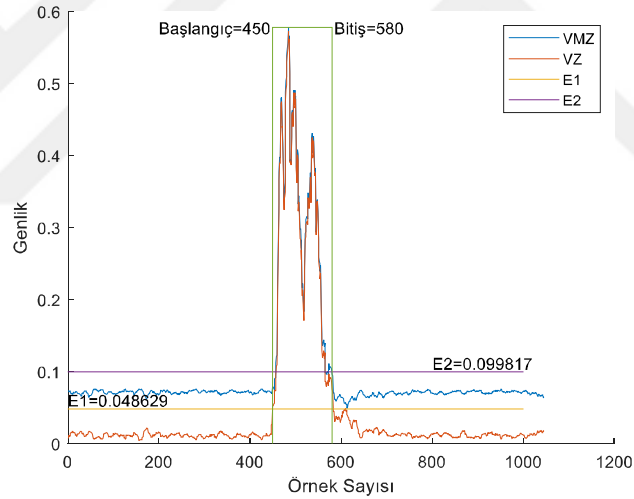
3.4.1. Hareketin Yapıldığı Kısımın Belirlenmesi

Yüksek sınıflandırma başarımı elde etmek için parmak hareketlerin yapıldığı kısmın belirlenmesi gerekmektedir (Xu et al., 2018; Z. Zhang et al., 2019). Bu kısmı belirlerken iki eşik noktası belirlenmiştir. İlk eşik (E1) yüzey EMG işaretinin zarfi alınarak (VZ) ortalamasının alınmış halidir. İkinci eşik (E2) belirlenirken yüzey EMG işaretinin önce mutlak değeri alınmış ve sonra zarfi alınarak (VMZ) ortalaması belirlenmiştir. Hareketin başladığı noktayı bulabilmek için ilk eşik kullanılmıştır. Verinin eşik değerini geçtiği nokta başlangıç değeri olarak kaydedilmiştir. Hareketin bittiği noktayı bulabilmek için ikinci eşik kullanılmıştır. Başlangıç değerinin bulunduğu veriden sonraki veriden başlanarak tarama yapılmış ve işaretin değerinin ikinci eşik değerinden az olduğu değer bitiş noktası olarak belirlenmiştir. Böylece başlangıç ve bitiş noktası bulunmuştur. Böylece başlangıç ve bitiş noktası bulunmuştur. Sınırları belirlenmiş hali Şekil 3.8’de gösterilmektedir.



Şekil 3.8. Sınırları belirlenmiş yüzey EMG işareti

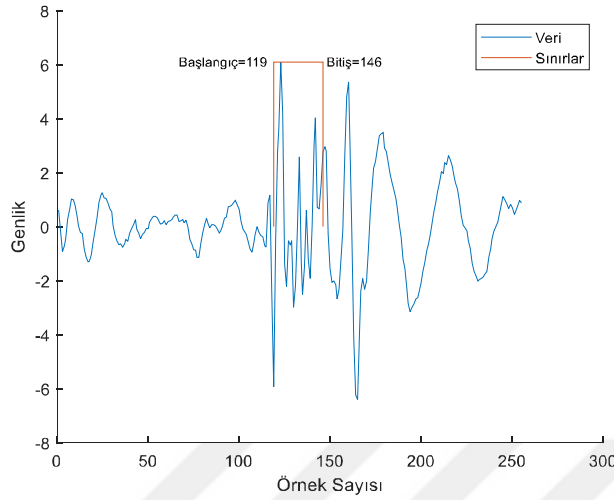
Yüzey EMG işaretinin zarfının alınmış hali ve eşik noktaları Şekil 3.9'da gösterilmektedir.



Şekil 3.9. Yüzey EMG işaretinin eşik noktaları ve zarfının alınmış hali

Jiroskop verilerinin sınırlarının belirlenmiş gösterimi Şekil 3.10'da gösterilmektedir. Jiroskop verisinin örnekleme frekansı 50 Hz ve yüzey EMG verisinin örnekleme frekansı 200 Hz'dir. Jiroskop verilerinin başlangıç noktası belirlenirken yüzey EMG verisinin 8 kanalının başlangıç noktası belirlenir. 8 kanal için belirlenen başlangıç noktalarından en büyük değer hesaplanır ve bu veri 4'e bölünerek jiroskop verisinin başlangıç noktası olarak belirlenir. Jiroskop verilerinin bitiş noktası belirlenirken yüzey EMG verisinin 8 kanalının bitiş noktası belirlenir. 8 kanal için belirlenen bitiş noktalarından en küçük değer hesaplanır ve bu veri 4'e bölünerek jiroskop verisinin bitiş noktası olarak belirlenir. 4'e bölünmesinin nedeni yüzey EMG

verisinin frekansının jiroskop verisinin frekansının 4 katı olmasından kaynaklanmaktadır.



Şekil 3.10. Sınırları belirlenmiş jiroskop işareti

3.4.2. Pencereleme Bölme


Pencereleme bölme işlemi gerçek zamanlı çalışan sistemlerde hızlı sonuçlar alabilmek amacıyla yapılmıştır. Gerçek zamanlı veri işleminde belirli bir veri kümesi oluşturulması gerekir. Pencereleme ayrılan işaret özneliği çıkartılabilecek hale gelmiştir. Pencere sayısı aşağıdaki denklemde gösterilmektedir (Khushaba et al., 2012).

$$Pencere\ Sayısı = \frac{Veri\ Uzunluğu - Pencere\ Boyutu}{Pencere\ Artışı} + 1 \quad (3.1)$$

Pencereleme bölme işlemi iki yöntemden oluşmaktadır. Bunlar örtüşen pencereleme ayırma yöntemi ve bitişik pencereleme ayırma yöntemidir.

3.4.2.1. Örtüşen pencereleme ayırma yöntemi


Yüzey EMG işareti pencereleme pencereleme ayrıştırılır. Bu yöntemde pencere oluşturulurken geçilen pencerenin son kısmının verileri yeni pencereye eklenmektedir. Buna aynı zamanda kayan pencere de denilmektedir. Örtüşen pencereleme Şekil 3.11'de gösterilmektedir.



Şekil 3.11. Örtüşen pencereleme gösterimi (Englehart and Hudgins, 2003)

3.4.2.2. Bitişik pencereleme ayırma yöntemi

Bu yöntemde ise pencere oluşturulurken geçilen pencerenin devamı şeklinde yeni pencere oluşturulur. Geçilen pencereden herhangi veri yeni pencerede bulunmaz. Bitişik pencereleme Şekil 3.12'de gösterilmektedir.



Şekil 3.12. Bitişik pencereleme gösterimi (Englehart and Hudgins, 2003)

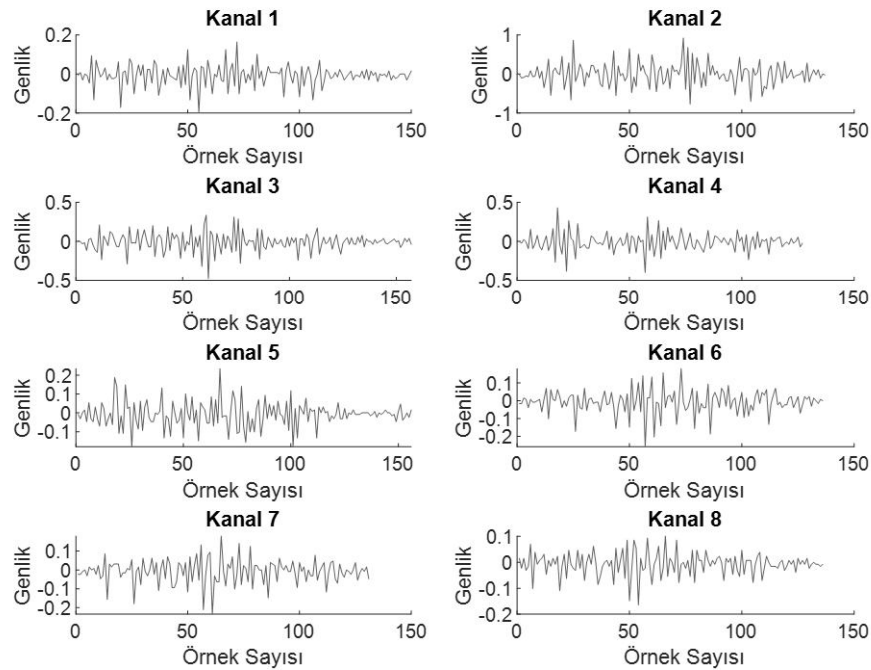
Bitişik ve örtüşen pencerelemede gösterilen şekillerde w sınıflandırma zamanını D ise karar verme zamanını göstermektedir. Gerçek zamanlı işlemlerde bitişik pencerede veri alınırken pencereler arasında veri kaybı olabilmektedir ancak örtüşen pencerede zaman kaybı olsa bile veri kaybı olmamaktadır (Englehart and Hudgins, 2003).

3.5. Öznitelik Çıkarma

Öznitelik oluşturma yüzey EMG işaretlerini daha anlamlı verilerle ifade etme yöntemidir. Böylece veri kümesi daha az veri ile oluşturulur, niteliğini kaybetmez ve sınıflandırma işlemi hızlandırılmış olur. Öznitelik seçimi sınıflandırma başarımını etkileyen en önemli faktörlerdendir. Yüzey EMG işareti üzerinde yapılan son

işlemlerden biridir. Bu işlem sonucunda veriler sınıflandırıcı yöntemlerine gönderilir.

Yüzey EMG işaretlerinin analizinde genel olarak üç çeşit öznitelik seçim alanı bulunmaktadır. Bunlar zaman alanı öznitelikleri, frekans alanı öznitelikleri ve zaman-frekans alanı öznitelikleridir. Bu çalışmada zaman alanı öznitelikleri kullanılmıştır. Şekil 3.13’de başparmak yüzey EMG verisi gösterilmektedir. Başparmak verisi filtrelenmiş ve hareketin yapıldığı kısım gösterilmektedir. Öznitelikler kısmında verilen şekiller başparmak verisi kullanılarak oluşturulmuştur. Veri 100 ms’lik pencereye bölünmüş 20 örnekten oluşmaktadır. Veri kaybı olmaması için %50 örtüşme kullanılmıştır.




Şekil 3.13. Başparmak yüzey EMG verisinin gösterimi

3.5.1. Ortalama Mutlak Değer

Ortalama mutlak değer en yaygın kullanılan yüzey EMG özniteliklerinden biridir (Akhmadeev et al., 2017; Too et al., 2019). İlk olarak oluşturulan penceredeki verilerin mutlak değeri alınır. Mutlak değeri alınan verilerin ortalaması alınarak ortalama mutlak değer hesaplanır ve denklemi 3.2’de gösterilmektedir.

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

Ortalama mutlak değer denkleminde L pencere içerisindeki toplam veri sayısı, x_i pencere içerisindeki veriyi ifade etmektedir. Ortalama mutlak değer özniteliği Şekil 3.14’de gösterilmektedir.




Şekil 3.14. MAV özniteliğinin gösterimi

3.5.2. Geliştirilmiş Ortalama Mutlak Değer

Ortalama mutlak değer öznitelik denkleminin geliştirilmiş halidir (Too et al., 2019). Ortalama mutlak değer denklemini geliştirmek için bir p fonksiyonu kullanılmıştır. Geliştirilmiş ortalama mutlak değer denkleminde L pencere içerisindeki toplam veri sayısı, x_i pencere içerisindeki veriyi ifade etmekte ve denklem 3.3'de verilmektedir. EMAV özniteliği Şekil 3.15'de gösterilmiştir.

$$EMAV = \frac{1}{L} \sum_{i=1}^L |(x_i)^p|, \quad p = \begin{cases} 0.75, & 0.2L \leq i \leq 0.8L \\ 0.5, & \text{diğer durumlar} \end{cases} \quad (3.3)$$

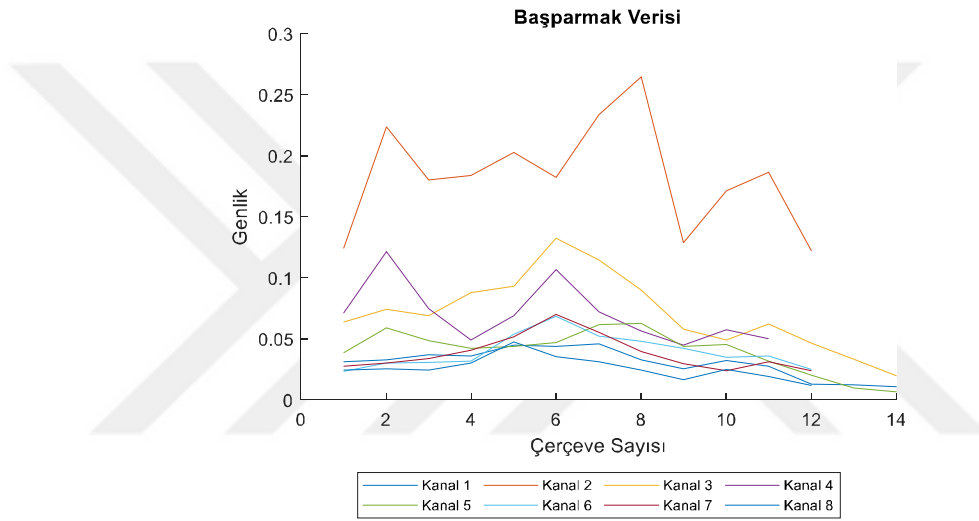


Şekil 3.15. EMAV özniteliğinin gösterimi

3.5.3. Modifiye Edilmiş Ortalama Mutlak Değer 1

Ortalama mutlak değerin değiştirilmiş halidir (Caesarendra et al., 2018). Bu denklemde w_i fonksiyonu tanımlanmış ve çarpılarak modifiye edilmiş ortalama mutlak değer 1 öznitelik denklemi oluşturulmuştur. Modifiye Edilmiş Ortalama Mutlak Değer 1 denkleminde L pencere içerisindeki toplam veri sayısı, x_i pencere içerisindeki veriyi ifade etmekte ve denklem 3.4’de verilmektedir. Modifiye Edilmiş Ortalama Mutlak Değer 1 özniteliği Şekil 3.16’da gösterilmektedir.

$$MMAV1 = \frac{1}{L} \sum_{i=1}^L w_i * |x_i|, \quad w_i = \begin{cases} 1, & 0.25L \leq i \leq 0.75L \\ 0.5, & \text{diğer durumlar} \end{cases} \quad (3.4)$$




Şekil 3.16. MMAV1 özniteliğinin gösterimi

3.5.4. Modifiye Edilmiş Ortalama Mutlak Değer 2

Ortalama mutlak değer denkleminin farklı bir halidir (Phinyomark et al., 2012). w_i fonksiyonu denkleme eklenerek modifiye edilmiş ortalama mutlak değer 2 özniteliği oluşturulmuştur. Modifiye edilmiş ortalama mutlak değer 2 denkleminde L pencere içerisindeki toplam veri sayısı, x_i pencere içerisindeki veriyi ifade etmekte ve denklem 3.5’de verilmektedir. Modifiye edilmiş ortalama mutlak değer 2 özniteliği Şekil 3.17’de verilmiştir.

$$MMAV2 = \frac{1}{L} \sum_{i=1}^L w_i * |x_i|, \quad w_i = \begin{cases} 1, & 0.25L \leq i \leq 0.75L \\ \frac{4i}{L}, & i < 0.25L \\ \frac{4(i-L)}{L}, & \text{diğer durumlar} \end{cases} \quad (3.5)$$



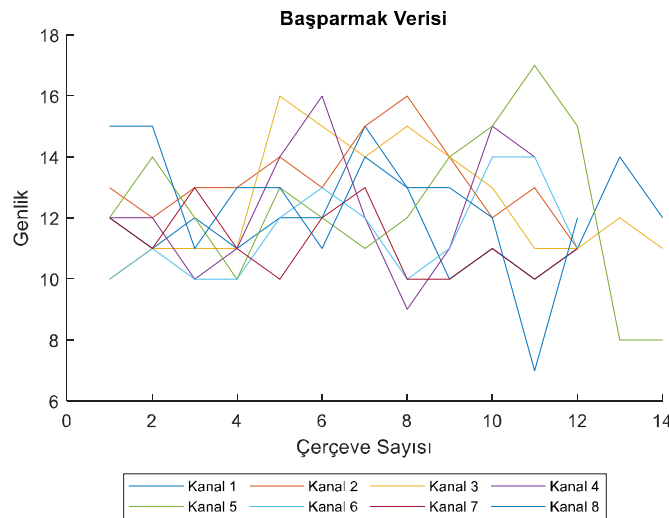
Şekil 3.17. MMAV2 özneliğinin gösterimi

3.5.5. Eğim İşareti Değişikliği

Yüzey EMG işaretlerinde sıklıkla kullanılan özneliklerden biridir (Côté-Allard et al., 2019). Yüzey EMG işaretinin frekans bilgisini temsil etmektedir. Eğim işareti değişikliği yönteminde eğimin işaretini kaç kez değiştirdiği hesaplanarak bulunur. Denklemi 3.6'da verilmektedir.

$$SSC = \sum_{i=2}^{N-1} [f[(x_i - x_{i-1}) * (x_i - x_{i+1})]], \quad f(x) = \begin{cases} 1, & x \geq \text{eşik} \\ 0, & x < \text{eşik} \end{cases} \quad (3.6)$$

Eğim işareti değişikliği denkleminde L pencere içerisindeki toplam veri sayısını, x_i pencere içerisindeki veriyi ifade etmektedir. Eğim işareti değişikliği özneliği Şekil 3.18'de verilmektedir. Öznelik değerlerinin genliğinin yüksek olmasının nedeni pencere içerisindeki verilerin denklemin içerisinde toplanmasından kaynaklanmaktadır.




Şekil 3.18. SSC özneliğinin gösterimi

3.5.6. Sıfır Geçişi Sayısı

Sıfır geçiş sayısı bir yüzey EMG işaretinin sıfır noktasını kaç kere geçtiği hesaplayan denklemdir (Fonseca et al., 2017). Zaman alanında frekans bilgisinin bir ölçütüdür. Bu denklem için belirli bir eşik belirlenebilir ve belirlenen eşikten geçme sayısı sıfır geçiş sayısı olarak hesaplanabilir. Sıfır geçiş sayısını hesaplamak için signum fonksiyonu kullanılır. Belirlenen eşik noktasında ve eşik noktasını geçtiğinde signum fonksiyonu 1 değerini ve eşik altına ise 0 değerini vermektedir. Her 1 değerinde sıfır geçiş sayısı 1 artmaktadır. Eşik tasarlanan sisteme göre istenildiği gibi değiştirilebilir. Denklemi 3.7’de verilmektedir.

$$ZC = \sum_{i=1}^{N-1} [sgn(x_i * x_{i+1}) \cap |x_i - x_{i+1}|] \geq eşik \quad (3.7)$$
$$sgn(x) = \begin{cases} 1, & x \geq eşik \\ 0, & x < eşik \end{cases}$$

L pencere içerisindeki toplam veri sayısını, x_i ise pencere içerisindeki veriyi temsil etmektedir. Sıfır geçiş sayısı özneliği Şekil 3.19’da gösterilmektedir.




Şekil 3.19. ZC özneliğinin gösterimi

3.5.7. Dalga Formu Uzunluğu

Dalga formu uzunluğu yüzey EMG işaretlerinde sıklıkla kullanılan özneliklerden biridir (Wahid et al., 2018). İşaretin karmaşıklığının bir ölçüsü olarak da ifade edilmektedir. Denklemde L pencere içerisindeki toplam veri sayısını, x_i pencere içerisindeki verileri ifade etmektedir. Denklemi 3.8’de verilmektedir.

$$WL = \sum_{i=2}^L |x_i - x_{i-1}| \quad (3.8)$$

Dalga formu uzunluğu özneliği Şekil 3.20’de gösterilmektedir. Dalga formu uzunluğu ardışık verilerin farklarının toplamı olduğundan genliği yüksektir.




Şekil 3.20. WL özneliğinin gösterimi

3.5.8. Geliştirilmiş Dalga Boyu

Geliştirilmiş dalga boyu özneliği dalga formu uzunluğu öznelik denkleminin geliştirilmiş bir versiyonudur (Too et al., 2019). Denklemi geliştirmek için p fonksiyonu eklenmiştir. Denklemi 3.9’da verilmektedir. Geliştirilmiş dalga boyu özneliği Şekil 3.21’de gösterilmiştir.

$$EWL = \frac{1}{L} \sum_{i=1}^L |(x_i - x_{i-1})^p|, \quad p = \begin{cases} 0.75, & 0.2L \leq i \leq 0.8L \\ 0.5, & \text{diğer durumlar} \end{cases} \quad (3.9)$$




Şekil 3.21. EWL özneliğinin gösterimi

3.5.9. Etkin Değer

Etkin değer yüzey EMG verilerinin öznelik çıkartma yöntemlerinden biridir ve yaygın olarak kullanılır (Yang et al., 2017). Etkin değer pencere içerisindeki işaretin karelerinin toplamının örnek sayısına bölündükten sonra karekökünün alınmasıyla elde edilmektedir. Aynı zamanda işaretin gücü de demektir. Denklemi 3.10'da verilmektedir.

$$RMS = \sqrt{\frac{1}{L} \sum_{i=1}^L x_i^2} \quad (3.10)$$

Etkin değerdeki L pencere içerisindeki toplam veri sayısını, x_i pencere içerisindeki örnekleri ifade etmektedir. Etkin değer özneliği Şekil 3.22'de gösterilmektedir.




Şekil 3.22. RMS özneliğinin gösterimi

3.5.10. Ortalama Genlik Değişimi

Ortalama genlik değişimi popüler yüzey EMG özneliklerindedir (Phinyomark et al., 2012). Ortalama genlik değişimi denklemi ardışık verilerin farkının mutlak değerinin ortalamasıdır. Bu denklem dalga uzunluğu denklemini benzemektedir. Ortalama genlik değişimi denklemindeki L pencere içerisindeki toplam veri sayısını, x_i pencere içerisindeki örnekleri ifade etmektedir. Denklemi 3.11'de verilmektedir. Ortalama genlik değişimi özneliği Şekil 3.23'de verilmektedir.

$$AAC = \frac{1}{L} \sum_{i=1}^{L-1} |x_{i+1} - x_i| \quad (3.11)$$




Şekil 3.23. AAC özneliğinin gösterimi

3.5.11. Mutlak Standart Sapma Değerlerinin Farkı

Mutlak standart sapma değerlerinin farkı dalga boyunun standart sapma değeridir (Caesarendra et al., 2018). Etkin değer öznelik denklemine benzerlik göstermektedir. Denklemi 3.12’de verilmektedir. Mutlak standart sapma değerlerinin farkı denklemindeki L pencere içerisindeki toplam veri sayısını, x_i pencere içerisindeki örnekleri ifade etmektedir. Mutlak standart sapma değerlerinin farkı özneliği Şekil 3.24’de verilmiştir.

$$DASDV = \sqrt{\frac{1}{L-1} \sum_{i=1}^{L-1} (x_{i+1} - x_i)^2} \quad (3.12)$$




Şekil 3.24. DASDV özneliğinin gösterimi

3.5.12. Log Detektör

Log detektör kas kasılma kuvvetini tahmin etmede iyi bir özneliktir. Denklemi 3.13'de verilmektedir. Log detektör denklemindeki L pencere içindeki toplam veri sayısını, x_i pencere içerisindeki örnekleri göstermektedir. Log detektör özneliği Şekil 3.25'de verilmektedir.

$$LOG = \exp\left(\frac{1}{L} \sum_{i=1}^L \log(|x_i|)\right) \quad (3.13)$$




Şekil 3.25. LOG özneliğinin gösterimi

3.5.13. Miyopülse Yüzde Oranı

Yüzey EMG işaretinin mutlak değerinin tanımlanan eşik değerini aştığı noktalarda 1 değerini almaktadır. Bu verilerin ortalaması alınarak miyopülse yüzde oranı özneliği hesaplanır (Castiblanco et al., 2016; Too et al., 2019). Denklemi 3.14'de verilmektedir. Miyopülse yüzde oranı denklemindeki L pencere içerisindeki toplam veri sayısını, x_i pencere içerisindeki örnekleri ifade etmektedir. Miyopülse yüzde oranı özneliği Şekil 3.26'da gösterilmektedir.

$$MYOP = \frac{1}{L} \sum_{i=1}^L f(|x_i|), \quad f(x) = \begin{cases} 1, & x \geq \text{eşik} \\ 0, & x < \text{eşik} \end{cases} \quad (3.14)$$




Şekil 3.26. MYOP özniteliğinin gösterimi

3.5.14. Basit Kare İntegral

Basit kare integral özniteliği yüzey EMG işaretinin enerjisinin endeksi olarak adlandırılır (K. S. Krishnan et al., 2017). Pencere içerisindeki yüzey EMG verilerinin karelerinin toplamı olarak hesaplanır. Denklemi 3.15’de verilmektedir. Basit kare integrali denklemindeki L pencere içerisindeki toplam veri sayısını, x_i pencere içerisindeki örnekleri ifade etmektedir. Basit kare integral özniteliği Şekil 3.27’de verilmiştir.

$$SSI = \sum_{i=1}^L x_i^2 \quad (3.15)$$




Şekil 3.27. SSI özniteliğinin gösterimi

3.5.15. Varyans

Varyans özneliği yüzey EMG işaretinin güç endekslerinden biridir (Singhvi and Ren, 2018; Z. Zhang et al., 2019). Yüzey EMG işaretlerinin karelerinin ortalaması olarak adlandırılır. Denklemi 3.16'da verilmektedir. Varyans özneliği denklemindeki L pencere içerisindeki toplam veri sayısını, x_i pencere içerisindeki örnekleri ifade etmektedir.

$$VAR = \frac{1}{L-1} \sum_{i=1}^L x_i^2 \quad (3.16)$$

Varyans özneliği Şekil 3.28'de gösterilmektedir. Öznelik verilerinin genliği çok küçüktür. Bunun sebebi yüzey EMG işaretinin genliğinin az olması nedeniyle işaretin karesinin alınması genliği daha da küçültmektedir.



Şekil 3.28. VAR özneliğinin gösterimi


3.5.16. Willison Genliği

Willison Genliği işaretin frekans bilgisinin bir ölçütü olarak da tanımlanmaktadır (Phinyomark et al., 2012). Willison Genliğinde pencere içerisindeki ardışık iki veri alınır. Bu verilerin arasındaki fark hesaplanır. Hesaplanan verinin mutlak değeri alınır. Oluşturulan değer eşik noktasından büyükse 1 küçükse 0 değerini alır. Yani ardışık iki verinin farkının mutlak değeri belirlenen eşik değerini kaç kez geçtiği hesaplanır. Denklemi 3.17'de verilmektedir.

$$WAMP = \sum_{i=2}^L f(|x_i - x_{i-1}|), \quad f(x) = \begin{cases} 1, & x \geq \text{eşik} \\ 0, & x < \text{eşik} \end{cases} \quad (3.17)$$

Willison Genliği denklemindeki L pencere içerisindeki toplam veri sayısını, x_i pencere içerisindeki verileri ifade etmektedir. Willison Genliği özneliği Şekil 3.29'da

gösterilmektedir.




Şekil 3.29. WAMP özneliğinin gösterimi

3.5.17. Maksimum Fraktal Uzunluk

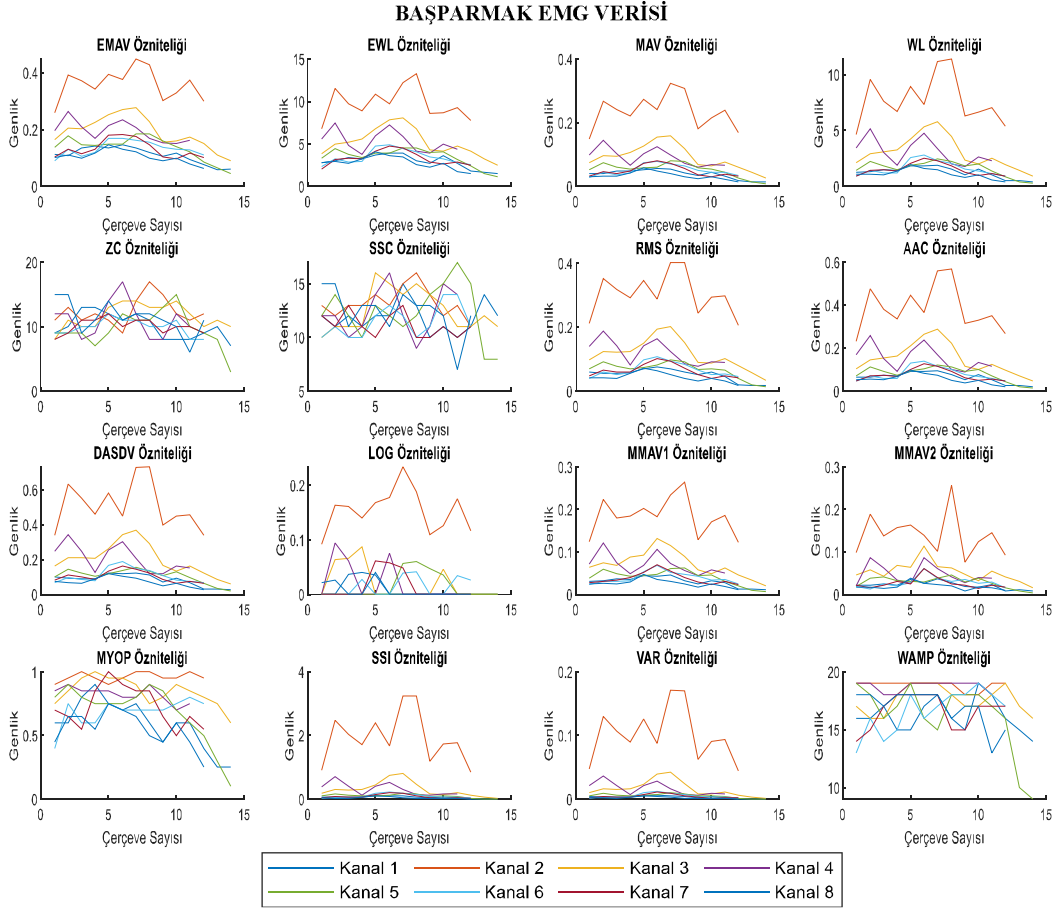
Maksimum fraktal uzunluk özneliği düşük seviyeli kas kasılmasının aktivasyonunu ölçmek için kullanılmaktadır (Too et al., 2019). Denklemi 3.18’de gösterilmektedir. Maksimum fraktal uzunluk denklemindeki L pencere içerisindeki toplam veri sayısını, x_i pencere içerisindeki verileri ifade etmektedir. Maksimum fraktal uzunluk özneliği Şekil 3.30’da gösterilmektedir.

$$MFL = \log_{10} \left(\sqrt{\sum_{i=1}^{L-1} (x_{i+1} - x_i)^2} \right) \quad (3.18)$$



Şekil 3.30. MFL özneliğinin gösterimi

Başparmak verisinin özneliklerinin alınmış gösterimi Şekil 3.31’de verilmektedir. 16 öznelik birlikte verilmektedir. 8 kanallı yüzey EMG verisi kullanılmaktadır. Her kanalın özneliği birlikte gösterilmektedir.



Şekil 3.31. Özneliklerin birlikte gösterimi

3.6. Ardışıl İleri Yönlü Öznelik Seçimi Yöntemi

Ardışıl ileri yönlü öznelik seçimi yönteminde yüksek başarımlı veren özneliğin yanına diğer öznelik eklenerek sınıflandırma yapılır. Başarımlı artıp artmadığı incelenir. Son özneliğe kadar bu işlem gerçekleştirilir. En yüksek başarımlı veren öznelik grubu seçilir (Stańczyk, 2015).

3.7. İşaretlerin Sınıflandırılması

Sınıflandırma işlemi insanların öğrenme yeteneğinin makinalara ve oluşturulan sistemlere kazandırılmasıdır. Sınıflandırma işleminin gerçekleştirilebilmesi için ilk olarak bir veri oluşturulması veya toplanması gerekir. Veri değerlendirilir ve analiz edilir. Veriler incelenerek gerekli bilgiler çıkarılarak model oluşturulur. Oluşturulan model eğitilir ve test edilerek performansı ölçülür. Yüksek performanslı modeller oluşturmak amaçlanır.

3.7.1. Karar Ağaçları

Karar ağacında her yaprak düğümü bir sınıfı temsil etmektedir. Yapırsız düğümlerde ise sınıfların niteliklerine ilişkin kurallara dayanarak oluşturulan ağaç yapısına göre sınıflandırılır. Ağaç yapısı kök düğüm, iç düğüm ve yaprak düğümü olarak üç bölümden oluşur. Başlangıçta verilerin öznitelikleri kök düğümüne yerleştirilir. Farklı özniteliklerde ağaç farklı dallara ayrılır. Veriler hangi sınıfa ait ise yaprak düğümlerine gönderilir. Karar ağaçları bu şekilde oluşturulur (X. Zhang et al., 2011).

Karar ağaçları algoritmaları biyomedikal işaretleri sınıflandırmak için yaygın olarak kullanılmaktadır. Bu çalışmada kaba ağaç, orta ağaç ve güzel ağaç sınıflandırıcıları kullanılmıştır. Karmaşık veri yapılarında iyi ve hızlı performans vermektedir. Verileri sınıflandırırken aradığı sınıfı sıralı dal yapısından dolayı hızlı olarak bulabilmektedir. Bu yapısından dolayı gerçek zamanlı sistemlerde önemli avantaj oluşturmaktadır (Gokgoz and Subasi, 2015).


3.7.2. Diskriminant Analizi

Diskriminant analizi yöntemi diskriminant fonksiyonlarını kullanan istatistiksel sınıflandırma tekniğidir. Diskriminant fonksiyonlar sınıflar arasında sınırlar oluşturmaktadır ve ayırım yaparak sınıflandırma işlemini gerçekleştirmektedir. Uygulanması kolay ve hızlıdır (Alkan and Günay, 2012).

3.7.3. Destek Vektör Makineleri

Klasik öğrenme yaklaşımlarında eğitim setindeki hata oranı en az yapmak için oluşturulmaktadır. Bu yönteme ampirik risk minimizasyonu denilmektedir. Destek vektör makinaları ise istatistiksel öğrenme teorisinden dolayı yapısal risk minimizasyonu prensibine dayanmaktadır. Bu yaklaşım ile genelleme yeteneği artmakta ve hata en aza indirgenmektedir (Widodo and Yang, 2007). Destek vektör makinaları iki sınıfa ait verileri birbirinden en uygun şekilde ayıran hiper düzlemler belirlemektedir. Yüksek genelleme yeteneğine sahip olduğundan büyük ve karmaşık veri setlerinde kolayca uygulanabilmektedir. Sistem Tasarımlarında sıkça kullanılan yöntemlerden biridir. Lineer veriler ve lineer olmayan veriler için birçok farklı varyasyonu bulunmaktadır (Bağcı, 2016). Bu çalışmada farklı destek vektör makinaları ile sınıflandırma işlemi yapılmıştır. Destek vektör makinalarının sınıflandırma yöntemi Şekil 3.32'de gösterilmektedir. Bu çalışmada CSVM, MGSVM ve QSVM yöntemleri ile sınıflandırma yapılmıştır. Kübik SVM (CSVM) sınıflandırıcısının tahmini hızlıdır. Hafıza kullanımı orta seviyededir. Model esnekliği normaldir. Orta Ölçekli Gauss

SVM (MGSVM) de orta ayrımlar çekirdek ölçeği olarak ayarlanmaktadır. Yorumlanması zor ve model tahmini hızlıdır. Kuadratik SVM (QSVM) hafıza kullanımını fazla ve model tahmini hızlıdır. Yorumlanması zordur (MathWorks, 1994).




Şekil 3.32. Destek vektör makinaları sınıflandırma sistemi(Bağcı, 2016)

3.7.4. K-En Yakın Komşu Sınıflandırıcıları

K-en yakın komşu sınıflandırıcısı en yaygın ve bilinen desen sınıflandırma yöntemlerinden biridir. Sınıflandırmalarda problemlerinde sade ve etkin olmasından dolayı tercih edilmektedir. Veriler dağılımı hakkında herhangi bir şey bilinmiyorsa bu sınıflandırma yöntemi ilk sırada tercih edilmelidir (Al-Faiz et al., 2010). KNN uzaklığa bağlı olarak sınıflandırma yapan bir algoritmadır. Bir veriyi sınıflandırmak için ve etrafındaki en yakın k tane verinin sınıfına bakmakta, en yakın ve en çok hangi veri bulunuyorsa veriyi o sınıfa dahil etmektedir. Örneğin k değerini 5 seçtiğimizde KNN yönteminde sınıflandırılacak veri etrafında en yakın 5 veriyi seçer. 5 veri içerisinde aynı sınıfa ait en fazla sayıdaki veri sınıfını belirler. Sınıflandırılacak verinin sınıfı belirlenen veri sınıfına eklenir. Sınıflar belirlenirken çeşitli uzaklık fonksiyonları kullanılmaktadır. Euclidean, Manhattan ve Minkowski uzaklık fonksiyonları ve Hamming mesafesi bunlardan bazılarıdır. KNN sınıflandırma yöntemi Şekil 3.33'de gösterilmektedir. Bu çalışmada WKNN, FKNN ve SKNN yöntemleri ile sınıflandırma yapılmıştır. Ağırlıklı KNN(WKNN) yöntemi KNN'nin farklı bir versiyonudur. WKNN en yakın k noktasını belirlerken çekirdek fonksiyonu kullanmaktadır. Kullanılan fonksiyon ters mesafe fonksiyonu olarak da adlandırılmaktadır. Bu fonksiyon ile noktalara ağırlık atamaktadır. Noktaların mesafesi arttıkça ağırlığın değeri azalmaktadır. Verilen ağırlıklara göre sınıflandırma yapılmaktadır. Hassas KNN (FKNN) de sınıflar arasında ince detaylar mevcuttur. Komşuların sayısı 1 olarak belirlenmiştir. Yorumlanması zordu ve orta büyüklükte hafıza kaplamaktadır. Altuzay

KNN (SKNN) birçok yönteme göre iyi sonuç vermektedir. Tahmin hızı normal ve hafıza kullanımı ortadır. Yorumlanabilmesi zordur (MathWorks, 1994).



Şekil 3.33. KNN sınıflandırıcısının gösterimi (Bağcı, 2016)

Bu çalışmada, Matlab 2018b © sınıflandırma öğreticisi uygulaması (Classification Learner Application-CLA) kullanılarak sınıflandırma yapılmıştır. Veriler 100 ms'lik ve %50 örtüşmeli pencerelere ayrıştırılarak öznitelikleri hesaplanmıştır. Sınıflandırma işlemi için veri seti eğitim verisi ve test verisi olarak iki eşit parçaya bölünmüştür. Veri setindeki matrisin tek sayılı satırları eğitim verileri için çift sayılı satırları test verisi için kullanılmıştır. Eğitim seti için sınıflandırma öncesinde etiket matrisi eklenmiştir. Etiket matrisi hareketlerin hangi sınıfa ait olduğunu göstermektedir. Başparmak hareketi için 1, işaret parmak hareketi için 2, orta parmak hareketi için 3, yüzük parmak hareketi için 4, serçe parmak hareketi için 5 ve dinlenme hareketi için 6 sayıları etiket olarak oluşturulmuştur. Etiket matrisi eğitim verisinin son sütununa eklenmiştir. K-kez çapraz doğrulama sayısı 50 olarak seçilmiştir.

3.7.5. Yapay Sinir Ağları

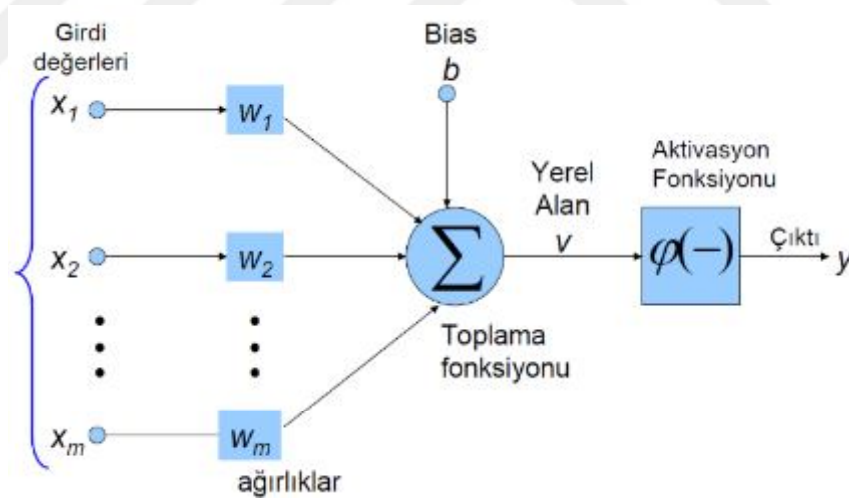
Yapay sinir ağları merkezi sinir sisteminin bilgi birikimini, hafızasını ve karar verme yeteneğini taklit etmek amacıyla tasarlanmış yapılardır. Geleneksel hesaplama yöntemlerinin zorlandığı karmaşık problemleri çözebilmektedir. YSA'nın verimliliği, sağlamlığı ve gerçek sistemlere uygulanabilir olması sınıflandırma, analiz ve karar desteği amacıyla birçok farklı alanda kullanımını arttırmakta ve hızla yaygınlaşmasına olanak sağlamaktadır (Tkáč and Verner, 2016).

YSA, bir problemi çözmek için çok sayıda birbirine bağlı birlikte çalışan nöronlardan oluşmaktadır. İnsanlar bir problemle karşılaştığında beyin çözüm üretmek

için düşünür, gözlemler ve eski bilgileri karşılaştırmaktadır. YSA da beyin gibi gözlemler ve bilgileri karşılaştırarak bir çözüm yöntemi oluşturmakta ve çözüm üretmeye çalışmaktadır. Biyolojik sistemlerde olduğu gibi YSA nöronlar arasında bağlantı kurarak öğrenmeye amaçlamaktadır. YSA çok boyutlu, karmaşık, problemlili, eksik, kusurlu, kesin olmayan hatalı ve çözüm için herhangi bir modelin olmadığı ve algoritmaların oluşturulamadığı durumlarda yağın olarak kullanılmaktadır. Havacılık, otomotiv, savunma, elektronik, eğlence, sağlık, robotik üretim gibi birçok farklı alanda sıklıkla kullanılmakta ve hayatın her alanında kullanımı gün geçtikçe artmaktadır (Ayaz, 2018).

3.7.5.1. Yapay Sinir Hücresinin Yapısı

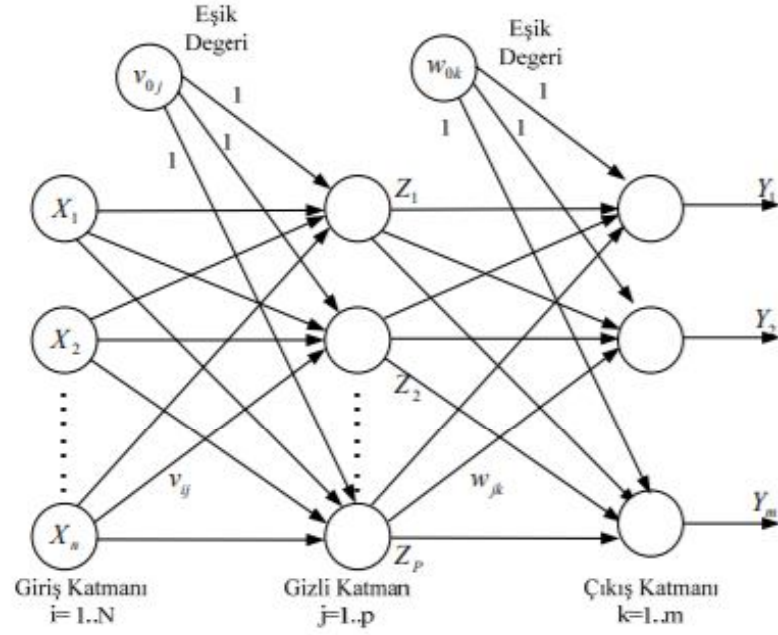
Yapay sinir hücreleri biyolojik sinir hücrelerinden esinlenerek oluşturulmakta ve yapıları benzerlik göstermektedir. YSA'nın en temel birimidir ve diğer sinir hücreleri ile bağ kurarak YSA oluştururlar. İşaretleri alır, işler ve bağ kurdukları diğer yapay sinir hücresine iletirler. Yapay sinir hücreleri girdiler, ağırlıklar, toplam fonksiyonu, aktivasyon fonksiyonu ve çıktı olmak üzere beş bölümden oluşmaktadır. Yapay sinir hücresinin yapısı Şekil 3.34'de gösterilmektedir (Çerçi, 2017).



Şekil 3.34. Yapay sinir hücresinin yapısı (Taşar, 2016)

3.7.5.2. YSA'nın Yapısı

Yapay sinir ağları yapay sinir hücrelerinin birbirlerine bağlanması sonucunda oluşmaktadır. Giriş katmanı, gizli katman ve çıkış katmanı olmak üzere üç ana bölümden oluşmaktadır. YSA'nın yapısı Şekil 3.35'de gösterilmektedir.



Şekil 3.35. YSA'nın yapısı (Kaynar et al., 2011)

Giriş katmanı sınıflandırılmak istenen verinin YSA'na verildiği bölgedir. Veriler YSA'nın giriş katmanına verilmeden önce filtreleme, ön işleme, pencereleme ve öznitelik çıkartma gibi işlemler uygulanmaktadır. Bu işlemler daha iyi sınıflandırma başarımı elde etmek için uygulanır ve veri karmaşasını azaltmak amaçlanır. Bu işlemlerden sonra veriler YSA'nın giriş katmanına gönderilir.

Gizli katmanda giriş katmanından gelen veriler bir ağırlık değişkeni ile çarpılarak veriler arasında bir bağlantı oluşturulmaya çalışılır. YSA'nın bazılarında gizli katman kullanılmazken bazılarında birden fazla gizli katman kullanılabilir. Karmaşık problemlerde gizli katman kullanılması önerilmektedir. Gizli katmanda bulunan yapay sinir hücreleri sayıları diğer katmanlarda bulunanlardan bağımsızdır. Bu sistemle problemlere çözüm üretmek kolaylaşmaktadır.

Çıkış katmanı gizli katmanda işlenen verileri ağırlık katsayıları ile çarparak almaktadır. Verilerin hangi sınıfa ait oldukları bu katmanda işlenerek belirlenmekte ve ayrılmaktadır (Çerçi, 2017).

3.7.5.3. Yapay Sinir Ağlarının Eğitilmesi

YSA insan beynine benzer şekilde öğrenme işlemini gerçekleştirir. İnsanlar duyu organları ile bilgi toplar ve bu bilgileri değerlendirerek sorunlara çözüm üretirler. Hiç karşılaşmadıkları bir sorun ise tecrübelerine göre en doğru çözümü bulmaya çalışırlar. YSA öğrenme sürecinde veri toplar ve aksiyon fonksiyonları ile bu

verilerden çıktı üretirler. Her çıktı daha önceki çıktılarla karşılaştırılarak hata oranı hesaplanır. Hata oranı öğrenme algoritmaları ile sıfırlanmaya çalışılır. Bunun için ağırlıkları değiştirilerek sınıflandırma tekrarlanır. Uygun ağırlıklar bulunduğu bu değerler saklanır. YSA eğitim sırasında verilmeyen veriler test için girdi katmanına gönderilir ve çıkışlar hesaplanır. YSA'na gönderilen test verileri doğru olarak sınıflandırılabilirse ağ öğrenmiş olur (Taşar, 2016). Bu çalışmada veri seti %75 eğitim, %15 doğrulama ve %15 test verisi olarak bölünmüş, YSA'nın öğrenmesi ve sınıflandırması bu veri setine göre gerçekleştirilmiştir. Öğrenme algoritmalarından 12 adet kullanılmıştır. Bunlar aşağıda açıklanmaktadır.

Levenberg-Marquardt algoritması ağırlık değerlerini güncelleyerek ağı eğitmektedir. Performansı belirlenirken kareler toplamı biçiminde hesaplanmaktadır. Fazla bellek gerektirmesine rağmen en hızlı algoritmalarından biridir. Bu algoritma, orta büyüklükteki ileri beslemeli yapay sinir ağlarını eğitmek için en hızlı yöntemdir. Eğitim veri seti çok büyük olduğunda hafıza azaltma özelliği bulunmaktadır. Bayesian Regularization algoritması ağırlıklarını Levenberg-Marquardt optimizasyonuna göre güncellemektedir. Kare hatalarını ve en aza indirir ve doğrusal kombinasyonu düzenler. Böylece ağın genelleme yeteneği artırılmış olur. Optimum ağ mimarisini belirleme zorluğunu azaltmaktadır. BFGS Quasi-Newton algoritması, ağırlık değerlerini BFGS Quasi-Newton yöntemine göre değiştiren bir yapay sinir ağı eğitim algoritmasıdır. Ağı eğitirken her yenilemede fazla hesaplama ve depolama gerektirmektedir. Küçük veriler için verimli ve kullanışlı bir algoritmadır.

YSA sonsuz bir giriş aralığını sonlu bir çıkış aralığına sıkıştırırlar. Sigmoid fonksiyonlarda giriş sayısı büyüdükçe eğitim sızfıra yaklaşmaktadır. Ağı eğitmek için en dik inişi kullandığımızda sorunlar oluşabilir çünkü gradyan çok küçük olabilir. Resilient Backpropagation algoritması kısmi türevler ile bu büyük girdilerin zararları ortadan kaldırmaktadır. Ağırlıkların güncelleştirilmesi sadece türevin işaretini belirler. YSA eğitiminde kullanılan algoritmalarından biridir. Hızlı yakınsama ve az yer kaplaması ile kullanışlı bir algoritmadır.

Scaled Conjugate Gradient algoritması ağırlıklarını ölçeklenen eşlenik gradyan yöntemi ile belirlemektedir. Türev fonksiyonlarına göre ağı eğitmektedir. Satır araması gerektirmeyen tek eşlenik gradyan algoritmasıdır. Çok işlevli eğitim algoritmasıdır. Conjugate Gradient with Powell/Beale Restarts algoritması ağ eğitim algoritmalarından biridir. Fletcher-Powell Conjugate Gradient algoritması ağırlıklarını Fletcher-Reeves güncellemeleriyle eşlenik gradyan geri yayılımına göre değiştiren bir

ağ eğitim algoritmasıdır. Değişken öğrenme hızı geri yayılım hızından daha fazladır. Bu algoritma çok sayıda ağırlığa sahip ağlarda daha iyi sonuç vermektedir.

Polak-Ribière Conjugate Gradient ağ eğitim algoritmalarından biridir. Depolama gereksinimi fazladır. One Step Secant algoritması ağırlık ve sapma değerlerini tek adımlı sekant yöntemine göre güncellemektedir. Depolama alanı küçüktür. Eşlenik gradyan algoritmaları ve yarı Newton algoritmaları arasındaki boşluğu gidermek amacıyla oluşturulmuştur. Variable Learning Rate Gradient Descent algoritması ağırlık değerlerini gradyan iniş momentumuna ve uyarlanabilir öğrenme hızına göre belirleyen bir ağ eğitim algoritmasıdır. Gradient Descent with Momentum algoritması ağırlık ve sapma değerlerini momentum ile eğim değişimine göre belirler. Ağ eğitim algoritmalarından biridir. Gradient Descent algoritmasında ağırlıklar ve sapmalar performans işlevinin negatif gradyanı yönünde güncellenmektedir. Öğrenme oranı ne kadar büyükse adım o kadar büyük olur. Öğrenme hızı çok büyük seçilirse, algoritma kararsızlaşır. Öğrenme hızı çok küçük belirlenirse, algoritmanın yakınsaması uzun zaman alır (MathWorks, 1994).

Bu çalışmada Matlab 2018b ® sinir ağı örüntü tanıma aracı (Neural Network Pattern Recognition Tool-nprtool) kullanılarak YSA'da sınıflandırma yapılmıştır. Veri seti 100 ms'lik %50 örtüşmeli pencerelere bölünmüş ve en yüksek başarımlı veren EMAV, SSI, VAR, DASDV, RMS, EWL, MMAV2, MMAV1, MFL, MYOP, MAV ve ZC öznitelikleri kullanılmıştır. Veri setinin %70'i eğitim, %15 test ve %15 doğrulama olarak ayrılmıştır. Etiketler Tablo 3.1'de gösterilmiştir.

Tablo 3.1. YSA ile sınıflandırmada kullanılan etiketler

Hareket Sınıfları	Etiketler
Başparmak	100000
İşaret Parmak	010000
Orta Parmak	001000
Yüzük Parmak	000100
Serçe Parmak	000010
Dinlenme Hareketi	000001

4. BULGULAR

4.1. CLA Kullanılarak Yapılan Sınıflandırmanın Bulguları

CLA'da 22 farklı makine öğrenme yöntemi kullanılarak sınıflandırma yapılmıştır. Tablo 4.1'de 22 adet sınıflandırıcıda 5 adet özneliğin sınıflandırma başarımları gösterilmektedir. EMAV özneliği için en yüksek başarımlı WKNN sınıflandırıcısı vermiştir. Başarım %90.11 olarak elde edilmiştir. EWL özneliği için en yüksek başarımlı WKNN sınıflandırıcısı vermiştir. Başarım %89.22 olarak elde edilmiştir. MAV özneliği için en yüksek başarımlı CSVM sınıflandırıcısı vermiştir. Başarım %89.11 olarak elde edilmiştir. WL özneliği için en yüksek başarımlı WKNN sınıflandırıcısı vermiştir. Başarım %88.78 olarak elde edilmiştir. ZC özneliği için en yüksek başarımlı LSVM sınıflandırıcısı vermiştir. Başarım %55.33 olarak elde edilmiştir.

Tablo 4.1. EMAV, EWL, MAV, WL ve ZC öznelikleri ile sınıflandırma

SINIFLANDIRICILAR	ÖZNETELİKLER				
	EMAV	EWL	MAV	WL	ZC
FT	75.78	76.67	75.33	74.33	45.56
MT	72.78	71.44	73.11	72.00	44.89
CT	57.89	57.11	58.67	57.56	41.11
LD	70.44	71.11	66.89	68.33	53.45
QD	79.78	80.00	78.22	78.11	54.33
LSVM	76.22	76.67	76.78	77.67	53.22
QSVM	88.78	86.56	88.56	87.67	53.67
CSVM	88.78	88.33	89.11	88.67	50.67
FQSVM	87.22	86.11	84.00	83.22	49.78
MGSVM	87.44	87.00	86.56	85.78	55.33
CGSVM	73.44	73.89	72.11	72.78	52.11
FKNN	89.00	88.56	87.33	88.00	46.89
MKNN	87.67	86.56	86.56	85.89	52.33
Coar.KNN	64.67	64.78	61.89	62.45	51.33
Cos.KNN	85.44	85.67	85.78	84.89	51.00
Cu.KNN	86.44	86.22	85.56	84.44	51.33
WKNN	90.11	89.22	88.56	88.78	53.56
Bo.T	78.11	77.11	75.78	77.556	46.33
Ba.T	86.89	85.33	86.67	84.22	52.45
SD	69.44	70.00	66.22	67.67	52.00
SKNN	87.33	85.33	85.56	85.11	48.44
RUST	72.77	71.11	73.11	72.00	42.78

Tablo 4.2'de 22 adet sınıflandırıcıda 4 adet özneliğin başarımlı yüzdeleri gösterilmektedir. SSC özneliği için en yüksek başarımlı LSVM sınıflandırıcısı vermiştir. Başarım %46.56 olarak elde edilmiştir. RMS özneliği için en yüksek başarımlı CSVM sınıflandırıcısı vermiştir. Başarım %88.89 olarak elde edilmiştir. AAC özneliği için en yüksek başarımlı WKNN sınıflandırıcısı vermiştir. Başarım

%88.78 olarak elde edilmiştir. DASDV özniteliği için en yüksek başarıyı WKNN sınıflandırıcısı vermiştir. Başarım %88.56 olarak elde edilmiştir.

Tablo 4.2. SSC, RMS, AAC ve DASDV öznitelikleri ile sınıflandırma

SINIFLANDIRICILAR	ÖZNİTELİKLER			
	SSC	RMS	AAC	DASDV
FT	39.22	74.67	74.33	75.67
MT	41.22	73.22	72.00	68.44
CT	37.33	58.89	57.56	57.22
LD	46.11	68.11	68.33	69.00
QD	45.78	77.78	78.11	77.89
LSVM	46.56	76.22	77.56	77.00
QSVM	42.67	88.11	87.56	86.44
CSVM	42.00	88.89	88.33	87.67
FQSVM	42.44	85.11	83.22	84.22
MGSVM	46.00	86.44	85.78	85.78
CGSVM	45.89	72.67	72.78	73.44
FKNN	39.78	87.78	88.00	87.89
MKNN	43.78	86.56	85.89	85.78
Coar.KNN	43.67	62.33	62.45	62.67
Cos.KNN	44.22	85.56	84.89	84.78
Cu.KNN	43.44	85.00	84.44	85.33
WKNN	43.78	88.78	88.78	88.56
Bo.T	42.44	75.67	77.56	76.44
Ba.T	43.78	85.33	86.56	86.22
SD	44.22	67.22	67.89	68.55
SKNN	40.67	86.33	85.78	85.89
RUST	40.45	73.22	72.00	68.55

Tablo 4.3’de 22 adet sınıflandırıcıda 4 adet özniteliğin başarımları yüzdeleri gösterilmektedir. LOG özniteliği için en yüksek başarımları WKNN sınıflandırıcısı vermiştir. Başarım %75.22 olarak elde edilmiştir. MMAV1 özniteliği için en yüksek başarımları Cu.KNN sınıflandırıcısı vermiştir. Başarım %71.67 olarak elde edilmiştir. MMAV2 özniteliği için en yüksek başarımları WKNN sınıflandırıcısı vermiştir. Başarım %88.44 olarak elde edilmiştir. MYOP özniteliği için en yüksek başarımları WKNN sınıflandırıcısı vermiştir. Başarım %82.22 olarak elde edilmiştir.

Tablo 4.3. MMAV1, MMAV2, MYOP ve LOG öznitelikleri ile sınıflandırma

SINIFLANDIRICILAR	ÖZNİTELİKLER			
	LOG	MMAV1	MMAV2	MYOP
FT	65.33	53.33	74.33	66.33
MT	59.56	57.00	71.67	63.11
CT	46.67	49.89	58.33	48.78
LD	58.11	71.44	67.00	66.89
QD	69.00	71.67	77.67	73.89
LSVM	66.44	73.89	76.78	68.89
QSVM	74.44	68.11	88.00	77.56
CSVM	75.11	60.78	87.44	78.00
FQSVM	68.44	44.33	84.33	82.22
MGSVM	74.67	63.11	86.11	79.00
CGSVM	63.33	69.55	71.55	70.33

Tablo 4.3. (devam)

FKNN	72.78	68.22	87.56	79.45
MKNN	73.78	70.33	86.22	80.00
Coar.KNN	55.22	65.67	62.56	67.00
Cos.KNN	72.56	70.78	85.33	78.78
Cu.KNN	73.22	71.67	85.56	79.11
WKNN	75.22	69.44	88.44	82.22
Bo.T	62.56	59.33	75.78	68.89
Ba.T	74.56	59.00	84.89	78.78
SD	57.00	67.00	67.22	69.11
SKNN	70.11	64.78	85.67	76.56
RUST	59.22	57.00	71.67	63.00

Tablo 4.4’de 22 adet sınıflandırıcıda 4 adet özneliğin başarımları yüzdeleri gösterilmektedir. SSI özneliği için en yüksek başarımları CSVM sınıflandırıcısı vermiştir. Başarımları %85.56 olarak elde edilmiştir. VAR özneliği için en yüksek başarımları Ba.T sınıflandırıcısı vermiştir. Başarımları %86.11 olarak elde edilmiştir. WAMP özneliği için en yüksek başarımları MGSVM sınıflandırıcısı vermiştir. Başarımları %72.22’dir. MFL özneliği için en yüksek başarımları FQSVM sınıflandırıcısı vermiştir. Sınıflandırma başarımları %90’ dır.

Tablo 4.4. SSI, VAR, WAMP ve MFL öznelikleri ile sınıflandırma

SINIFLANDIRICILAR	ÖZNETELİKLER			
	SSI	VAR	WAMP	MFL
FT	76.22	76.22	59.44	75.33
MT	69.89	69.89	57.44	69.89
CT	58.67	58.67	52.45	56.11
LD	57.78	57.78	60.56	72.11
QD	73.00	73.00	65.11	82.89
LSVM	75.67	75.56	62.67	75.11
QSVM	84.89	84.78	70.55	85.78
CSVM	85.56	85.22	68.67	89.11
FQSVM	78.78	78.78	67.11	90.00
MGSVM	80.89	80.89	72.22	88.22
CGSVM	67.67	67.67	66.22	73.44
FKNN	81.56	81.56	65.22	89.00
MKNN	78.22	78.22	71.00	87.78
Coar.KNN	56.89	56.89	63.33	68.55
Cos.KNN	79.22	79.22	67.22	85.22
Cu.KNN	77.56	77.56	71.22	87.33
WKNN	82.89	82.89	72.33	89.56
Bo.T	75.67	75.67	62.45	75.67
Ba.T	85.44	86.11	69.22	83.33
SD	56.78	56.45	60.78	71.89
SKNN	83.56	83.33	66.11	86.11
RUST	69.89	69.89	57.78	69.33

Ardışıl ileri yönlü öznelik seçimi yöntemi 1. aşamada En yüksek başarımları veren öznelik EMAV ve başarımları %90.11’dir. En yüksek sınıflandırma başarımları gösteren sınıflandırıcılar WKNN, FKNN, CSVM, MGSVM, QSVM ve SKNN olarak

belirlenmiştir. Tablo 4.5’de ardışıl ileri yönlü öznelik seçimi 2. aşamanın sınıflandırma başarımları verilmiştir. EMAN ve SSI öznelikleri ardışıl ileri yönlü öznelik seçimi 2. aşamada en yüksek başarımları vermiştir. Bu öznelikler için en yüksek başarımları QSVM sınıflandırıcısı vermiştir. Başarım %90.89 olarak elde edilmiştir.

Tablo 4.5. Ardışıl ileri yönlü öznelik seçimi 2. Aşama

ÖZNELİKLER	SINIFLANDIRICILAR					
	WKNN	FKNN	CSVM	MGSVM	QSVM	SKNN
F1,F2	89.22	89.00	89.78	87.56	88.22	86.67
F1,F3	89.67	88.11	89.00	87.00	89.33	89.67
F1,F4	89.00	88.67	89.22	87.00	89.00	86.67
F1,F5	86.22	83.89	86.11	84.89	86.22	53.77
F1,F6	85.44	84.67	84.78	83.89	84.44	47.56
F1,F7	89.89	88.56	88.89	87.11	89.00	89.44
F1,F8	89.00	88.67	88.89	87.00	89.00	88.56
F1,F9	89.00	88.67	88.89	87.00	89.00	88.56
F1,F10	85.11	83.78	87.44	84.78	86.44	87.89
F1,F11	89.33	89.56	89.00	86.78	89.00	90.00
F1,F12	89.78	88.22	88.44	87.11	88.67	90.22
F1,F13	90.22	88.56	89.89	87.00	87.33	87.56
F1,F14	89.00	87.11	88.67	85.78	90.89	86.00
F1,F15	89.00	87.11	88.89	85.78	90.78	89.89
F1,F16	90.78	89.67	86.89	86.00	86.33	71.56
F1,F17	90.22	89.89	90.22	88.67	88.44	89.22

Tablo 4.6’da ardışıl ileri yönlü öznelik 3. aşamanın sınıflandırma başarımları gösterilmiştir. EMAN, SSI ve VAR öznelikleri ardışıl ileri yönlü öznelik 3. aşamada en yüksek başarımları vermiş ve QSVM yöntemi kullanılarak sınıflandırılmıştır. Başarım %90.78 olarak elde edilmiştir.

Tablo 4.6. Ardışıl ileri yönlü öznelik seçimi 3. Aşama

ÖZNELİKLER	SINIFLANDIRICILAR					
	WKNN	FKNN	CSVM	MGSVM	QSVM	SKNN
F1,F14,F2	90.22	88.78	89.67	86.67	89.67	89.11
F1,F14,F3	89.00	87.33	89.00	86.00	90.67	86.11
F1,F14,F4	89.89	87.78	88.56	86.67	89.89	87.33
F1,F14,F5	86.11	85.11	86.00	86.00	88.00	71.33
F1,F14,F6	86.56	86.78	86.67	84.11	88.00	70.67
F1,F14,F7	89.00	87.33	88.78	85.78	90.67	86.56
F1,F14,F8	89.89	87.78	89.33	86.67	89.56	87.56
F1,F14,F9	89.56	88.33	88.56	86.78	90.22	87.44
F1,F14,F10	85.67	85.89	88.67	84.11	89.00	85.67
F1,F14,F11	89.11	87.33	89.11	86.11	90.11	86.89
F1,F14,F12	88.89	87.56	88.44	86.11	90.56	86.67
F1,F14,F13	90.56	89.00	89.22	87.44	88.11	88.44
F1,F14,F15	87.33	86.33	88.22	85.00	90.78	86.44
F1,F14,F16	89.67	89.44	89.33	87.00	87.78	83.33
F1,F14,F17	90.00	89.89	90.22	87.67	89.78	90.44

Tablo 4.7’de ardışıl ileri yönlü öznitelik seçimi 4. aşamanın sınıflandırma başarımları gösterilmiştir. EMAV, SSI, VAR ve DASDV öznitelikleri ardışıl ileri yönlü öznitelik seçimi 4. aşamada en yüksek başarıyı vermiş ve QSVM yöntemi kullanılarak sınıflandırılmıştır. Başarım %90.67 olarak elde edilmiştir.

Tablo 4.7. Ardışıl ileri yönlü öznitelik seçimi 4. Aşama

ÖZİNTELİKLER	SINIFLANDIRICILAR					
	WKNN	FKNN	CSVM	MGSVM	QSVM	SKNN
F1,F14,F15,F2	89.33	87.67	88.78	86.56	89.89	89.22
F1,F14,F15,F3	88.33	86.56	88.33	85.00	90.00	86.89
F1,F14,F15,F4	88.67	87.33	88.00	85.00	90.67	87.00
F1,F14,F15,F5	86.44	86.11	86.33	85.22	88.78	72.67
F1,F14,F15,F6	86.11	86.67	87.00	83.67	87.33	68.11
F1,F14,F15,F7	88.44	86.44	88.22	85.22	90.33	86.67
F1,F14,F15,F8	88.67	87.33	88.67	85.00	90.44	87.33
F1,F14,F15,F9	88.89	87.00	88.44	84.89	90.67	87.33
F1,F14,F15,F10	85.78	85.89	88.00	83.89	88.89	86.67
F1,F14,F15,F11	88.22	86.56	88.44	85.00	90.00	86.67
F1,F14,F15,F12	88.22	86.56	88.56	85.11	90.33	87.56
F1,F14,F15,F13	88.78	87.56	89.33	86.89	89.33	88.78
F1,F14,F15,F16	88.33	87.67	89.22	86.44	88.00	82.67
F1,F14,F15,F17	88.67	88.56	90.33	86.56	90.33	90.33

Tablo 4.8’de ardışıl ileri yönlü öznitelik seçimi 5. aşamanın sınıflandırma başarımları gösterilmiştir. EMAV, SSI, VAR, DASDV ve RMS öznitelikleri ardışıl ileri yönlü öznitelik seçimi 5. aşamada en yüksek başarıyı ve QSVM yöntemi kullanılarak sınıflandırılmıştır. Başarım %91.11 olarak elde edilmiştir.

Tablo 4.8. Ardışıl ileri yönlü öznitelik seçimi 5. Aşama

ÖZİNTELİKLER	SINIFLANDIRICILAR					
	WKNN	FKNN	CSVM	MGSVM	QSVM	SKNN
F1,F14,F15,F9,F2	90.22	87.33	88.56	86.67	90.00	88.56
F1,F14,F15,F9,F3	88.78	86.89	88.56	85.67	90.56	87.33
F1,F14,F15,F9,F4	89.44	86.78	88.78	86.00	90.44	88.78
F1,F14,F15,F9,F5	87.89	88.11	88.00	86.33	88.67	71.89
F1,F14,F15,F9,F6	87.22	84.89	85.89	85.11	87.44	71.00
F1,F14,F15,F9,F7	88.44	86.89	88.56	85.89	91.11	88.00
F1,F14,F15,F9,F8	89.44	86.78	88.22	86.00	90.44	87.78
F1,F14,F15,F9,F10	88.11	86.56	89.33	84.78	89.33	87.11
F1,F14,F15,F9,F11	88.78	86.89	88.33	85.78	90.56	86.89
F1,F14,F15,F9,F12	88.78	86.89	88.00	85.33	90.11	87.22
F1,F14,F15,F9,F13	89.22	88.44	89.67	87.00	90.00	89.00
F1,F14,F15,F9,F16	89.11	87.33	90.33	86.89	88.22	81.67
F1,F14,F15,F9,F17	89.44	88.11	90.00	87.00	90.11	90.44

Tablo 4.9’da ardışıl ileri yönlü öznitelik seçimi 6. aşamanın sınıflandırma başarımları gösterilmiştir. EMAV, SSI, VAR, DASDV, RMS ve EWL öznitelikleri ardışıl ileri yönlü öznitelik seçimi 6. aşamada en yüksek başarıyı vermiş ve QSVM yöntemi kullanılarak sınıflandırılmıştır. Başarım %90.89 olarak elde edilmiştir.

Tablo 4.9. Ardışıl ileri yönlü öznitelik seçimi 6. Aşama

ÖZİNİTELİKLER	SINIFLANDIRICILAR					
	WKNN	FKNN	CSVM	MGSVM	QSVM	SKNN
F1,F14,F15,F9,F7,F2	90.00	87.78	88.78	86.44	90.89	89.11
F1,F14,F15,F9,F7,F3	88.78	86.89	88.44	85.89	90.33	88.00
F1,F14,F15,F9,F7,F4	89.56	87.56	88.89	86.11	90.56	88.78
F1,F14,F15,F9,F7,F5	87.78	89.00	88.56	86.44	89.33	73.11
F1,F14,F15,F9,F7,F6	88.00	88.44	89.33	84.78	88.78	71.44
F1,F14,F15,F9,F7,F8	89.56	87.56	88.11	86.11	90.67	87.89
F1,F14,F15,F9,F7,F10	86.11	86.11	87.67	85.89	86.89	85.89
F1,F14,F15,F9,F7,F11	88.89	87.00	88.78	85.89	89.89	87.22
F1,F14,F15,F9,F7,F12	88.89	87.11	88.67	85.78	90.11	87.22
F1,F14,F15,F9,F7,F13	89.44	88.89	89.67	87.44	89.89	88.56
F1,F14,F15,F9,F7,F16	89.11	87.67	89.33	86.56	89.11	83.00
F1,F14,F15,F9,F7,F17	89.67	88.67	90.22	86.78	90.44	89.89

Tablo 4.10'da ardışıl ileri yönlü öznitelik seçimi 7. aşamanın sınıflandırma başarımları gösterilmiştir. EMAV, SSI, VAR, DASDV, RMS, EWL ve MMAV2 öznitelikleri ardışıl ileri yönlü öznitelik seçimi 7. aşamada seçiminde en yüksek başarımları vermiş ve QSVM yöntemi kullanılarak sınıflandırılmıştır. Başarımları %91 olarak elde edilmiştir.

Tablo 4.10. Ardışıl ileri yönlü öznitelik seçimi 7. Aşama

ÖZİNİTELİKLER	SINIFLANDIRICILAR					
	WKNN	FKNN	CSVM	MGSVM	QSVM	SKNN
F1,F14,F15,F9,F7,F2,F3	90.11	87.89	88.56	86.22	90.00	89.22
F1,F14,F15,F9,F7,F2,F4	90.11	87.89	88.67	86.22	90.89	87.89
F1,F14,F15,F9,F7,F2,F5	88.00	89.56	89.00	86.56	89.78	87.78
F1,F14,F15,F9,F7,F2,F6	89.33	89.00	89.67	86.00	88.56	87.78
F1,F14,F15,F9,F7,F2,F8	89.89	88.00	88.33	86.44	89.78	88.89
F1,F14,F15,F9,F7,F2,F10	89.11	87.89	89.22	85.11	90.00	88.89
F1,F14,F15,F9,F7,F2,F11	90.11	88.00	89.00	86.22	90.33	89.44
F1,F14,F15,F9,F7,F2,F12	89.89	88.00	88.67	86.33	91.00	89.11
F1,F14,F15,F9,F7,F2,F13	89.56	89.67	89.56	87.67	90.22	89.44
F1,F14,F15,F9,F7,F2,F16	89.78	88.44	89.78	87.67	88.22	88.22
F1,F14,F15,F9,F7,F2,F17	89.44	88.78	89.78	86.89	90.00	90.56

Tablo 4.11'de ardışıl ileri yönlü öznitelik seçimi 8. aşamanın sınıflandırma başarımları gösterilmiştir. EMAV, SSI, VAR, DASDV, RMS, EWL, MMAV2 ve MMAV1 öznitelikleri ardışıl ileri yönlü öznitelik seçimi 8. aşamada en yüksek başarımları vermiş ve QSVM yöntemi kullanılarak sınıflandırılmıştır. Başarımları %90,56 olarak elde edilmiştir.

Tablo 4.11. Ardışıl ileri yönlü öznitelik seçimi 8. Aşama

ÖZİNTELİKLER	SINIFLANDIRICILAR					
	WKNN	FKNN	CSVM	MG SVM	QSVM	SKNN
F1,F14,F15,F9,F7,F2,F12,F3	89.67	88.33	88.78	86.33	90.33	88.00
F1,F14,F15,F9,F7,F2,F12,F4	89.78	87.89	88.44	86.33	90.33	89.11
F1,F14,F15,F9,F7,F2,F12,F5	88.11	89.00	89.00	87.00	89.56	87.56
F1,F14,F15,F9,F7,F2,F12,F6	89.11	88.78	89.22	86.22	89.44	88.67
F1,F14,F15,F9,F7,F2,F12,F8	89.78	87.89	88.78	86.33	90.00	89.00
F1,F14,F15,F9,F7,F2,F12,F10	88.78	87.67	89.44	85.56	89.89	89.44
F1,F14,F15,F9,F7,F2,F12,F11	89.67	88.22	88.78	86.33	90.56	89.33
F1,F14,F15,F9,F7,F2,F12,F13	89.11	89.11	89.33	87.67	90.22	89.22
F1,F14,F15,F9,F7,F2,F12,F16	89.56	88.56	89.22	87.78	88.44	89.44
F1,F14,F15,F9,F7,F2,F12,F17	89.33	88.89	90.11	87.22	90.22	90.00

Tablo 4.12’de ardışıl ileri yönlü öznitelik seçimi 9. aşamanın sınıflandırma başarımları gösterilmiştir. EMAV, SSI, VAR, DASDV, RMS, EWL, MMAV2, MMAV1 ve MFL öznitelikleri ardışıl ileri yönlü öznitelik seçimi 9. aşamada en yüksek başarımları vermiş ve SKNN yöntemi kullanılarak sınıflandırılmıştır. Başarımları %90.67 olarak elde edilmiştir.

Tablo 4.12. Ardışıl ileri yönlü öznitelik seçimi 9. Aşama

ÖZİNTELİKLER	SINIFLANDIRICILAR					
	WKNN	FKNN	CSVM	MG SVM	QSVM	SKNN
F1,F14,F15,F9,F7,F2,F12,F11,F3	89.67	88.22	88.89	86.22	90.33	89.00
F1,F14,F15,F9,F7,F2,F12,F11,F4	89.78	87.89	88.67	86.56	90.11	88.78
F1,F14,F15,F9,F7,F2,F12,F11,F5	88.44	88.89	89.56	87.11	89.67	87.78
F1,F14,F15,F9,F7,F2,F12,F11,F6	88.78	88.22	89.22	86.11	89.33	87.89
F1,F14,F15,F9,F7,F2,F12,F11,F8	89.78	87.89	88.78	86.56	89.78	89.67
F1,F14,F15,F9,F7,F2,F12,F11,F10	89.33	87.67	89.33	85.56	90.11	88.89
F1,F14,F15,F9,F7,F2,F12,F11,F13	89.11	89.11	89.89	87.67	90.00	89.44
F1,F14,F15,F9,F7,F2,F12,F11,F16	89.44	88.44	90.00	87.44	89.22	88.78
F1,F14,F15,F9,F7,F2,F12,F11,F17	89.11	88.89	89.78	87.22	90.00	90.67

Tablo 4.13’de ardışıl ileri yönlü öznitelik seçimi 10. aşamanın sınıflandırma başarımları gösterilmiştir. EMAV, SSI, VAR, DASDV, RMS, EWL, MMAV2, MMAV1, MFL ve MYOP öznitelikleri ardışıl ileri yönlü öznitelik seçimi 10. aşamada en yüksek başarımları vermiş ve SKNN yöntemi kullanılarak sınıflandırılmıştır. Başarımları %90.89 olarak elde edilmiştir.

Tablo 4.13. Ardışıl ileri yönlü öznitelik seçimi 10. Aşama

ÖZİNTELİKLER	SINIFLANDIRICILAR					
	WKNN	FKNN	CSVM	MG SVM	QSVM	SKNN
F1,F14,F15,F9,F7,F2,F12,F11,F17,F3	89.33	88.78	89.44	87.11	90.00	90.33
F1,F14,F15,F9,F7,F2,F12,F11,F17,F4	89.22	89.00	89.44	87.00	89.89	89.00
F1,F14,F15,F9,F7,F2,F12,F11,F17,F5	88.67	89.67	89.44	88.11	90.67	87.33

Tablo 4.13. (devam)

F1,F14,F15,F9,F7,F2, F12,F11,F17,F6	89.33	88.78	90.11	87.33	89.89	89.11
F1,F14,F15,F9,F7,F2, F12,F11,F17,F8	89.22	89.00	89.56	87.00	90.00	90.22
F1,F14,F15,F9,F7,F2, F12,F11,F17,F10	89.33	87.89	89.78	87.00	89.89	90.22
F1,F14,F15,F9,F7,F2, F12,F11,F17,F13	89.44	89.67	90.11	88.22	90.67	90.89
F1,F14,F15,F9,F7,F2, F12,F11,F17,F16	90.00	89.22	89.67	88.44	89.33	89.11

Tablo 4.14’de ardışıl ileri yönlü öznitelik seçimi 11. aşamanın sınıflandırma başarımları gösterilmiştir. EMAV, SSI, VAR, DASDV, RMS, EWL, MMAV2, MMAV1, MFL, MYOP ve MAV öznitelikleri ardışıl ileri yönlü öznitelik seçimi 11. aşamada en yüksek başarımları vermiş ve SKNN yöntemi kullanılarak sınıflandırılmıştır. Başarım %91.33 olarak elde edilmiştir.

Tablo 4.14. Ardışıl ileri yönlü öznitelik seçimi 11. Aşama

ÖZİNİTELİKLER	SINIFLANDIRICILAR					
	WKNN	FKNN	CSVM	MGSVM	QSVM	SKNN
F1,F14,F15,F9,F7,F2, F12,F11,F17,F13,F3	89.22	89.33	90.22	87.78	90.22	<u>91.33</u>
F1,F14,F15,F9,F7,F2, F12,F11,F17,F13,F4	89.56	89.89	90.44	87.78	90.67	90.00
F1,F14,F15,F9,F7,F2, F12,F11,F17,F13,F5	89.44	90.00	90.89	88.22	90.89	88.89
F1,F14,F15,F9,F7,F2, F12,F11,F17,F13,F6	90.11	89.67	90.44	87.78	89.33	88.67
F1,F14,F15,F9,F7,F2, F12,F11,F17,F13,F8	89.56	89.89	89.78	87.78	90.44	90.56
F1,F14,F15,F9,F7,F2, F12,F11,F17,F13,F10	89.11	89.11	90.44	86.89	90.56	90.33
F1,F14,F15,F9,F7,F2, F12,F11,F17,F13,F16	89.89	90.33	89.44	88.44	89.00	89.56

Tablo 4.15’de ardışıl ileri yönlü öznitelik seçimi 12. aşamanın sınıflandırma başarımları gösterilmiştir. EMAV, SSI, VAR, DASDV, RMS, EWL, MMAV2, MMAV1, MFL, MYOP, MAV ve ZC öznitelikleri ardışıl ileri yönlü öznitelik seçimi 12. aşamada en yüksek başarımları vermiş ve CSVM yöntemi kullanılarak sınıflandırılmıştır. Sınıflandırmanın başarımları %91.56 olarak elde edilmiştir.

Tablo 4.15. Ardışıl ileri yönlü öznitelik seçimi 12. Aşama

ÖZNİTELİKLER	SINIFLANDIRICILAR					
	WKNN	FKNN	CSVM	MGSVM	QSVM	SKNN
F1,F14,F15,F9,F7,F2, F12,F11,F17,F13,F3,F4	89.11	89.56	90.00	88.00	90.67	89.33
F1,F14,F15,F9,F7,F2, F12,F11,F17,F13,F3,F5	89.44	90.11	91.56	88.33	91.11	88.11
F1,F14,F15,F9,F7,F2, F12,F11,F17,F13,F3,F6	90.22	89.56	90.67	87.89	89.33	90.00
F1,F14,F15,F9,F7,F2, F12,F11,F17,F13,F3,F8	89.11	89.56	90.11	88.00	90.56	90.22
F1,F14,F15,F9,F7,F2, F12,F11,F17,F13,F3,F10	88.78	89.11	90.11	86.44	90.78	90.22
F1,F14,F15,F9,F7,F2, F12,F11,F17,F13,F3,F16	89.78	90.22	89.78	88.22	89.11	90.00

Tablo 4.16’da ardışıl ileri yönlü öznitelik seçimi 13. aşamanın sınıflandırma başarımları gösterilmiştir. EMAV, SSI, VAR, DASDV, RMS, EWL, MMAV2, MMAV1, MFL, MYOP, MAV, ZC ve AAC öznitelikleri ardışıl ileri yönlü öznitelik seçimi 13. aşamada en yüksek başarımları CSVM sınıflandırıcısında vermiştir. Başarım %91.33’dür.

Tablo 4.16. Ardışıl ileri yönlü öznitelik seçimi 13. Aşama

ÖZNİTELİKLER	SINIFLANDIRICILAR					
	WKNN	FKNN	CSVM	MGSVM	QSVM	SKNN
F1,F14,F15,F9,F7,F2,F12, F11,F17,F13,F3,F5,F4	89.44	89.56	91.00	88.33	90.89	88.89
F1,F14,F15,F9,F7,F2,F12, F11,F17,F13,F3,F5,F6	90.11	90.11	90.33	87.89	90.33	87.11
F1,F14,F15,F9,F7,F2,F12, F11,F17,F13,F3,F5,F8	89.44	89.56	91.33	88.33	90.78	88.67
F1,F14,F15,F9,F7,F2,F12, F11,F17,F13,F3,F5,F10	89.67	89.22	90.56	88.00	90.67	88.56
F1,F14,F15,F9,F7,F2,F12, F11,F17,F13,F3,F5,F16	89.56	90.11	91.00	88.89	90.89	88.33

Tablo 4.17’de ardışıl ileri yönlü öznitelik seçimi 14. aşamanın sınıflandırma başarımları gösterilmiştir. EMAV, SSI, VAR, DASDV, RMS, EWL, MMAV2, MMAV1, MFL, MYOP, MAV, ZC, AAC ve WL öznitelikleri ardışıl ileri yönlü öznitelik seçimi 14. aşamada en yüksek başarımları vermiş ve CSVM yöntemi kullanılarak sınıflandırılmıştır. Başarım %91.33 olarak elde edilmiştir.

Tablo 4.17. Ardışıl ileri yönlü öznelik seçimi 14. Aşama

ÖZİNTELİKLER	SINIFLANDIRICILAR					
	WKNN	FKNN	CSVM	MGSVM	QSVM	SKNN
F1,F14,F15,F9,F7,F2,F12, F11,F17,F13,F3,F5,F8,F4	89.33	89.89	91.33	87.78	90.89	89.56
F1,F14,F15,F9,F7,F2,F12, F11,F17,F13,F3,F5,F8,F6	89.67	89.89	90.00	87.56	90.22	86.56
F1,F14,F15,F9,F7,F2,F12, F11,F17,F13,F3,F5,F8,F10	89.56	89.33	91.00	87.00	90.89	88.33
F1,F14,F15,F9,F7,F2,F12, F11,F17,F13,F3,F5,F8,F16	89.56	89.89	91.00	88.44	90.89	88.00

Tablo 4.18’de ardışıl ileri yönlü öznelik seçimi 15. aşamanın sınıflandırma başarımları gösterilmiştir. EMAV, SSI, VAR, DASDV, RMS, EWL, MMAV2, MMAV1, MFL, MYOP, MAV, ZC, AAC, WL ve WAMP öznelikleri ardışıl ileri yönlü öznelik seçimi 15. aşamada en yüksek başarımları vermiş ve CSVM yöntemi kullanılarak sınıflandırılmıştır. Başarım %91 olarak elde edilmiştir.

Tablo 4.18. Ardışıl ileri yönlü öznelik seçimi 15. Aşama

ÖZİNTELİKLER	SINIFLANDIRICILAR					
	WKNN	FKNN	CSVM	MGSVM	QSVM	SKNN
F1,F14,F15,F9,F7,F2,F12, F11,F17,F13,F3,F5,F8,F4,F6	89.44	89.78	89.89	87.89	90.56	87.56
F1,F14,F15,F9,F7,F2,F12, F11,F17,F13,F3,F5,F8,F4,F10	89.67	89.44	90.56	86.89	90.56	88.67
F1,F14,F15,F9,F7,F2,F12, F11,F17,F13,F3,F5,F8,F4,F16	89.56	90.00	91.00	88.89	90.11	89.11

Tablo 4.19’da ardışıl ileri yönlü öznelik seçimi 16. aşamanın sınıflandırma başarımları gösterilmiştir. EMAV, SSI, VAR, DASDV, RMS, EWL, MMAV2, MMAV1, MFL, MYOP, MAV, ZC, AAC, WL, WAMP ve LOG öznelikleri ardışıl ileri yönlü öznelik seçimi 16. aşamada en yüksek başarımları vermiş ve CSVM yöntemi kullanılarak sınıflandırılmıştır. Başarım %90.89 olarak elde edilmiştir.

Tablo 4.19. Ardışıl ileri yönlü öznelik seçimi 16. Aşama

ÖZİNTELİKLER	SINIFLANDIRICILAR					
	WKNN	FKNN	CSVM	MGSVM	QSVM	SKNN
F1,F14,F15,F9,F7,F2,F12,F11, F17,F13,F3,F5,F8,F4,F16,F6	89.67	89.89	90.67	88.33	89.78	88.78
F1,F14,F15,F9,F7,F2,F12,F11, F17,F13,F3,F5,F8,F4,F16,F10	89.67	89.56	90.89	88.89	90.67	88.78


Tablo 4.20’de ardışıl ileri yönlü öznelik seçimi 17. aşamanın sınıflandırma başarımları gösterilmiştir. EMAV, SSI, VAR, DASDV, RMS, EWL, MMAV2, MMAV1, MFL, MYOP, MAV, ZC, AAC, WL, WAMP, LOG ve SSC öznelikleri ardışıl ileri yönlü öznelik seçimi 17. aşamada en yüksek başarımları vermiş ve CSVM

yöntemi kullanılarak sınıflandırılmıştır. Başarım %90.33 olarak elde edilmiştir.

Tablo 4.20. Ardışıl ileri yönlü öznelik seçimi 17. Aşama

ÖZNETELİKLER	SINIFLANDIRICILAR					
	WKNN	FKNN	CSVM	MGSVM	QSVM	SKNN
F1,F14,F15,F9,F7,F2,F12,F11, F17,F13,F3,F5,F8,F4,F16,F10,F6	90.11	88.89	90.33	87.67	89.22	88.22

Şekil 4.1’de ardışıl ileri yönlü öznelik seçiminde gerçekleşen başarımlar gösterilmektedir. En yüksek başarımları EMAV, SSI, VAR, DASDV, RMS, EWL, MMAV2, MMAV1, MFL, MYOP, MAV ve ZC öznelikleri vermiştir. Sınıflandırma doğruluğu %91.56 olarak elde edilmiştir. Ardışıl ileri yönlü öznelik seçiminde yapılan sınıflandırmalarda belirli bir noktaya kadar başarımlar yükselmiştir. En yüksek başarımları veren öznelikler ardışıl ileri yönlü öznelik seçimi yöntemi ile belirlendikten sonra yapılan sınıflandırmalarda başarımlar kademeli olarak azalmıştır.



Şekil 4.1. Ardışıl ileri yönlü öznelikler seçimi ve başarımları

Tablo 4.21’de bireysel sınıflandırma başarımları gösterilmektedir. Sınıflandırma için en yüksek başarımları veren EMAV, SSI, VAR, DASDV, RMS, EWL, MMAV2, MMAV1, MFL, MYOP, MAV ve ZC öznelikleri kullanılmıştır. Katılımcı 1 ve 6’nın sınıflandırma başarımları 100, katılımcı 2’nin sınıflandırma başarımları 93.33, katılımcı 3’ün sınıflandırma başarımları 97.73, katılımcı 4’ün sınıflandırma başarımları 98.89, katılımcı 5’in sınıflandırma başarımları 92.22, katılımcı 7’nin sınıflandırma başarımları 94.44, katılımcı 8’nin sınıflandırma başarımları 98.89, katılımcı 9’nin sınıflandırma başarımları 96.67 ve katılımcı 10’nin sınıflandırma başarımları 98.89 olarak elde edilmiştir. Katılımcıların başarımlarının ortalaması alındığında başarımlar 95.44 olarak elde edilmiştir. Katılımcıların yüzey EMG verileri birlikte sınıflandırıldığında ise

sınıflandırma başarımı 91.56 olarak elde edilmiştir. Bireysel sınıflandırmada daha yüksek başarımlar elde edilmiştir. Bunun nedeni yüzey EMG işaretlerinin katılımcılara özel olmasıdır. Her katılımcının verisi kendi veri setinde benzerlik gösterdiğinden başarımları yüksek olmuştur.

Tablo 4.21. Seçilen öznitelikler ile bireysel sınıflandırma başarımları

KATILIMCILAR	SINIFLANDIRICILAR					
	WKNN	FKNN	CSVM	MGSVM	QSVM	SKNN
K1	98.89	100	98.89	100	100	100
K2	90.00	90.00	93.33	91.11	92.22	87.78
K3	92.22	92.22	97.78	91.11	96.67	90.00
K4	98.89	97.78	95.56	94.44	95.56	97.78
K5	90.00	91.11	91.11	91.11	90.00	92.22
K6	97.78	95.56	98.89	100	98.89	98.89
K7	87.78	88.89	88.89	94.44	91.11	84.44
K8	97.78	98.89	96.67	98.89	96.67	98.89
K9	96.67	95.56	94.44	94.44	93.33	96.67
K10	93.33	96.67	98.89	96.67	97.78	95.56
Ortalama	95.34	94.67	95.44	95.22	95.22	94.22
Tümü	89.44	90.11	91.56	88.33	91.11	88.11

Tablo 4.22’de jiroskop verileri eklenerek yapılan sınıflandırma başarımları verilmiştir. EMAV, SSI, VAR, DASDV, RMS, EWL, MAV2, MMAV1, MFL, MYOP, MAV ve ZC öznitelikleri kullanılmıştır. Jiroskop verisi 3 kanal olarak alınmıştır. Veri setine jiroskop verisi 3 kanal olarak eklenerek ve ayrı ayrı tek kanal olarak eklenerek sınıflandırılmıştır. Yüzey EMG verisi bir pencere için 100 ms olarak alınmıştır. 100 ms 20 örnek sayısına eşittir. Örnek sayıları eşit olması amacıyla jiroskop verileri de 20 örnek alınmıştır. En yüksek başarımlar jiroskop kanalının eklenmesi sonucunda elde edilmiştir. Sınıflandırma başarımı %92.56 olarak elde edilmiştir.

Tablo 4.22. Jiroskop verileri eklenerek yapılan sınıflandırma başarımları

JİROSKOP	SINIFLANDIRICILAR					
	WKNN	FKNN	CSVM	MGSVM	QSVM	SKNN
G1,G2,G3	90.00	91.00	91.11	89.89	91.11	54.48
G1	90.67	91.44	91.11	87.89	91.33	62.56
G2	89.33	89.89	90.33	89.67	90.00	78.78
G3	89.67	90.44	92.56	89.33	90.22	77.67

Farklı pencere boyutları ile sınıflandırmanın başarımlarına etkisi Tablo 4.23’de gösterilmiştir. Gerçek zamanlı biyomedikal veri işleyerek yapılan protez kontrollerinde tepki süresi 300 ms’den az olması gerekmektedir. Bu nedenle veri işlemede pencere boyu 300 ms’den az olmalıdır (Englehart and Hudgins, 2003). 50 ms, 100 ms, 150 ms, 200 ms, 250 ms ve 300 ms sınıflandırma yapılmıştır. EMAV,

SSI, VAR, DASDV, RMS, EWL, MMAV2, MMAV1, MFL, MYOP, MAV ve ZC öznitelikleri kullanılmıştır. Yapılan sınıflandırmalarda 100 ms ile yapılan sınıflandırıcı daha iyi sonuç verdiği gözlenmiştir. Başarım %92.56 olarak elde edilmiş ve CSVM sınıflandırıcısı kullanılmıştır. Sınıflandırmada %50 örtüşme kullanılmıştır.

Tablo 4.23. Farklı pencere boyutlarında sınıflandırma başarımları

PENCERE BOYUTU	SINIFLANDIRICILAR					
	WKNN	FKNN	CSVM	MG SVM	QSVM	SKNN
50 ms	90.44	90.56	91.78	89.22	90.89	79.67
100 ms	89.56	90.44	92.56	89.33	90.22	77.67
150 ms	88.11	90.00	90.78	88.33	89.67	80.44
200 ms	88.11	89.67	90.22	87.89	90.00	87.22
250 ms	89.89	90.67	90.67	88.00	90.67	88.00
300 ms	90.00	90.89	91.11	87.78	89.89	88.22

Bu çalışmada CLA kullanarak elde edilen en yüksek başarımlar %92.56'dır. Sınıflandırmanın karmaşıklık matrisi Tablo 4.24'de gösterilmektedir.

Tablo 4.24. Karmaşıklık matrisi

GERÇEK SINIFLAR	TAHMİN EDİLEN SINIFLAR					
	Başparmak	İşaret Parmak	Orta Parmak	Yüzük Parmak	Serçe Parmak	Dinlenme Hareketi
Başparmak	135	1	5	2	7	0
İşaret Parmak	2	139	5	3	1	0
Orta Parmak	2	6	137	3	2	0
Yüzük Parmak	2	3	4	132	9	0
Serçe Parmak	5	0	0	5	140	0
Dinlenme	0	0	0	0	0	150

Test veri setinin başarımlarını hesaplamak için doğru pozitif (TP), doğru negatif (TN), yanlış pozitif (FP) ve yanlış negatif (FN) değerlerini hesaplanması gerekmektedir. Bu değerler hesaplamak için veriler gerçek sınıflar ve tahmin edilen sınıflar olarak ayrıştırılmaktadır. Gerçek sınıflarda 150 adet verimiz bulunmaktadır. Sınıflandırıcı başparmak verilerden 135 tanesini başparmak olarak tahmin etmiş, 1 veriyi işaret parmak, 5 veriyi orta parmak, 2 veriyi yüzük parmak ve 7 veriyi serçe parmak olarak tahmin etmiştir. Sınıflandırıcı işaret parmak verilerden 139 tanesini işaret parmak olarak tahmin etmiş, 2 veriyi başparmak, 5 veriyi orta parmak, 3 veriyi yüzük parmak ve 1 veriyi serçe parmak olarak tahmin etmiştir. Sınıflandırıcı orta parmak verilerden 137 tanesini orta parmak olarak tahmin etmiş, 2 veriyi başparmak, 6 işaret parmak, 3 veriyi yüzük parmak ve 2 veriyi serçe parmak olarak tahmin etmiştir. Sınıflandırıcı serçe parmak verilerden 140 tanesini orta parmak olarak tahmin etmiş, 5 veriyi başparmak ve 5 veriyi yüzük parmak olarak tahmin etmiştir. Sınıflandırıcı

dinlenme halini doğru tahmin etmiştir.

Başparmak veri sınıfı için TP, TN, FP, FN gösterimi Tablo 4.25’de gösterilmektedir. Başparmak verisi için tahmin edilen sınıflarda -başparmak verisidir- ve -başparmak verisi değildir- cümlelerine gerçek sınıflar kısmında doğru veya yanlış cevabını aranmaktadır. -Başparmak verisidir- cümlesine cevap aradığımız bölgeler cümle olumlu bir cümle olduğundan pozitif kısımlardır. -Başparmak verisi değildir- cümlesine cevap aradığımız bölgeler cümle olumsuz bir cümle olduğundan negatif kısımlardır. Veri başparmak verisidir cümlesine gerçek değerlerde doğru yanıtını verdiğimiz veriler doğru pozitiflerdir. Başparmak verisi için doğru pozitif değerlerimiz 135’dir ve Tablo 4.25’de yeşil alanda gösterilmektedir. Başparmak verisidir cümlesine gerçek değerlerde yanlış yanıtını verdiğimiz veriler yanlış pozitiflerdir. Başparmak verisi için yanlış pozitif sayısı 11’dir ve Tablo 4.25’de sarı renk ile belirtilmiştir. Başparmak verisi değildir cümlesine gerçek sınıflarda yanlış cevabını veriyorsak bu kısım hem yanlış olmasından hem de cümle negatif olmasından yanlış negatiftir. Yanlış negatif sayısı 15’dir ve Tablo 4.25’de kırmızı renk ile gösterilmektedir. Başparmak verisi değildir cümlesine gerçek değerlerde doğru cevabını verdiğimiz veriler doğru negatiftir. Başparmak verisi için yanlış negatif sayısı 739’dir ve Tablo 4.25’de mavi renk ile belirtilmiştir.

Tablo 4.25. Başparmak için TP,TN,FP,FN gösterimi

GERÇEK SINIFLAR	TAHMİN EDİLEN SINIFLAR					
	Başparmak	İşaret Parmak	Orta Parmak	Yüzük Parmak	Serçe Parmak	Dinlenme Hareketi
Başparmak	135	1	5	2	7	0
İşaret Parmak	2	139	5	3	1	0
Orta Parmak	2	6	137	3	2	0
Yüzük Parmak	2	3	4	132	9	0
Serçe Parmak	5	0	0	5	140	0
Dinlenme	0	0	0	0	0	150

İşaret parmak verileri için TP, TN, FP, FN gösterimi Tablo 4.26’da gösterilmektedir. İşaret parmak için doğru pozitif değeri 139’dur. Yanlış pozitif değeri 10, yanlış negatif değeri 11 ve doğru negatif değeri 740’dur. Doğru pozitif verileri yeşil renkte, yanlış pozitif sarı renkte, doğru negatif verileri mavi renkte ve yanlış negatif değerleri kırmızı renkte gösterilmiştir.

Tablo 4.26. İşaret parmak için TP, TN, FP, FN gösterimi

GERÇEK SINIFLAR	TAHMİN EDİLEN SINIFLAR					
	Başparmak	İşaret Parmak	Orta Parmak	Yüzük Parmak	Serçe Parmak	Dinlenme Hareketi
Başparmak	135	1	5	2	7	0
İşaret Parmak	2	139	5	3	1	0
Orta Parmak	2	6	137	3	2	0
Yüzük Parmak	2	3	4	132	9	0
Serçe Parmak	5	0	0	5	140	0
Dinlenme	0	0	0	0	0	150

Orta parmak verileri için TP, TN, FP, FN gösterimi Tablo 4.27’de gösterilmektedir. Orta parmak için doğru pozitif değeri 137’dir. Yanlış pozitif değeri 14, yanlış negatif değeri 13 ve doğru negatif değeri 736’dür. Doğru pozitif verileri yeşil renkte, yanlış pozitif sarı renkte, doğru negatif verileri mavi renkte ve yanlış negatif değerleri kırmızı renkte gösterilmiştir.

Tablo 4.27. Orta parmak için TP,TN,FP,FN gösterimi

GERÇEK SINIFLAR	TAHMİN EDİLEN SINIFLAR					
	Başparmak	İşaret Parmak	Orta Parmak	Yüzük Parmak	Serçe Parmak	Dinlenme Hareketi
Başparmak	135	1	5	2	7	0
İşaret Parmak	2	139	5	3	1	0
Orta Parmak	2	6	137	3	2	0
Yüzük Parmak	2	3	4	132	9	0
Serçe Parmak	5	0	0	5	140	0
Dinlenme	0	0	0	0	0	150

Yüzük parmak verileri için TP, TN, FP, FN gösterimi Tablo 4.28’de gösterilmektedir. Yüzük parmak için doğru pozitif değeri 132’dür. Yanlış pozitif değeri 13, yanlış negatif değeri 18 ve doğru negatif değeri 737’dür. Doğru pozitif verileri yeşil renkte, yanlış pozitif sarı renkte, doğru negatif verileri mavi renkte ve yanlış negatif değerleri kırmızı renkte gösterilmiştir.

Tablo 4.28. Yüzük parmak için TP,TN,FP,FN gösterimi

GERÇEK SINIFLAR	TAHMİN EDİLEN SINIFLAR					
	Başparmak	İşaret Parmak	Orta Parmak	Yüzük Parmak	Serçe Parmak	Dinlenme Hareketi
Başparmak	135	1	5	2	7	0
İşaret Parmak	2	139	5	3	1	0
Orta Parmak	2	6	137	3	2	0
Yüzük Parmak	2	3	4	132	9	0
Serçe Parmak	5	0	0	5	140	0
Dinlenme	0	0	0	0	0	150

Serçe parmak verileri için TP, TN, FP, FN gösterimi Tablo 4.29’da gösterilmektedir. Serçe parmak için doğru pozitif değeri 140’dür. Yanlış pozitif değeri

19, yanlış negatif değeri 10 ve doğru negatif değeri 731'dir. Doğru pozitif verileri yeşil renkte, yanlış pozitif sarı renkte, doğru negatif verileri mavi renkte ve yanlış negatif değerleri kırmızı renkte gösterilmiştir.

Tablo 4.29. Serçe parmak için TP,TN,FP,FN gösterimi

GERÇEK SINIFLAR	TAHMİN EDİLEN SINIFLAR					
	Başparmak	İşaret Parmak	Orta Parmak	Yüzük Parmak	Serçe Parmak	Dinlenme Hareketi
Başparmak	135	1	5	2	7	0
İşaret Parmak	2	139	5	3	1	0
Orta Parmak	2	6	137	3	2	0
Yüzük Parmak	2	3	4	132	9	0
Serçe Parmak	5	0	0	5	140	0
Dinlenme	0	0	0	0	0	150

Dinlenme hareketi için TP, TN, FP, FN gösterimi Tablo 4.30'da gösterilmektedir. Orta parmak için doğru pozitif değeri 150'dir. Yanlış pozitif değeri 0, yanlış negatif değeri 0 ve doğru negatif değeri 750'dür. Doğru pozitif verileri yeşil renkte, yanlış pozitif sarı renkte, doğru negatif verileri mavi renkte ve yanlış negatif değerleri kırmızı renkte gösterilmiştir.

Tablo 4.30. Dinlenme hareketi için TP,TN,FP,FN gösterimi

GERÇEK SINIFLAR	TAHMİN EDİLEN SINIFLAR					
	Başparmak	İşaret Parmak	Orta Parmak	Yüzük Parmak	Serçe Parmak	Dinlenme Hareketi
Başparmak	135	1	5	2	7	0
İşaret Parmak	2	139	5	3	1	0
Orta Parmak	2	6	137	3	2	0
Yüzük Parmak	2	3	4	132	9	0
Serçe Parmak	5	0	0	5	140	0
Dinlenme	0	0	0	0	0	150

Sınıflandırma işlemlerinin değerlendirme araçları doğruluk, hassasiyet, özgünlük, pozitif tahmin değeri ve negatif tahmin değeridir (Carvajal and Rowe, 2010; Castro et al., 2015; Gökçe, 2019; Lalkhen and McCluskey, 2008; Oweis et al., 2014). Hassasiyet ayrıca sensitivity, true pozitif rate, recall, probability of detection olarak da adlandırılır. Her sınıf için ayrı ayrı hesaplanır. Sınıfların aritmetik ortalaması alınarak ortalama hassasiyet hesaplanır. Denklemi 4.1'de gösterilmektedir.

$$Hassiyet = \frac{TP}{TP + FN} \times 100 \quad (4.1)$$

Özgünlük specificity, selectivity, true negative rate olarak da adlandırılır. Her sınıf için ayrı ayrı hesaplanır. Sınıfların aritmetik ortalaması alınarak ortalama özgünlük hesaplanır. Denklemi 4.2'de gösterilmektedir.

$$\text{Özgünlük} = \frac{TN}{TN + FP} \times 100 \quad (4.2)$$

Pozitif tahmin değeri doğru pozitiflerin, doğru pozitif ve yanlış pozitiflere oranıdır. Her sınıf için ayrı ayrı hesaplanır. Sınıfların aritmetik ortalaması alınarak ortalama pozitif tahmin değeri hesaplanır. Denklemi 4.3’de gösterilmektedir.

$$\text{Pozitif tahmin değeri} = \frac{TP}{TP + FP} \times 100 \quad (4.3)$$

Negatif tahmin değeri ise doğru negatiflerin, doğru negatif ve yanlış negatiflere oranıdır. Her sınıf için ayrı ayrı hesaplanır. Sınıfların aritmetik ortalaması alınarak ortalama negatif tahmin değeri hesaplanır. Denklemi 4.4’de gösterilmektedir.

$$\text{Negatif tahmin değeri} = \frac{TN}{TN + FN} \times 100 \quad (4.4)$$

Doğruluk, accuracy veya correct rate olarak da adlandırılır ve her sınıftaki doğru pozitiflerin tüm verilere oranıdır. Denklemi 4.5’de gösterilmektedir.

$$\text{Doğruluk} = \frac{TP (\text{Tüm Sınıflar})}{\text{Tüm Veriler}} \times 100 \quad (4.5)$$

Başparmak hareketinin başarımları Tablo 4.31’de verilmiştir. Hassasiyet %90, özgünlük %98.53, pozitif tahmin değeri %92.46 ve negatif tahmin değeri %98.01’dir.

Tablo 4.31. Başparmağın başarımlarının hesaplanması

BAŞPARMAK	
Doğru Pozitifler(TP)=135	Doğru Negatifler(TN)=739
Yanlış Pozitifler(FP)=11	Yanlış Negatifler(FN)=15
Hassasiyet = $TP / (TP + FN) \times 100 = 135 / (135 + 15) \times 100 = 90$	
Özgünlük = $TN / (TN + FP) \times 100 = 739 / (739 + 11) \times 100 = 98.53$	
Pozitif tahmin değeri = $TP / (TP + FP) \times 100 = 135 / 146 \times 100 = 92.46$	
Negatif tahmin değeri = $TN / (TN + FN) \times 100 = 739 / 754 \times 100 = 98.01$	

İşaret parmak hareketinin başarımlarının hesaplanması Tablo 4.32’de verilmiştir. Hassasiyet %92.67, özgünlük %98.67, pozitif tahmin değeri %93.28 ve negatif tahmin değeri %99.86 olarak elde edilmiştir.

Tablo 4.32. İşaret parmağın başarımlarının hesaplanması

İŞARET PARMAK	
Doğru Pozitifler(TP)=139	Doğru Negatifler(TN)=740
Yanlış Pozitifler(FP)=10	Yanlış Negatifler(FN)=11
Hassasiyet = $TP / (TP + FN) \times 100 = 139 / 150 \times 100 = 92.67$	
Özgünlük = $TN / (TN + FP) \times 100 = 740 / 750 \times 100 = 98.67$	
Pozitif tahmin değeri = $TP / (TP + FP) \times 100 = 139 / 149 \times 100 = 93.28$	
Negatif tahmin değeri = $TN / (TN + FN) \times 100 = 740 / 751 \times 100 = 99.86$	

Orta parmak hareketinin başarımlarının hesaplanması Tablo 4.33’de verilmiştir. Hassasiyet %91.33, özgünlük %98.13, pozitif tahmin değeri %90.72 ve negatif tahmin değeri

%99.59 olarak elde edilmiştir.

Tablo 4.33. Orta parmağın başarımlarını yüzdelere hesaplanması

ORTA PARMAK	
Doğru Pozitifler(TP)=137	Doğru Negatifler(TN)=736
Yanlış Pozitifler(FP)=14	Yanlış Negatifler(FN)=13
Hassasiyet = $TP/(TP+FN) \times 100=137/150 \times 100=91.33$	
Özgünlük = $TN / (TN + FP) \times 100=736/750 \times 100=98.13$	
Pozitif tahmin değeri = $TP / (TP + FP) \times 100=137/151 \times 100=90.72$	
Negatif tahmin değeri = $TN / (TN + FN) \times 100=736/739 \times 100=99.59$	

Yüzük parmak hareketinin başarımlarını yüzdelere Tablo 4.34’de verilmiştir. Hassasiyet %88.00, özgünlük %98.26, pozitif tahmin değeri %91.03 ve negatif tahmin değeri %97.61 olarak elde edilmiştir.

Tablo 4.34. Yüzük parmağın başarımlarını yüzdelere hesaplanması

YÜZÜK PARMAK	
Doğru Pozitifler(TP)=132	Doğru Negatifler(TN)=737
Yanlış Pozitifler(FP)=13	Yanlış Negatifler(FN)=18
Hassasiyet = $TP/(TP+FN) \times 100=132/(132+18) \times 100=88.00$	
Özgünlük = $TN / (TN + FP) \times 100=737/750 \times 100=98.26$	
Pozitif tahmin değeri = $TP / (TP + FP) \times 100=132/145 \times 100=91.03$	
Negatif tahmin değeri = $TN / (TN + FN) \times 100=737/755 \times 100=97.61$	

Serçe parmak hareketinin başarımlarını yüzdelere Tablo 4.35’de verilmiştir. Hassasiyet %93.33, özgünlük %97.46, pozitif tahmin değeri %88.05 ve negatif tahmin değeri %98.65 olarak elde edilmiştir.

Tablo 4.35. Serçe parmağın başarımlarını yüzdelere hesaplanması

SERÇE PARMAK	
Doğru Pozitifler(TP)=140	Doğru Negatifler(TN)=731
Yanlış Pozitifler(FP)=19	Yanlış Negatifler(FN)=10
Hassasiyet = $TP/(TP+FN) \times 100=140/150 \times 100=93.33$	
Özgünlük = $TN / (TN + FP) \times 100=731/750 \times 100=97.46$	
Pozitif tahmin değeri = $TP / (TP + FP) \times 100=140/159 \times 100=88.05$	
Negatif tahmin değeri = $TN / (TN + FN) \times 100=731/741 \times 100=98.65$	

Dinlenme hareketinin başarımlarını yüzdelere Tablo 4.36’da verilmiştir. Hassasiyet, özgünlük, pozitif tahmin değeri ve negatif tahmin değeri %100 olarak elde edilmiştir.

Tablo 4.36. Dinlenme hareketinin başarımlarını yüzdelere hesaplanması

DİNLENME HAREKETİ	
Doğru Pozitifler(TP)=150	Doğru Negatifler(TN)=750
Yanlış Pozitifler(FP)=0	Yanlış Negatifler(FN)=0
Hassasiyet = $TP/(TP+FN) \times 100=150/150 \times 100=100$	
Özgünlük = $TN / (TN + FP) \times 100=750/750 \times 100=100$	
Pozitif tahmin değeri = $TP / (TP + FP) \times 100=150/150 \times 100=100$	
Negatif tahmin değeri = $TN / (TN + FN) \times 100=750/750 \times 100=100$	

5 parmak ve dinlenme hareketi için başarımların yüzdeleri şunlardır:

Ortalama Hassasiyet = $(90+92.67+91.33+88+93.33+100) / 6 = \%92.56$

Ortalama Özgünlük = $(98.53+98.67+98.13+98.26+97.46+100) / 6 = \%98.51$

Ortalama Pozitif Tahmin Değeri = $(92.46+93.28+90.72+91.03+88.05+100)/6 = \%92.59$


Ortalama Negatif Tahmin Değeri = $(98+99.86+99.59+97.61+98.65+100)/6 = \%98.95$

Doğruluk = $TP(\text{Tüm Sınıflar})/\text{Tüm Veriler} \times 100 = 833/900 = \%92.56$

Bu sınıflandırmada doğruluk %92.56, ortalama hassasiyet %92.56, ortalama özgünlük %98.51, ortalama pozitif tahmin değeri %92.59 ve ortalama negatif tahmin değeri %98.95 olarak elde edilmiştir.


4.2. YSA Kullanılarak Yapılan Sınıflandırmanın Bulguları

YSA kullanılarak yapılan sınıflandırmada farklı eğitim algoritmaları kullanılmıştır. Şekil 4.2’de SCG eğitim algoritması ile sınıflandırma başarımları gösterilmektedir. Gizli katman nöron sayısı 1’den başlayarak 100’e kadar artırılarak sınıflandırma yapılmıştır. En iyi sınıflandırma başarımını gizli katmanda 83 nöron sayısına sahip YSA vermiştir. Eğitim başarımı %97.60, test başarımı %93.70 ve doğrulama %88.90 olarak elde edilmiştir.




Şekil 4.2. SCG eğitim algoritması ile sınıflandırma başarımları

Şekil 4.3’de LM eğitim algoritması ile sınıflandırma başarımları gösterilmektedir. Gizli katman nöron sayısı 1’den başlayarak 100’e kadar artırılarak sınıflandırma yapılmıştır. En iyi sınıflandırma başarımını gizli katmanda 65 nöron sayısına sahip YSA vermiştir. Eğitim başarımı %97, test başarımı %94.10 ve doğrulama %87.80 olarak elde edilmiştir.




Şekil 4.3. LM eğitim algoritması ile sınıflandırma başarımları

Şekil 4.4'de BR eğitim algoritması ile sınıflandırma başarımları gösterilmektedir. Gizli katman nöron sayısı 1'den başlayarak 100'e kadar artırılarak sınıflandırma yapılmıştır. En iyi sınıflandırma başarımlarını gizli katmanda 49 nöron sayısına sahip YSA vermiştir. Eğitim başarımlarını %96.20, test başarımlarını %93.00 ve doğrulama %90.40 olarak elde edilmiştir.




Şekil 4.4. BR eğitim algoritması ile sınıflandırma başarımları

Şekil 4.5'de BFG eğitim algoritması ile sınıflandırma başarımları gösterilmektedir. Gizli katman nöron sayısı 1'den başlayarak 100'e kadar artırılarak sınıflandırma yapılmıştır. En iyi sınıflandırma başarımlarını gizli katmanda 91 nöron sayısına sahip YSA vermiştir. Test başarımlarını %93.30 ve doğrulama %90.40 olarak elde edilmiştir.




Şekil 4.5. BFG eğitim algoritması ile sınıflandırma başarımları

Şekil 4.6'da NRP eğitim algoritması ile sınıflandırma başarımları gösterilmektedir. Gizli katman nöron sayısı 1'den başlayarak 100'e kadar artırılarak sınıflandırma yapılmıştır. En iyi sınıflandırma başarımlarını gizli katmanda 97 nöron sayısına sahip YSA vermiştir. Eğitim başarımlarını %98.20, test başarımlarını %92.60 ve doğrulama %88.50 olarak elde edilmiştir.




Şekil 4.6. NRP eğitim algoritması ile sınıflandırma başarımları

Şekil 4.7'de CGB eğitim algoritması ile sınıflandırma başarımları gösterilmektedir. Gizli katman nöron sayısı 1'den başlayarak 100'e kadar artırılarak sınıflandırma yapılmıştır. En iyi sınıflandırma başarımlarını gizli katmanda 98 nöron sayısına sahip YSA vermiştir. Eğitim başarımlarını %99.40, test başarımlarını %94.40 ve doğrulama %92.20 olarak elde edilmiştir.




Şekil 4.7. CGB eğitim algoritması ile sınıflandırma başarımları

Şekil 4.8’de CGF eğitim algoritması ile sınıflandırma başarımları gösterilmektedir. Gizli katman nöron sayısı 1’den başlayarak 100’e kadar artırılarak sınıflandırma yapılmıştır. En iyi sınıflandırma başarımlarını gizli katmanda 65 nöron sayısına sahip YSA vermiştir. Eğitim başarımlarını %96.70, test başarımlarını %93.00 ve doğrulama %90.40 olarak elde edilmiştir.




Şekil 4.8. CGF eğitim algoritması ile sınıflandırma başarımları

Şekil 4.9’da CGP eğitim algoritması ile sınıflandırma başarımları gösterilmektedir. Gizli katman nöron sayısı 1’den başlayarak 100’e kadar artırılarak sınıflandırma yapılmıştır. En iyi sınıflandırma başarımlarını gizli katmanda 85 nöron sayısına sahip YSA vermiştir. Eğitim başarımlarını %98.70, test başarımlarını %94.10 ve doğrulama %90.40 olarak elde edilmiştir.




Şekil 4.9. CGP eğitim algoritması ile sınıflandırma başarımları

Şekil 4.10'da OSS eğitim algoritması ile sınıflandırma başarımları gösterilmektedir. Gizli katman nöron sayısı 1'den başlayarak 100'e kadar artırılarak sınıflandırma yapılmıştır. En iyi sınıflandırma başarımlarını gizli katmanda 65 nöron sayısına sahip YSA vermiştir. Eğitim başarımlarını %97.40, test başarımlarını %94.10 ve doğrulama %89.30 olarak elde edilmiştir.




Şekil 4.10. OSS eğitim algoritması ile sınıflandırma başarımları

Şekil 4.11'de GDX eğitim algoritması ile sınıflandırma başarımları gösterilmektedir. Gizli katman nöron sayısı 1'den başlayarak 100'e kadar artırılarak sınıflandırma yapılmıştır. En iyi sınıflandırma başarımlarını gizli katmanda 33 nöron sayısına sahip YSA vermiştir. Eğitim başarımlarını %95.90, test başarımlarını %93.70 ve doğrulama %91.50 olarak elde edilmiştir.




Şekil 4.11. GDX eğitim algoritması ile sınıflandırma başarımları

Şekil 4.12’de GDM eğitim algoritması ile sınıflandırma başarımları gösterilmektedir. Gizli katman nöron sayısı 1’den başlayarak 100’e kadar artırılarak sınıflandırma yapılmıştır. En iyi sınıflandırma başarımlarını gizli katmanda 74 nöron sayısına sahip YSA vermiştir. Test başarımlarını %76.70 ve doğrulama %74.10 olarak elde edilmiştir.




Şekil 4.12. GDM eğitim algoritması ile sınıflandırma başarımları

Şekil 4.13’de GD eğitim algoritması ile sınıflandırma başarımları gösterilmektedir. Gizli katman nöron sayısı 1’den başlayarak 100’e kadar artırılarak sınıflandırma yapılmıştır. En iyi sınıflandırma başarımlarını gizli katmanda 98 nöron sayısına sahip YSA vermiştir. Test başarımlarını %77.80 ve doğrulama %75.60 olarak elde edilmiştir.




Şekil 4.13. GD eğitim algoritması ile sınıflandırma başarımları

Şekil 4.14’de jiroskop verileri eklenerek SCG eğitim algoritması ile sınıflandırma başarımları gösterilmektedir. Gizli katman nöron sayısı 1’den başlayarak 100’e kadar artırılarak sınıflandırma yapılmıştır. En iyi sınıflandırma başarımlarını gizli katmanda 97 nöron sayısına sahip YSA vermiştir. Eğitim başarımlarını %98.40, test başarımlarını %96.30 ve doğrulama %91.50 olarak elde edilmiştir.




Şekil 4.14. Jiroskop verileri eklenerek SCG eğitim algoritması ile sınıflandırma

Şekil 4.15’de jiroskop verileri eklenerek NRP eğitim algoritması ile sınıflandırma başarımları gösterilmektedir. Gizli katman nöron sayısı 1’den başlayarak 100’e kadar artırılarak sınıflandırma yapılmıştır. En iyi sınıflandırma başarımlarını gizli katmanda 100 nöron sayısına sahip YSA vermiştir. Eğitim başarımlarını %99.70, test başarımlarını %94.10 ve doğrulama %97.70 olarak elde edilmiştir.




Şekil 4.15. Jiroskop verileri eklenerek NRP eğitim algoritması ile sınıflandırma

Şekil 4.16'da jiroskop verileri eklenerek CGB eğitim algoritması ile sınıflandırma başarımları gösterilmektedir. Gizli katman nöron sayısı 1'den başlayarak 100'e kadar artırılarak sınıflandırma yapılmıştır. En iyi sınıflandırma başarımlarını gizli katmanda 46 nöron sayısına sahip YSA vermiştir. Eğitim başarımlarını %98.20, test başarımlarını %93.70 ve doğrulama %91.90 olarak elde edilmiştir.




Şekil 4.16. Jiroskop verileri eklenerek CGB eğitim algoritması ile sınıflandırma

Şekil 4.17'de jiroskop verileri eklenerek CGF eğitim algoritması ile sınıflandırma başarımları gösterilmektedir. Gizli katman nöron sayısı 1'den başlayarak 100'e kadar artırılarak sınıflandırma yapılmıştır. En iyi sınıflandırma başarımlarını gizli katmanda 99 nöron sayısına sahip YSA vermiştir. Eğitim başarımlarını %100, test başarımlarını %93.70 ve doğrulama %93.30 olarak elde edilmiştir.




Şekil 4.17. Jiroskop verileri eklenerek CGF eğitim algoritması ile sınıflandırma

Şekil 4.18’de jiroskop verileri eklenerek CGP eğitim algoritması ile sınıflandırma başarımları gösterilmektedir. Gizli katman nöron sayısı 1’den başlayarak 100’e kadar artırılarak sınıflandırma yapılmıştır. En iyi sınıflandırma başarımlarını gizli katmanda 74 nöron sayısına sahip YSA vermiştir. Eğitim başarımlarını %98.50, test başarımlarını %94.40 ve doğrulama %91.10 olarak elde edilmiştir.




Şekil 4.18. Jiroskop verileri eklenerek CGP eğitim algoritması ile sınıflandırma

Şekil 4.19’da jiroskop verileri eklenerek OSS eğitim algoritması ile sınıflandırma başarımları gösterilmektedir. Gizli katman nöron sayısı 1’den başlayarak 100’e kadar artırılarak sınıflandırma yapılmıştır. En iyi sınıflandırma başarımlarını gizli katmanda 53 nöron sayısına sahip YSA vermiştir. Eğitim başarımlarını %99.10, test başarımlarını %95.90 ve doğrulama %92.60 olarak elde edilmiştir.




Şekil 4.19. Jiroskop verileri eklenerek OSS eğitim algoritması ile sınıflandırma

Şekil 4.20’de jiroskop verileri eklenerek GDX eğitim algoritması ile sınıflandırma başarımları gösterilmektedir. Gizli katman nöron sayısı 1’den başlayarak 100’e kadar artırılarak sınıflandırma yapılmıştır. En iyi sınıflandırma başarımlarını gizli katmanda 45 nöron sayısına sahip YSA vermiştir. Eğitim başarımlarını %96.70, test başarımlarını %94.80 ve doğrulama %94.10 olarak elde edilmiştir.




Şekil 4.20. Jiroskop verileri eklenerek GDX eğitim algoritması ile sınıflandırma

Şekil 4.21’de jiroskop verileri eklenerek GDM eğitim algoritması ile sınıflandırma başarımları gösterilmektedir. En iyi sınıflandırma başarımlarını gizli katmanda 58 nöron sayısına sahip YSA vermiştir. Test başarımlarını %78.90 ve doğrulama %74.10 olarak elde edilmiştir.



Şekil 4.21. Jiroskop verileri eklenerek GDM eğitim algoritması ile sınıflandırma

Şekil 4.22’de jiroskop verileri eklenerek GD eğitim algoritması ile sınıflandırma başarımları gösterilmektedir. Gizli katman nöron sayısı 1’den başlayarak 100’e kadar artırılarak sınıflandırma yapılmıştır. En iyi sınıflandırma başarımlarını gizli katmanda 68 nöron sayısına sahip YSA vermiştir. Test başarımları %79.60 ve doğrulama %74.40 olarak elde edilmiştir.



Şekil 4.22. Jiroskop verileri eklenerek GD eğitim algoritması ile sınıflandırma

Tablo 4.37’de YSA ile yapılan sınıflandırmada eğitim algoritmalarının en yüksek başarımları verdiği veri seti ve gizli katman nöron sayısı gösterilmiştir. Yüzey EMG veri setinde en yüksek başarımları %94.40 ile CGB eğitim algoritması 98 gizli

katman nöron sayısında vermiştir. Yüzey EMG ve jiroskop verileri ile en yüksek başarıyı %96.30 ile SCG eğitim algoritması 97 gizli katman nöron sayısında vermiştir. Veri setine jiroskop verilerinin eklenmesi ile yapılan sınıflandırmalarda genellikle başarımın arttığı gözlenmektedir. Test başarıyı %96.30 ve doğrulama %91.50 olarak elde edilmiştir.

Tablo 4.37. Eğitim algoritmalarının en yüksek başarıları


Veri Seti	Eğitim Algoritması	Gizli Katman Nöron Sayısı	Sınıflandırma Başarımları	
			Test	Doğrulama
EMG	SCG	83	93.70	88.90
EMG	LM	65	94.10	87.80
EMG	BR	49	93.00	90.40
EMG	BFG	91	93.30	90.40
EMG	NRP	97	92.60	88.50
EMG	CGB	98	94.40	92.20
EMG	CGF	65	93.00	90.40
EMG	CGP	85	94.10	90.40
EMG	OSS	65	94.10	89.30
EMG	GDX	33	93.70	91.50
EMG	GDM	74	76.70	74.10
EMG	GD	98	77.80	75.60
EMG,GYRO	SCG	97	96.30	91.50
EMG,GYRO	NRP	100	94.10	97.70
EMG,GYRO	CGB	46	93.70	91.90
EMG,GYRO	CGF	99	93.70	93.30
EMG,GYRO	CGP	74	94.40	91.10
EMG,GYRO	OSS	53	95.90	92.60
EMG,GYRO	GDX	45	94.80	94.10
EMG,GYRO	GDM	58	78.90	74.10
EMG,GYRO	GD	68	79.60	74.40

YSA'nda en yüksek sınıflandırma başarıyı veren eğitim algoritması SCG'dır. Bu nedenle bireysel sınıflandırma için SCG eğitim algoritması kullanılmıştır. Tüm veriler kullanılarak yapılan sınıflandırmada en iyi başarıyı gizli katmanda 97 nöron sayısına sahip YSA vermiştir. Bireysel veriler kullanılarak yapılan sınıflandırma için gizli katman nöron sayısı 90'dan başlayarak 100'e kadar artırılarak sınıflandırma yapılmıştır. SCG eğitim algoritması ile bireysel sınıflandırma başarımları Tablo 4.38'de verilmektedir. Farklı gizli katman nöron sayılarında bireysel sınıflandırma başarımları tüm katılımcılarda %100'dür.

Tablo 4.38. SCG eğitim algoritması ile bireysel sınıflandırma başarımları


Katılımcılar		GİZLİ KATMAN NÖRON SAYISI										
		90	91	92	93	94	95	96	97	98	99	100
K1	Eğitim	100	100	100	100	100	100	100	100	100	100	100
	Test	100	100	100	100	100	100	100	100	100	100	100
	Doğrulama	100	96.3	100	100	100	100	100	100	100	100	100
K2	Eğitim	100	99.2	100	100	100	100	100	96	100	100	100
	Test	100	92.6	96.3	96.3	100	96.3	100	92.6	100	100	100
	Doğrulama	100	92.6	92.6	96.3	100	88.9	96.3	92.6	100	100	96.3
K3	Eğitim	100	100	100	100	100	100	100	100	100	100	100
	Test	96.3	100	100	100	100	100	96.3	96.3	100	100	100
	Doğrulama	100	96.3	96.3	100	96.3	100	96.3	100	100	96.3	100
K4	Eğitim	100	100	100	100	100	100	100	100	100	100	100
	Test	96.3	96.3	100	96.3	100	100	96.3	100	100	100	100
	Doğrulama	100	100	96.3	96.3	96.3	100	100	100	100	100	96.3
K5	Eğitim	97.6	100	100	100	97.6	100	100	99.2	100	100	99.2
	Test	96.3	92.6	100	88.9	92.6	96.3	88.9	96.3	88.9	88.9	100
	Doğrulama	88.9	92.6	100	92.6	92.6	92.6	96.3	92.6	100	100	96.3
K6	Eğitim	98.4	100	100	100	100	100	100	100	100	100	98.4
	Test	96.3	92.6	100	100	100	96.3	100	96.3	96.3	96.3	96.3
	Doğrulama	96.3	100	100	92.6	100	100	100	96.3	100	100	92.6
K7	Eğitim	100	100	100	98.4	100	96	100	100	100	100	100
	Test	96.3	96.3	96.3	100	96.3	100	100	88.9	96.3	96.3	100
	Doğrulama	100	100	100	88.9	100	96.3	92.6	96.3	100	96.3	100
K8	Eğitim	100	100	100	100	100	100	100	100	100	100	100
	Test	96.3	100	96.3	96.3	100	96.3	100	100	100	100	100
	Doğrulama	96.3	100	100	96.3	100	100	100	100	100	100	100
K9	Eğitim	100	98.4	99.2	100	100	99.2	100	99.2	96.8	100	100
	Test	96.3	96.3	96.3	96.3	100	96.3	100	96.3	92.6	96.3	96.3
	Doğrulama	100	96.3	96.3	96.3	96.3	96.3	100	96.3	100	100	96.3
K10	Eğitim	100	100	100	100	100	100	100	100	100	100	100
	Test	100	100	96.3	100	100	100	100	100	100	100	100
	Doğrulama	100	100	100	100	100	100	100	100	100	100	100
Ort.	Eğitim	99.6	99.7	99.5	99.8	99.7	99.5	100	99.4	99.6	100	99.7
	Test	97.4	96.6	98.5	97.4	98.9	98.1	98.1	<u>96.7</u>	97.4	97.7	99.2
	Doğrulama	98.1	97.4	98.1	95.9	98.1	97.4	98.1	97.4	100	99.2	97.7
Tümü	Eğitim	93	98.6	97.5	99	99.4	98	94.8	98.4	98	97.6	96.7
	Test	85.6	91.5	92.2	90	89.3	90.7	91.5	<u>96.3</u>	90.4	93	93
	Doğrulama	87.4	92.2	91.9	92.6	90.4	93.7	88.9	91.5	91.1	91.1	92.2

Şekil 4.23’de gizli katman nöron sayısı 97’ken SCG eğitim algoritması ile bireysel sınıflandırma başarımları verilmiştir. Katılımcıların ortalaması alındığında eğitim başarımları 99.40, test başarımları 96.60 ve doğrulama başarımları 97.40 olarak elde edilmiştir. Tüm veri seti kullanılarak yapılan sınıflandırmada eğitim başarımları 98.40, test başarımları 96.30 ve doğrulama başarımları 91.50’dir. Bireysel verilerin sınıflandırma başarımları tüm verilerin sınıflandırma başarımlarından daha yüksektir.



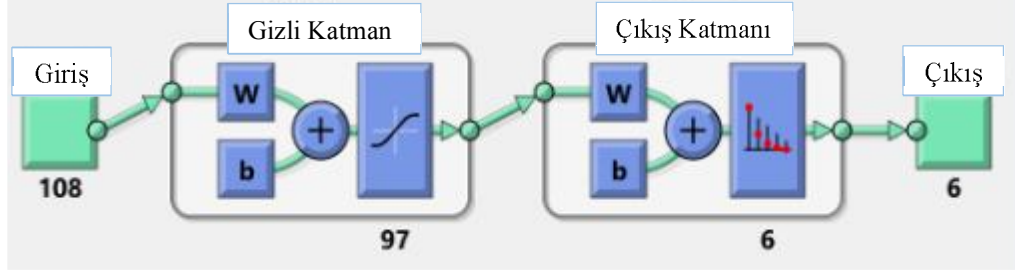
Şekil 4.23. SCG eğitim algoritması ile bireysel sınıflandırma başarımları

Farklı pencere boyutları ile sınıflandırmanın başarıma etkisi Şekil 4.24'de gösterilmiştir. 50 ms, 100 ms, 150 ms, 200 ms, 250 ms ve 300 ms için sınıflandırma yapılmıştır. Yapılan sınıflandırmada 100 ms'de sınıflandırıcı en iyi sonucu verdiği gözlenmiştir. Pencerelelere bölünerek yapılan sınıflandırmada %50 örtüşme kullanılmıştır. Jiroskop verileri eklenmiştir. Gizli katman nöron sayısı 97 seçilmiştir. SCG eğitim algoritmasında eğitilmiştir. EMVA, SSI, VAR, DASDV, RMS, EWL, MMAV2, MMAV1, MFL, MYOP, MAV ve ZC öznitelikleri kullanılmıştır.



Şekil 4.24. Farklı pencere boyutlarında sınıflandırma başarımları

YSA ile yapılan sınıflandırmada en yüksek başarımları SCG eğitim algoritması 97 gizli katman nöron sayısında vermiştir. Ağın yapısı Şekil 4.25'de gösterilmektedir.



Şekil 4.25. Katmanlar ve nöron sayıları

Şekil 4.26'da YSA ile yapılan sınıflandırmada en yüksek başarıyı gösteren sistemin karmaşıklık matrisi gösterilmektedir. Eğitim veri setinin sınıflandırma başarıyı %98.40, test başarıyı %96.30 ve doğrulama başarıyı %91.50 olarak elde edilmiştir.

EĞİTİM KARMAŞIKLIK MATRİSİ							
Tahmin Sınıfları	1	2	3	4	5	6	
1	214	1	1	0	2	0	%98,2
2	0	208	3	0	1	0	%98,1
3	1	2	205	0	0	0	%98,6
4	0	2	1	203	1	0	%98,1
5	2	1	0	2	187	0	%97,4
6	0	0	0	0	0	223	%100
	%98,6	%97,2	%97,2	%99	%97,9	%100	%98,4
	1	2	3	4	5	6	
	Gerçek Sınıflar						

DOĞRULAMA KARMAŞIKLIK MATRİSİ							
Tahmin Sınıfları	1	2	3	4	5	6	
1	32	0	1	0	2	0	%91,4
2	2	37	6	0	1	0	%80,4
3	1	4	38	0	0	0	%88,4
4	2	0	1	44	0	0	%94,3
5	0	0	1	2	50	0	%94,3
6	0	0	0	0	0	46	%100
	%86,5	%90,2	%80,9	%95,7	%94,3	%100	%91,5
	1	2	3	4	5	6	
	Gerçek Sınıflar						

TEST KARMAŞIKLIK MATRİSİ							
Tahmin Sınıfları	1	2	3	4	5	6	
1	45	1	0	0	1	0	%95,7
2	0	42	2	0	0	0	%95,5
3	1	2	41	0	1	0	%91,1
4	0	0	0	48	1	0	%98
5	0	0	0	1	53	0	%98,1
6	0	0	0	0	0	31	%100
	%97,8	%93,3	%95,3	%98	%94,6	%100	%96,3
	1	2	3	4	5	6	
	Gerçek Sınıflar						

TÜM VERİLERİN KARMAŞIKLIK MATRİSİ							
Tahmin Sınıfları	1	2	3	4	5	6	
1	291	2	2	0	5	0	%97
2	2	287	11	0	2	0	%95
3	3	8	284	0	1	0	%95,9
4	2	2	2	295	2	0	%97,4
5	2	1	1	5	290	0	%97
6	0	0	0	0	0	300	%100
	%97	%95,7	%94,7	%98,3	%96,7	%100	%97,1
	1	2	3	4	5	6	
	Gerçek Sınıflar						

Şekil 4.26. YSA sınıflandırmanın karmaşıklık matrisi ile gösterimi

Sınıflandırma işlemlerinin değerlendirme araçları doğruluk, hassasiyet, özgünlük, pozitif tahmin değeri ve negatif tahmin değeridir. Başparmak hareketinin

başarım yüzdeleri Tablo 4.39’da verilmiştir. Hassasiyet %97.82, özgünlük %99.11, pozitif tahmin değeri %95.74 ve negatif tahmin değeri %99.55 olarak elde edilmiştir.

Tablo 4.39. Başparmağın başarım yüzdelerinin hesaplanması

BAŞPARMAK	
Doğru Pozitifler(TP)=45	Doğru Negatifler(TN)=222
Yanlış Pozitifler(FP)=2	Yanlış Negatifler(FN)=1
Hassasiyet= $TP/(TP+FN) \times 100=45/(45+1) \times 100=97.82$	
Özgünlük = $TN / (TN + FP) \times 100=222/(222+2) \times 100=99.11$	
Pozitif tahmin değeri = $TP / (TP + FP) \times 100=45/47 \times 100=95.74$	
Negatif tahmin değeri = $TN / (TN + FN) \times 100=222/223 \times 100=99.55$	

İşaret parmak hareketinin başarım yüzdeleri Tablo 4.40’da verilmiştir. Hassasiyet %93.33, özgünlük %99.11, pozitif tahmin değeri %95.45 ve negatif tahmin değeri %98.67 olarak elde edilmiştir.

Tablo 4.40. İşaret parmağın başarım yüzdelerinin hesaplanması

İŞARET PARMAK	
Doğru Pozitifler(TP)=42	Doğru Negatifler(TN)=223
Yanlış Pozitifler(FP)=2	Yanlış Negatifler(FN)=3
Hassasiyet = $TP/(TP+FN) \times 100=42/45 \times 100=93.33$	
Özgünlük = $TN / (TN + FP) \times 100=223/225 \times 100=99.11$	
Pozitif tahmin değeri = $TP / (TP + FP) \times 100=42/44 \times 100=95.45$	
Negatif tahmin değeri = $TN / (TN + FN) \times 100=223/226 \times 100=98.67$	

Orta parmak hareketinin başarım yüzdeleri Tablo 4.41’de verilmiştir. Hassasiyet %95.35, özgünlük %98.24, pozitif tahmin değeri %91.11 ve negatif tahmin değeri %99.11 olarak elde edilmiştir.

Tablo 4.41. Orta parmağın başarım yüzdelerinin hesaplanması

ORTA PARMAK	
Doğru Pozitifler(TP)=41	Doğru Negatifler(TN)=223
Yanlış Pozitifler(FP)=4	Yanlış Negatifler(FN)=2
Hassasiyet = $TP/(TP+FN) \times 100=41/43 \times 100=95.35$	
Özgünlük = $TN / (TN + FP) \times 100=223/227 \times 100=98.24$	
Pozitif tahmin değeri = $TP / (TP + FP) \times 100=41/45 \times 100=91.11$	
Negatif tahmin değeri = $TN / (TN + FN) \times 100=223/225 \times 100=99.11$	

Yüzük parmak hareketinin başarım yüzdeleri Tablo 4.42’de verilmiştir. Hassasiyet %97.96, özgünlük %98.26, pozitif tahmin değeri %97.96 ve negatif tahmin değeri %98.26 olarak elde edilmiştir.

Tablo 4.42. Yüzük parmağın başarımların yüzdelerinin hesaplanması

YÜZÜK PARMAK	
Doğru Pozitifler(TP)=48	Doğru Negatifler(TN)=220
Yanlış Pozitifler(FP)=1	Yanlış Negatifler(FN)=1
Hassasiyet = $TP/(TP+FN) \times 100=48/49 \times 100=97.96$	
Özgünlük = $TN / (TN + FP) \times 100=220/221 \times 100=99.53$	
Pozitif tahmin değeri = $TP / (TP + FP) \times 100=48/49 \times 100=97.96$	
Negatif tahmin değeri = $TN / (TN + FN) \times 100=220/221 \times 100=99.53$	

Serçe parmak hareketinin başarımların yüzdeleri Tablo 4.43'de verilmiştir. Hassasiyet %94.64, özgünlük %99.53, pozitif tahmin değeri %98.15 ve negatif tahmin değeri %98.61 olarak elde edilmiştir.

Tablo 4.43. Serçe parmağın başarımların yüzdelerinin hesaplanması

SERÇE PARMAK	
Doğru Pozitifler(TP)=53	Doğru Negatifler(TN)=213
Yanlış Pozitifler(FP)=1	Yanlış Negatifler(FN)=3
Hassasiyet = $TP/(TP+FN) \times 100=53/56 \times 100=94.64$	
Özgünlük = $TN / (TN + FP) \times 100=213/214 \times 100=99.53$	
Pozitif tahmin değeri = $TP / (TP + FP) \times 100=53/54 \times 100=98.15$	
Negatif tahmin değeri = $TN / (TN + FN) \times 100=213/216 \times 100=98.61$	

Dinlenme hareketinin başarımların yüzdeleri Tablo 4.44'de verilmiştir. Hassasiyet %100, özgünlük %100, pozitif tahmin değeri %100 ve negatif tahmin değeri %100'dür.

Tablo 4.44. Dinlenme hareketinin başarımların yüzdelerinin hesaplanması

DİNLENME HAREKETİ	
Doğru Pozitifler(TP)=31	Doğru Negatifler(TN)=239
Yanlış Pozitifler(FP)=0	Yanlış Negatifler(FN)=0
Hassasiyet = $TP/(TP+FN) \times 100=31/31 \times 100=100$	
Özgünlük = $TN / (TN + FP) \times 100=239/239 \times 100=100$	
Pozitif tahmin değeri = $TP / (TP + FP) \times 100=31/31 \times 100=100$	
Negatif tahmin değeri = $TN / (TN + FN) \times 100=239/239 \times 100=100$	

5 parmak ve dinlenme hareketi için başarımların yüzdeleri şunlardır:

$$\text{Ortalama Hassasiyet} = (97.82+93.33+95.35+97.96+94.64+100) / 6 = \%96.3$$

$$\text{Ortalama Özgünlük} = (99.11+99.11+98.24+98.26+99.53+100) / 6 = \%99.04$$

$$\text{Ortalama Pozitif Tahmin Değeri} = (95.74+95.45+91.11+97.96+98.15+100)/6 = \%96.3$$


$$\text{Ortalama Negatif Tahmin Değeri} = (99.55+98.67+99.11+98.26+98.6+100)/6 = \%99.03$$

$$\text{Doğruluk} = TP(\text{Tüm Sınıflar})/\text{Tüm Veriler} \times 100 = 260/270 = \%96.3$$

Bu sınıflandırmada doğruluk %96.3, ortalama hassasiyet %96.3, ortalama özgünlük %99.04, ortalama pozitif tahmin değeri %96.3 ve ortalama negatif tahmin değeri %99.03 olarak elde edilmiştir.


4.3. Gerçek Zamanlı Veriler İle Yapılan Sınıflandırmanın Bulguları

Gerçek zamanlı sınıflandırma işlemi çevrimdışı olarak oluşturulan modele myo bileklikten anlık olarak alınan veriler gönderilerek yapılmıştır. Gerçek zamanlı sınıflandırmada matlab® programında yazılan kod ile gerçek zamanlı veriler alınmıştır. Alınan veri filtrelenmiş, özneteliği çıkarılmış ve modele gönderilerek sınıflandırılmıştır. Bu işlem her hareket için 30 kez tekrarlanarak gerçekleştirilmiştir. Yüzey EMG veri setinde CLA kullanılarak en yüksek başarıyı veren model CSVM modelidir ve çevrimdışı başarıyı %91,56'dır. Şekil 4.27'de CSVM sınıflandırıcısı kullanılarak yapılan gerçek zamanlı sınıflandırma başarımları verilmiştir. CSVM modeli oluşturulurken 1 katılımcının bireysel verileri kullanılarak model oluşturulmuş ve aynı katılımcının gerçek zamanlı verileri ile test edilmiştir. Çevrimdışı sınıflandırmada en yüksek başarıyı veren EMAV, SSI, VAR, DASDV, RMS, EWL, MMAV2, MMAV1, MFL, MYOP, MAV ve ZC öznetelikleri kullanılarak oluşturulan modelin gerçek zamanlı sınıflandırmada başarımları %41.67 olarak düşük bir başarımla elde edilmiştir. Başarımların düşük olmasının nedeni belirlenen öznetelik grubunun fazla işlem süresi ile sınıflandırılmasından kaynaklanmaktadır. Gerçek zamanlı sınıflandırmada tüm işlemler 300 ms az olarak hesaplanması gerekmektedir. Ancak yapılan sınıflandırmada bu süre aşılmıştır. Böylece veri kaybı yaşanmış ve sınıflandırma başarımları düşük elde edilmiştir. Her öznetelik için çevrimdışı olarak CSVM yönteminde model oluşturulmuş ve gerçek zamanlı sınıflandırma yapılmıştır. RMS özneteliği kullanılarak oluşturulan model en yüksek başarımla göstermiş ve başarımları %75 olarak elde edilmiştir.



Şekil 4.27. CSVM modeli ile gerçek zamanlı sınıflandırma başarımları


CSVM sınıflandırıcısında gerçek zamanlı veriler sınıflandırılırken düşük başarımlar elde edilmiştir. Çevrimdışı sınıflandırmada yüksek başarımlar veren SKNN, QSVM, MGSVM, FKNN ve WKNN yöntemleri ile de gerçek zamanlı sınıflandırma yapılmıştır. RMS özneliği ile farklı sınıflandırıcılar kullanılarak yapılan gerçek zamanlı sınıflandırma başarımları Şekil 4.28’de gösterilmektedir. 1 katılımcının verileri çevrimdışı sınıflandırılarak model oluşturulmuş ve aynı katılımcının gerçek zamanlı verileri ile test edilmiştir. WKNN modeli RMS özneliği ile gerçek zamanlı sınıflandırmada %90 başarımlar vermiştir. En düşük başarımları %57.22 ile MGSVM modeli vermiştir.



Şekil 4.28. RMS özneliğiyle farklı sınıflandırıcılardaki başarımlar


Şekil 4.29’da farklı veri setleri kullanılarak tekrarlanan gerçek zamanlı sınıflandırma başarımları verilmiştir. WKNN sınıflandırıcısı ve RMS özneliği kullanılarak 2 model oluşturulmuştur. İlk modelde 1 katılımcının verileri kullanılmıştır. Diğer modelde ise 10 katılımcının verileri kullanılmıştır. Modeller çevrimdışı sınıflandırılarak oluşturulmuştur. Oluşturulan modeller 10 kez tekrarlanmıştır. İki model için de 1 katılımcıdan gerçek zamanlı veri alınmıştır. 1 katılımcının veri seti kullanılarak çevrimdışı oluşturulan modelde kullanılan katılımcı ile gerçek zamanlı veri alınan katılımcı aynı kişiden seçilmiştir. Bireysel veri seti ile oluşturulan modelde en yüksek başarımlar %97.78 ve en düşük başarımlar %90.56 olarak elde edilmiştir. 10 tekrarın ortalamasında başarımlar %95.11’dir. Tüm veri seti kullanılarak oluşturulan modelde en yüksek başarımlar %93.89 ve en düşük başarımlar %86.67 olarak elde edilmiştir. 10 tekrarın ortalamasında başarımlar %90.67’dir. Sonuçlar incelendiğinde bireysel veriler kullanılarak oluşturulan model tüm veriler kullanılarak oluşturulan modele göre daha yüksek başarımlar vermiştir. Bunun nedeni yüzey EMG

verisinin katılımcıdan katılımcıya farklılık göstermesinden kaynaklandığı düşünülmektedir.




Şekil 4.29. Farklı veriler kullanarak tekrarlanan gerçek zamanlı sınıflandırma 1

Şekil 4.30’da farklı veri setleri kullanarak tekrarlanan gerçek zamanlı sınıflandırma başarımları verilmiştir. Başka bir katılımcı kullanılarak Şekil 4.29 oluşturulurken yapılan işlemler tekrarlanmıştır. Bireysel veri seti ile oluşturulan modelde en yüksek başarımlar %98.33 ve en düşük başarımlar %95.56 olarak elde edilmiştir. 10 tekrarın ortalamasında başarımlar %97.45’dir. Tüm veri seti kullanılarak oluşturulan modelde en yüksek başarımlar %97.78 ve en düşük başarımlar %91.11 olarak elde edilmiştir. 10 tekrarın ortalamasında başarımlar %94.89’dur. Bireysel veriler kullanılarak oluşturulan model tüm veriler kullanılarak oluşturulan modele göre daha yüksek başarımlar vermiştir. Şekil 4.29 ve Şekil 4.30 incelendiğinde yüzey EMG verilerinin başarımlarının kişiden kişiye değiştiği gözlemlenmektedir.



Şekil 4.30. Farklı veriler kullanarak tekrarlanan gerçek zamanlı sınıflandırma 2

Katılımcıların bireysel veri seti ve tüm veri seti ile sınıflandırılan modelde gerçek zamanlı başarımları Şekil 4.31’de verilmiştir. Gerçek zamanlı sınıflandırmada en yüksek başarıyı veren RMS özneliği ve WKNN yöntemi ile farklı katılımcıların veri setlerinde çevrimdışı sınıflandırılarak modeller oluşturulmuştur. Bireysel veri seti ile yapılan sınıflandırmada en yüksek başarıım %98.33 olarak elde edilmiş ve bu başarıım katılımcı 8’den alınan veriler ile gerçekleştirilmiştir. Bireysel veri seti ile yapılan sınıflandırmada en düşük başarıım %85.56 olarak elde edilmiş ve bu başarıım katılımcı 2’den alınan veriler ile gerçekleştirilmiştir. Tüm veri setinde tüm katılımcıların verileri ile çevrimdışı model oluşturulmuş ve her katılımcının kendi verileri ile gerçek zamanlı sınıflandırma yapılmıştır. Tüm veri seti ile yapılan sınıflandırmada en yüksek başarıım %97.78 olarak elde edilmiş ve bu başarıım katılımcı 8’den alınan veriler ile gerçekleştirilmiştir. Tüm veri seti ile yapılan sınıflandırmada en düşük başarıım %86.11 olarak elde edilmiş ve bu başarıım katılımcı 5’den alınan veriler ile gerçekleştirilmiştir. Bireysel veri setinde katılımcıların ortalama başarıımı %92.17 ve tüm veri setinde katılımcıların ortalaması %90.36 olarak elde edilmiştir. Sonuçlar incelendiğinde gerçek zamanlı sınıflandırmada yüksek başarıım elde edilmiştir. Bireysel veri setinde tüm veri setine göre daha yüksek başarıım elde edilmiştir.



Şekil 4.31. Katılımcıların gerçek zamanlı sınıflandırmaları

5. TARTIŞMALAR

Parmak hareketleri sonucunda oluşan işaretleri kullanarak protez kontrol sistemi veya sanal el kontrol sistemleri tasarlanabilmektedir. Bu çalışmada parmak hareketleri çevrimdışı ve gerçek zamanlı sınıflandırılarak protez veya sanal el kontrolü için modeller oluşturulmuştur. Literatürde parmak hareketlerinin sınıflandırılması ile ilgili birçok çalışma yapılmıştır. Myo bileklik kullanılarak parmak hareketlerinin sınıflandırılması ile ilgili yapılan çalışmalar Tablo 5.1’de verilmiştir.

Yüzey EMG ve jiroskop verileri ile YSA kullanılarak yapılan bu çalışmada %96.30 başarımla elde edilmiştir. Yapılan çalışma literatürdeki çalışmalardan (Altan et al., 2019; Caesarendra et al., 2018; Castiblanco et al., 2016; Millar et al., 2020; Naseer et al., 2018; Singhvi and Ren, 2018; Srinivasan et al., 2018; Stephenson et al., 2018; Tepe and Erdim, 2020) daha yüksek başarımla vermiştir. Bazı çalışmalarda (Arozi et al., 2020; S. Krishnan et al., 2019) 1 kişiden veri olarak parmak hareketlerini sınıflandırmışlardır. Tez çalışmasında bireysel veriler kullanılarak sınıflandırma yapılmış ve en yüksek başarımla %100 olarak elde edilmiştir. Böylece bir kişiden veri olarak yapılan literatürdeki çalışmalardan (Arozi et al., 2020; S. Krishnan et al., 2019) daha yüksek başarımla elde edilmiştir.

Yüzey EMG verileri kullanılarak YSA’nda yapılan çalışmada %94.40 başarımla elde edilmiştir. Literatürdeki çalışmalardan (Altan et al., 2019; Caesarendra et al., 2018; Castiblanco et al., 2016; Millar et al., 2020; Singhvi and Ren, 2018; Srinivasan et al., 2018) daha yüksek başarımla elde edilmiştir.

Yüzey EMG ve jiroskop verileri kullanılarak CSVM yöntemi ile sınıflandırılan çalışmada %92.56 başarımla elde edilmiştir. Literatürdeki çalışmalardan (Caesarendra et al., 2018; Castiblanco et al., 2016; Millar et al., 2020; Singhvi and Ren, 2018; Srinivasan et al., 2018) daha yüksek başarımla elde edilmiştir.

Yüzey EMG verileri kullanılarak CSVM yöntemi ile sınıflandırılan çalışmada %91.56 başarımla elde edilmiştir. Literatürdeki çalışmalardan (Caesarendra et al., 2018; Millar et al., 2020; Singhvi and Ren, 2018; Srinivasan et al., 2018) daha yüksek başarımla elde edilmiştir.

Tablo 5.1. Literatürde myo bileklikle yapılan çalışmalar

Literatürdeki Çalışmalar	Deney Protokolü	Öznitelikler	Sınıflandırma Yöntemi	Başarım
(Millar et al., 2020)	1 kişi, 70 tekrar, 12 parmak hareketi	MAV, WL, VAR, SSC, AR, ZC, WAMP, RMS, STD, MAD, KURT	LSTM yapay sinir ağı	%90.00
(Arozi et al., 2020)	1 kişi, 6 tekrar, 7 parmak hareketi	RMS	ANFİS	%98.09
(Altan et al., 2019)	1 kişi ve 7 parmak hareketi	VAR	SVM, KNN, karar ağaçları	%94.00
(Castiblanco et al., 2016)	7 kişi, 4 tekrar, 5 parmak hareketi	IEMG, MAV, SSI, VAR, RMS, WL, AAC, DASDV, MYOP, WAMP ve SSC	SVM ve karar ağaçları	% 92.00
(Caesarendra et al., 2018)	1 kişi, 10 tekrar, 5 parmak hareketi	IEMG, MAV, MAV1, MAV2, SSI, VAR, RMS, WL, DASDV, H1, H2, H3	ANFİS	% 72.00
(Singhvi and Ren, 2018)	6 kişi, 6 tekrar, 6 parmak hareketi	MAV, STD, VAR, RMS, WL, ZC ve IEMG	KNN ve SVM	%80.00-86.00
(Stephenson et al., 2018)	4 kişi, 20 tekrar, 12 parmak hareketi	RMS	CNN mimarisi	%94.90
(Naseer et al., 2018)	10 kişi, 20 tekrar, 6 parmak hareketi	STD, RMS, WL ve WAMP	LDA, KNN, SVM ve DNN	%95.00
(Srinivasan et al., 2018)	10 kişi, 20 tekrar, 6 parmak hareketi	Mean, STD, VAR ve RMS	CNN mimarisi	%72.50
(Tepe and Erdim, 2020)	4 kişi, 10 tekrar, 6 parmak hareketi	RMS, MMAV, DASDV ve MFL	SKNN	%95.83
(S. Krishnan et al., 2019)	1 kişi, 4 tekrar, 8 parmak hareketi	RMS, enerji, medyan, ZC, SSC, VAR, MAV, SS, K ve AR	SVM, LDA ve MLP	%97.70
Bu çalışmada (EMG)	10 kişi, 30 tekrar, 6 parmak hareketi	EMAV, SSI, VAR, DASDV, RMS, EWL, MMAV2, MMAV1, MFL, MYOP, MAV,ZC	CSVM	%91.56
Bu çalışmada (EMG,Gyro)	10 kişi, 30 tekrar, 6 parmak hareketi	EMAV, SSI, VAR, DASDV, RMS, EWL, MMAV2, MMAV1, MFL, MYOP, MAV,ZC	CSVM	%92.56
Bu çalışmada (EMG)	10 kişi, 30 tekrar, 6 parmak hareketi	EMAV, SSI, VAR, DASDV, RMS, EWL, MMAV2, MMAV1, MFL, MYOP, MAV,ZC	YSA CGB eğitim algoritması	%94.40
Bu çalışmada (EMG,Gyro)	10 kişi, 30 tekrar, 6 parmak hareketi	EMAV, SSI, VAR, DASDV, RMS, EWL, MMAV2, MMAV1, MFL, MYOP, MAV,ZC	YSA SCG eğitim algoritması	%96.30
Bu çalışmada (EMG)	1 kişi, 30 tekrar, 6 parmak hareketi	EMAV, SSI, VAR, DASDV, RMS, EWL, MMAV2, MMAV1, MFL, MYOP, MAV,ZC	FKNN	%100
Bu çalışmada (EMG,Gyro)	1 kişi, 30 tekrar, 6 parmak hareketi	EMAV, SSI, VAR, DASDV, RMS, EWL, MMAV2, MMAV1, MFL, MYOP, MAV,ZC	YSA SCG eğitim algoritması	%100

Parmak hareketlerinin sınıflandırılması ile ilgili myo bileklik kullanılmadan yapılan çalışmalar Tablo 5.2’de verilmiştir. Yüzey EMG ve jiroskop verileri ile YSA kullanılarak yapılan bu çalışmada %96.30 başarımlar elde edilmiştir. Yapılan çalışma literatürdeki çalışmalardan (Anam and Al-Jumaily, 2015; Birdwell et al., 2014; Cipriani et al., 2011; Çerçi, 2017; Emayavaramban et al., 2020; Jiang et al., 2006; Kanitz et al., 2011; Khushaba et al., 2012; Tenore et al., 2008; Z. Zhang et al., 2020) daha yüksek sınıflandırma başarımlarını elde edilmiştir. Literatürdeki bir çalışmada (Celadon et al., 2016) 192 kanal kullanarak %97 başarımlar elde etmişlerdir. Ancak 8 kanal kullanılarak yapılan sınıflandırmada ise %92 başarımlar elde etmişlerdir. Tez çalışmasında 8 kanal kullanılmış ve elde edilen sınıflandırma başarımlarını diğer çalışmadan (Celadon et al., 2016) daha yüksektir.

Yüzey EMG verileri kullanılarak YSA’nda yapılan çalışmada %94.40 başarımlar elde edilmiştir. Literatürdeki çalışmalardan (Birdwell et al., 2014; Cipriani et al., 2011; Çerçi, 2017; Emayavaramban et al., 2020; Jiang et al., 2006; Kanitz et al., 2011; Khushaba et al., 2012; Tenore et al., 2008; Z. Zhang et al., 2020) daha yüksek sınıflandırma başarımlarını elde edilmiştir.

Yüzey EMG ve jiroskop verileri kullanılarak CSVM yöntemi ile sınıflandırılan çalışmada %92.56 başarımlar elde edilmiştir. Literatürdeki çalışmalardan (Birdwell et al., 2014; Cipriani et al., 2011; Çerçi, 2017; Jiang et al., 2006; Kanitz et al., 2011; Khushaba et al., 2012; Tenore et al., 2008; Z. Zhang et al., 2020) daha yüksek sınıflandırma başarımlarını elde edilmiştir.

Yüzey EMG verileri kullanılarak CSVM yöntemi ile sınıflandırılan çalışmada %91.56 başarımlar elde edilmiştir. Literatürdeki çalışmalardan (Birdwell et al., 2014; Cipriani et al., 2011; Jiang et al., 2006; Kanitz et al., 2011; Tenore et al., 2008; Z. Zhang et al., 2020) daha yüksek sınıflandırma başarımlarını elde edilmiştir.

Tablo 5.2. Literatürde myo bileklik kullanılmadan yapılan çalışmalar

Literatürdeki Çalışmalar	Veri Alımı	Deney Protokolü	Öznitelikler	Sınıflandırma Yöntemi	Başarım
(Emayavaramban et al., 2020)	5 kanal 400 Hz	12 parmak hareketi, 10 kişi, 10 tekrar	AR Burg, AR Yule-Walker, AR, LDR ve LPC	GRNN, PNN, RBFNN	%94.04
(Çerçi, 2017)	2 kanal 4000 Hz	4 kişi, 6 tekrar, 8 parmak hareketi	ZC, WL, SSI, MAV, WAMP, VAR, RMS, Hjorth	KNN, YSA	%92.00
(Celadon et al., 2016)	192 kanal elektrot	9 parmak hareketi, 9 kişi, 10 tekrar	RMS, MSE	Regresyon, LDA, CSP-PE ve THR	%97, %92 (8 kanal)
(Anam and Al-Jumaily, 2015)	2 kanal 2000 Hz	10 parmak hareketi, 8 kişi	AR, MAV, WL, SSC, ZC ve Hjorth	ELM ve SRELM	%95.67 ile %86.73
(Kanitz et al., 2011)	16 sensör 1,6 kHz	13 parmak hareketi, 6 kişi, 5 tekrar	ZC, WL, SSC ve MAV	LDA, KNN ve SVM	%80.00
(Jiang et al., 2006)	16 kanal 2000 Hz	6 parmak hareketi 10 kişi	VAR, Max ve MAV	YSA	%80.00
(Birdwell et al., 2014)	ince telli elektrot 1000 Hz	6 parmak hareketi, 7 kişi, 12 tekrar	MAV	Örüntü tanıma	%85.00
(Khushaba et al., 2012)	2 elektrot 4000 Hz	8 kişi, 10 parmak hareketi, 6 tekrar	SSC, ZC, WL, Hjort, SS ve AR	LDA, LIBSVM	%92.00
(Cipriani et al., 2011)	8 elektrot 10 kHz	7 parmak hareketi, 10 kişi, 3 tekrar	MAV	Denetimli öğrenme	%89.00, Ampute %79.00
(Tenore et al., 2008)	32 kanal 2000 Hz	12 parmak hareketi 1 ampute 5 sağlam 25-30 tekrar	MAV, VAR, WL ve WAMP	MLP	%90.00
(Z. Zhang et al., 2020)	8 kanal 1500 Hz	11 parmak hareketi, 5 kişi, 36 tekrar	RMS, ZC, WL, SSC ve MAV	YSA, SVM ve KNN	%91.10
Bu çalışmada (EMG)	8 kanal 200 Hz	10 kişi, 30 tekrar, 6 parmak hareketi	EMAV, SSI, VAR, DASDV, RMS, EWL, MMAV2, MMAV1, MFL, MYOP, MAV, ZC	CSVM	%91.56
Bu çalışmada (EMG, Gyro)	8 kanal 200 Hz	10 kişi, 30 tekrar, 6 parmak hareketi	EMAV, SSI, VAR, DASDV, RMS, EWL, MMAV2, MMAV1, MFL, MYOP, MAV, ZC	CSVM	%92.56
Bu çalışmada (EMG)	8 kanal 200 Hz	10 kişi, 30 tekrar, 6 parmak hareketi	EMAV, SSI, VAR, DASDV, RMS, EWL, MMAV2, MMAV1, MFL, MYOP, MAV, ZC	YSA CGB eğitim algoritması	%94.40
Bu çalışmada (EMG, Gyro)	8 kanal 200 Hz	10 kişi, 30 tekrar, 6 parmak hareketi	EMAV, SSI, VAR, DASDV, RMS, EWL, MMAV2, MMAV1, MFL, MYOP, MAV, ZC	YSA SCG eğitim algoritması	%96.30

Yüzey EMG verileri kullanılarak gerçek zamanlı sınıflandırma yapılan çalışmalar Tablo 5.3’de verilmiştir. Bir kişi ile yapılan gerçek zamanlı sınıflandırmada %98.33 başarımlar elde edilmiştir. Literatürdeki çalışmalardan (Celadon et al., 2016; Khushaba et al., 2012; Naseer et al., 2018) daha yüksek başarımlar elde edilmiştir. Yüzey EMG verileri kullanılarak 8 kişi ile yapılan sınıflandırmada %90.36 başarımlar elde edilmiş ve bu başarımlar literatürdeki çalışmalardan (Khushaba et al., 2012) yüksek başarımlar göstermiştir.

Tablo 5.3. Literatürde gerçek zamanlı sınıflandırma yapılan çalışmalar

Literatürdeki Çalışmalar	Veri Alımı	Deney Protokolü	Öznitelikler	Sınıflandırma Yöntemi	Başarımlar
(Naseer et al., 2018)	8 kanal 200 Hz	1 kişi, 6 parmak hareketi, 20 tekrar	STD, RMS, WL ve WAMP	DNN	%92.00
(Celadon et al., 2016)	192 kanal elektrot	9 parmak hareketi 9 kişi 10 tekrar	RMS	LDA	%91.00
(Khushaba et al., 2012)	2 sensör 4000 Hz	1 kişi, 10 parmak hareketi, 3 tekrar	SSC, ZC, WL, Hjort, SS ve AR	LIBSVM	%90.00
Bu çalışmada	8 kanal 200 Hz	1 kişi, 30 tekrar, 6 parmak hareketi	RMS	WKNN	%98.33
Bu çalışmada	8 kanal 200 Hz	8 kişi, 30 tekrar, 6 parmak hareketi	RMS	WKNN	%90.36

6. SONUÇLAR

Protez kol kontrollerinde yüzey EMG işaretleri sıkça kullanılmaktadır. Yüzey EMG işaretleri doğru ve düzgün bir şekilde alındığında yüksek sınıflandırma başarımı elde edilmektedir. Böylece protez elin hareket kabiliyeti genişlemekte ve protez el daha işlevsel kullanılabilir. Bu amaçla tez çalışmasında parmak hareketleri çevrimdışı ve gerçek zamanlı olarak sınıflandırılmıştır.

Bu çalışmada myo kol bandı kullanılarak 10 katılımcıdan yüzey EMG ve jiroskop işaretleri alınarak veri seti oluşturulmuştur. Her katılımcı 5 parmak ve 1 dinlenme hareketini 30 kez tekrarlamıştır. Veri seti işlenmiştir. EMAN, EWL, MAN, WL, ZC, SSC, RMS, AAC, DASDV, MMAV1, MMAV2, MYOP, SSI, WAMP, MFL, LOG ve VAR öznitelikleri kullanılmıştır. Matlab® programında CLA ile FT, MT, CT, LD, QD, LSVM, QSVM, CSVM, FQSVM, MGSVM, CGSVM, FKNN, MKNN, Coar.KNN, Cos.KNN, Cu.KNN, WKNN, Bo.T, Ba.T, SD, SKNN ve RUST sınıflandırıcıları kullanılmıştır. Yüzey EMG veri seti kullanılarak ardışıl ileri yönlü öznitelik seçimi yapılmış ve en yüksek başarımı veren öznitelikler EMAN, SSI, VAR, DASDV, RMS, EWL, MMAV2, MMAV1, MFL, MYOP, MAN ve ZC olarak belirlenmiştir. Başarım %91.56'dır ve CSVM yöntemi ile sınıflandırılmıştır. Seçilen öznitelikler kullanılarak bireysel veri setleri ile sınıflandırma yapılmış ve katılımcıların gösterdiği en yüksek başarım %100 ve en düşük başarım %92.22 olarak elde edilmiştir. Yüzey EMG veri setine jiroskop verileri eklenmiş ve sınıflandırma yapılmıştır. Jiroskop verilerinin eklenmesi başarımı önemli ölçüde arttırmıştır. Başarım %92.56 olarak elde edilmiş ve CSVM yöntemi ile sınıflandırılmıştır. Farklı pencere boyutları ile sınıflandırma yapılmış ve en yüksek başarımı veren pencere boyutu 100 ms olduğu belirlenmiştir.

Matlab® programında nprtool ile YSA'da SCG, LM, BR, BFG, NRP, CGB, CGF, CGP, OSS, GDX, GDM ve GD eğitim algoritmaları kullanılarak sınıflandırma yapılmıştır. Yüzey EMG veri seti kullanılarak yapılan sınıflandırmada en yüksek başarımı %94.40 ile CGB eğitim algoritması 98 gizli katman nöron sayısında vermiştir. Yüzey EMG ve jiroskop verileri kullanılarak yapılan sınıflandırmada en yüksek başarımı %96.30 ile SCG eğitim algoritması 97 gizli katman nöron sayısında vermiştir. Veri setine jiroskop verilerinin eklenmesi ile yapılan sınıflandırmalarda başarımın arttığı gözlenmektedir. Yüzey EMG ve jiroskop işaretleri ile bireysel veri setinde sınıflandırma yapılmıştır. Katılımcıların gösterdiği en yüksek başarım %100

ve en düşük başarımlar %88.90 olarak elde edilmiştir. Farklı pencere boyutları ile sınıflandırma yapılmış ve en yüksek başarımları veren pencere boyutu 100 ms olduğu belirlenmiştir.

Gerçek zamanlı sınıflandırma CLA'da kullanılan sınıflandırıcılardan model oluşturularak yüzey EMG verileri ile yapılmıştır. Yüzey EMG verilerinde en yüksek başarımları veren öznitelikler EMAV, SSI, VAR, DASDV, RMS, EWL, MMAV2, MMAV1, MFL, MYOP, MAV, ZC ve en yüksek başarımları veren sınıflandırıcı CSVM ile çevrimdışı model oluşturulmuştur. Matlab® programındaki yazılan koda gerçek zamanlı yüzey EMG verileri gönderilerek sınıflandırma yapılmış ve başarımlar 41.67 olarak elde edilmiştir. Düşük başarımlar elde edilince her öznitelik için çevrimdışı olarak CSVM yönteminde model oluşturulmuş ve gerçek zamanlı sınıflandırma yapılmıştır. RMS özniteliği kullanılarak oluşturulan model en yüksek başarımları göstermiş ve başarımlar %75 olarak elde edilmiştir. RMS özniteliği kullanılarak yüksek başarımları veren sınıflandırıcılarda SKNN, QSVM, MGSVM, FKNN ve WKNN gerçek zamanlı sınıflandırma yapılmıştır. En yüksek başarımları WKNN yöntemi vermiş ve gerçek zamanlı sınıflandırma başarımları %90 olarak elde edilmiştir. Tüm veri seti ve bireysel veri seti için WKNN sınıflandırıcısı ve RMS özniteliğiyle 2 model oluşturulmuş ve modeller 10 kez tekrarlanmıştır. İlk katılımcının bireysel veri setinde en yüksek başarımlar %97.78 ve en düşük başarımlar %90.56 olarak elde edilmiştir. Tüm veri setinde en yüksek başarımlar %93.89 ve en düşük başarımlar %86.67 olarak elde edilmiştir. 10 tekrarın ortalama başarımları bireysel veri setinde %95.11 ve tüm veri setinde %90.67'dir. Diğer katılımcının bireysel veri setinde en yüksek başarımlar %98.33 ve en düşük başarımlar %95.56 olarak elde edilmiştir. Tüm veri setinde en yüksek başarımlar %97.78 ve en düşük başarımlar %91.11 olarak elde edilmiştir. 10 tekrarın ortalama başarımları bireysel veri setinde %97.45 ve tüm veri setinde %94.89'dur. RMS özniteliği ve WKNN yöntemi kullanılarak bireysel veri seti ve tüm veri setiyle çevrimdışı model oluşturulmuş ve 8 katılımcı ile gerçek zamanlı sınıflandırma yapılmıştır. Bireysel veri setinde ile yapılan sınıflandırmada en yüksek başarımlar %98.33 ve en düşük başarımlar %85.56 olarak elde edilmiştir. Tüm veri setinde ile yapılan sınıflandırmada en yüksek başarımlar %97.78 ve en düşük başarımlar %86.11 olarak elde edilmiştir. Bireysel veri setinde katılımcıların ortalama başarımları %92.17 ve tüm veri setinde katılımcıların ortalaması %90.36 olarak elde edilmiştir. Bireysel veriler kullanılarak oluşturulan model tüm veriler kullanılarak oluşturulan modele göre daha yüksek başarımlar vermiştir. Yüzey EMG işareti kişiye özeldir ve yüzey EMG işaretinin genliği

katılımcıdan katılımcıya farklılık göstermektedir.

Biyomedikal işaretlerin analizi ve sınıflandırılmasında farklı yöntemler kullanılmıştır. Bu yöntemlerden biri de jiroskop işaretinin veri setine eklenerek sınıflandırma işlemlerinin uygulanmasıdır. Jiroskop verileri sınıflandırma başarımını önemli ölçüde yükseltmiştir. Veri setinin oluşturulması, ardışıl ileri yönlü öznelik seçimi yöntemi ile en yüksek başarımlı veren özneliklerin seçilmesi, farklı makine öğrenme yöntemleri kullanılarak yüksek başarımlı veren sınıflandırıcının belirlenmesi, çevrimdışı sınıflandırmada yüksek başarımlı 4 model önerilmesi, gerçek zamanlı sınıflandırma yüksek başarımlı modeller oluşturulması ve jiroskop verilerinin eklenerek başarımların artırılması bu tez çalışmasının literatüre katkısı ve özgün yönlerini oluşturmaktadır.

Gelecek çalışmalarda oluşturulan modeller, mikro denetleyici kullanılarak protez el kontrolü yapılabilir. Ayrıca hareket tespiti uygulamalarında ve sanal el kontrollerinde kullanılabilir. Veri setine farklı parmak hareketleri eklenerek sınıflandırma işlemleri tekrarlanabilir. Tüm vücudunda hareket kabiliyeti az olan bireyler için elektroensefalogram (EEG) ve elektrookülografi (EOG) işaretleri de alınarak incelenebilir ve model önerilebilir.

KAYNAKLAR

- Abreu, J. G., Teixeira, J. M., Figueiredo, L. S., & Teichrieb, V. (2016). *Evaluating sign language recognition using the myo armband*. Paper presented at the 2016 XVIII Symposium on Virtual and Augmented Reality (SVR).
- Akhmadeev, K., Rampone, E., Yu, T., Aoustin, Y., & Le Carpentier, E. (2017). A testing system for a real-time gesture classification using surface EMG. *IFAC-PapersOnLine*, 50(1), 11498-11503.
- Al-Faiz, M. Z., Ali, A. A., & Miry, A. H. (2010). *A k-nearest neighbor based algorithm for human arm movements recognition using EMG signals*. Paper presented at the 2010 1st International Conference on Energy, Power and Control (EPC-IQ).
- Al-Timemy, A. H., Bugmann, G., Escudero, J., & Outram, N. (2013). Classification of finger movements for the dexterous hand prosthesis control with surface electromyography. *IEEE journal of Biomedical Health Informatics*, 17(3), 608-618.
- Alkan, A., & Günay, M. (2012). Identification of EMG signals using discriminant analysis and SVM classifier. *Expert Systems with Applications*, 39(1), 44-47.
- Altan, E., Pehlivan, K., & Kaplanoğlu, E. (2019). *Comparison of EMG Based Finger Motion Classification Algorithms*. Paper presented at the 2019 27th Signal Processing and Communications Applications Conference (SIU).
- Anam, K., & Al-Jumaily, A. (2015). *A novel extreme learning machine for dimensionality reduction on finger movement classification using sEMG*. Paper presented at the 2015 7th International IEEE/EMBS Conference on Neural Engineering (NER).
- Arozi, M., Ariyanto, M., Kristianto, A., & Setiawan, J. D. (2020). *EMG Signal Processing of Myo Armband Sensor for Prosthetic Hand Input using RMS and ANFIS*. Paper presented at the 2020 7th International Conference on Information Technology, Computer, and Electrical Engineering (ICITACEE).
- Ayaz, F. (2018). *EMG Sinyallerinin Sınıflandırılması*. (Yüksek Lisans Tezi), İnönü Üniversitesi, Malatya.
- Bağcı, D. (2016). *Biyonik El Kontrolü İçin EMG İşaretlerinin Makine Öğrenmesi Yöntemiyle Sınıflandırılması*. (Yüksek Lisans Tezi), Yalova Üniversitesi, Yalova.
- Birdwell, J. A., Hargrove, L. J., & Kuiken, T. A. (2014). Extrinsic finger and thumb muscles command a virtual hand to allow individual finger and grasp control. *IEEE Transactions On Biomedical Engineering*, 62(1), 218-226.
- Caesarendra, W., Tjahjowidodo, T., Nico, Y., Wahyudati, S., & Nurhasanah, L. (2018). *EMG finger movement classification based on ANFIS*. Paper presented at the Journal of Physics: conference series.
- Carvajal, D. N., & Rowe, P. C. (2010). Sensitivity, specificity, predictive values, and likelihood ratios. *Pediatr Rev*, 31(12), 511-513.
- Castiblanco, C., Parra, C., & Colorado, J. (2016). *Individual hand motion classification through EMG pattern recognition: Supervise and unsupervised methods*. Paper presented at the 2016 XXI Symposium on Signal Processing, Images and Artificial Vision (STSIVA).
- Castro, M. C. F., Arjunan, S. P., & Kumar, D. K. (2015). Selection of suitable hand gestures for reliable myoelectric human computer interface. *Biomedical engineering online*, 14(1), 30.
- Celadon, N., Došen, S., Binder, I., Ariano, P., & Farina, D. (2016). Proportional estimation of finger movements from high-density surface electromyography. *Journal of neuroengineering and rehabilitation*, 13(1), 73.
- Cipriani, C., Antfolk, C., Controzzi, M., Lundborg, G., Rosén, B., Carrozza, M. C., & Sebelius, F. (2011). Online myoelectric control of a dexterous hand prosthesis by transradial amputees. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 19(3), 260-270.

- Côté-Allard, U., Fall, C. L., Drouin, A., Campeau-Lecours, A., Gosselin, C., Glette, K., . . . Gosselin, B. (2019). Deep learning for electromyographic hand gesture signal classification using transfer learning. *27(4)*, 760-771.
- Çerçi, Ç. (2017). *EMG İşaretlerinin Özniteliklerinin Çıkarılması, KNN Ve YSA Yöntemleri İle Sınıflandırılması*. (Yüksek Lisans Tezi), İstanbul Teknik Üniversitesi, İstanbul.
- Emayavaramban, G., Divyapriya, S., Mansoor, V., Amudha, A., Ramkumar, M. S., Nagaveni, P., & SivaramKrishnan, M. (2020). SEMG based classification of hand gestures using artificial neural network. *Materials Today: Proceedings*.
- Englehart, K., & Hudgins, B. (2003). A robust, real-time control scheme for multifunction myoelectric control. *IEEE Transactions On Biomedical Engineering*, *50(7)*, 848-854.
- Farina, D., Merletti, R., & Stegeman, D. (2004). Biophysics of the generation of EMG signals. *Electromyography: physiology, engineering, and noninvasive applications*, 81-105.
- Fonseca, M., Conceição, A. G. S., & Simas Filho, E. F. (2017). *Artificial neural networks applied to the classification of hand gestures using eletromyographic signals*. Paper presented at the 2017 Latin American Robotics Symposium (LARS) and 2017 Brazilian Symposium on Robotics (SBR).
- Ganiev, A., Shin, H.-S., & Lee, K.-H. (2016). Study on virtual control of a robotic arm via a myo armband for the selfmanipulation of a hand amputee. *Int. J. Appl. Eng. Res*, *11(2)*, 775-782.
- Gokgoz, E., & Subasi, A. (2015). Comparison of decision tree algorithms for EMG signal classification using DWT. *Biomedical Signal Processing and Control*, *18*, 138-144.
- Gökçe, F. (2019). *Koldan Alınan EMG Sinyalleri İle Uzaktan Kontrollü Sistemlerin Kullanılmasına Yönelik Uygulama Geliştirilmesi*. (Yüksek Lisans Tezi), Karabük Üniversitesi, Karabük.
- Jiang, M., Wang, R., Wang, J., & Jin, D. (2006). *A method of recognizing finger motion using wavelet transform of surface EMG signal*. Paper presented at the 2005 IEEE Engineering in Medicine and Biology 27th Annual Conference.
- Kanitz, G. R., Antfolk, C., Cipriani, C., Sebelius, F., & Carrozza, M. C. (2011). *Decoding of individuated finger movements using surface EMG and input optimization applying a genetic algorithm*. Paper presented at the 2011 Annual International Conference of the IEEE Engineering in Medicine and Biology Society.
- Kaynar, O., Taştan, S., & Demirkoparan, F. (2011). Yapay sinir ağları ile doğalgaz tüketim tahmini. *Atatürk Üniversitesi İktisadi ve İdari Bilimler Dergisi*, *25*.
- Khushaba, R. N., Kodagoda, S., Takruri, M., & Dissanayake, G. (2012). Toward improved control of prosthetic fingers using surface electromyogram (EMG) signals. *Expert Systems with Applications*, *39(12)*, 10731-10738.
- Krishnan, K. S., Saha, A., Ramachandran, S., & Kumar, S. (2017). *Recognition of human arm gestures using Myo armband for the game of hand cricket*. Paper presented at the 2017 IEEE International Symposium on Robotics and Intelligent Sensors (IRIS).
- Krishnan, S., Akash, R., Kumar, D., Jain, R., Rathai, K. M. M., & Patil, S. (2019). Finger movement pattern recognition from surface EMG signals using machine learning algorithms *ICTMI 2017* (pp. 75-89): Springer.
- Kristof, R., Moldovan, C., Ciupe, V., Maniu, I., & Banda, M. (2019). *Applications based on electromyography sensors*. Paper presented at the ITM Web of Conferences.
- Lalkhen, A. G., & McCluskey, A. (2008). Clinical tests: sensitivity and specificity. *Continuing Education in Anaesthesia Critical Care & Pain*, *8(6)*, 221-223.
- MathWorks, I. (1994, 2020). Retrieved 17 Mayıs, 2020, from <https://www.mathworks.com/>
- McGinnis, P. M. (2013). *Biomechanics of sport and exercise: Human Kinetics*.
- Merlo, A., & Campanini, I. (2010). Technical aspects of surface electromyography for clinicians. *The open rehabilitation journal*, *3(1)*.
- Millar, C., Siddique, N., & Kerr, E. (2020). *LSTM Classification of sEMG Signals For Individual Finger Movements Using Low Cost Wearable Sensor*. Paper presented at the 2020 International Symposium on Community-centric Systems (CcS).
- Moore, K. L., Agur, A. M., Dalley, A. F., & Moore, K. L. (2015). *Essential clinical anatomy: Wolters Kluwer Health*.

- Naseer, N., Ali, F., Ahmed, S., Iftikhar, S., Khan, R. A., & Nazeer, H. (2018). *EMG based control of individual fingers of robotic hand*. Paper presented at the 2018 International Conference on Sustainable Information Engineering and Technology (SIET).
- Obuş, S. (2019). *EMG Sensör Kontrollü Beş Eksenli Robotik Kol Ve Robotik El tasarımı ve Gerçeklenmesi*. (Yüksek Lisans Tezi), Fırat Üniversitesi, Elazığ.
- Oweis, R. J., Rihani, R., & Alkhawaja, A. (2014). ANN-based EMG classification for myoelectric control. *International Journal of Medical Engineering and Informatics*, 6(4), 365-380.
- Peleg, D., Braiman, E., Yom-Tov, E., & Inbar, G. F. (2002). Classification of finger activation for use in a robotic prosthesis arm. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 10(4), 290-293.
- Phinyomark, A., Phukpattaranont, P., & Limsakul, C. (2012). Feature reduction and selection for EMG signal classification. *Expert Systems with Applications*, 39(8), 7420-7431.
- Pizzolato, S., Tagliapietra, L., Cognolato, M., Reggiani, M., Müller, H., & Atzori, M. (2017). Comparison of six electromyography acquisition setups on hand movement classification tasks. *PloS one*, 12(10).
- Said, S., Sheikh, M., Al-Rashidi, F., Lakys, Y., Beyrouthy, T., & Nait-ali, A. (2019). *A Customizable Wearable Robust 3D Printed Bionic Arm: Muscle Controlled*. Paper presented at the 2019 3rd International Conference on Bio-engineering for Smart Technologies (BioSMART).
- Singhvi, S., & Ren, H. (2018). *Comparative study of motion recognition with temporal modelling of electromyography for thumb and index finger movements aiming for wearable robotic finger exercises*. Paper presented at the 2018 3rd International Conference on Advanced Robotics and Mechatronics (ICARM).
- Srinivasan, V. B., Islam, M., Zhang, W., & Ren, H. (2018). *Finger Movement Classification from Myoelectric Signals Using Convolutional Neural Networks*. Paper presented at the 2018 IEEE International Conference on Robotics and Biomimetics (ROBIO).
- Stańczyk, U. (2015). Weighting of features by sequential selection *Feature Selection for Data and Pattern Recognition* (pp. 71-90): Springer.
- Stephenson, R. M., Chai, R., & Eager, D. (2018). *Isometric Finger Pose Recognition with Sparse Channel SpatioTemporal EMG Imaging*. Paper presented at the 2018 40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC).
- Taşar, B. (2016). *EMG Sinyalleri İle Çok Fonksiyonlu Protez El Simülasyonunun Kontrolü*. (Doktora Tezi), Fırat Üniversitesi, Elazığ.
- Taşdemir, Ç. (2018). *Ön Kol Kas Kuvvetlerinin EMG Sinyalleri İle Belirlenmesi Ve Yapay Sinir Ağlarıyla Tahmini*. (Yüksek Lisans Tezi), Kocaeli Üniversitesi, Kocaeli.
- Tenore, F. V., Ramos, A., Fahmy, A., Acharya, S., Etienne-Cummings, R., & Thakor, N. V. (2008). Decoding of individuated finger movements using surface electromyography. *IEEE Transactions On Biomedical Engineering*, 56(5), 1427-1434.
- Tepe, C. (2014). *EMG İşareti İle Protez Elin Değişken Hızla Denetimi: Donanım, Yazılım ve Algoritmik Yöntemler*. (Doktora Tezi), Ondokuz Mayıs Üniversitesi, Samsun.
- Tepe, C., & Erdim, M. (2020). *Classification of EMG Finger Data Acquired with Myo Armband*. Paper presented at the 2020 International Congress on Human-Computer Interaction, Optimization and Robotic Applications (HORA).
- Tepe, C., Erdim, M., & Eminoğlu, İ. (2020). Myo Bileklik İle Gerçek Zamanlı Protez Kol Kontrolü. *Avrupa Bilim ve Teknoloji Dergisi*, 184-193.
- Tkáč, M., & Verner, R. (2016). Artificial neural networks in business: Two decades of research. *Applied Soft Computing*, 38, 788-804.
- Too, J., Abdullah, A. R., Mohd Saad, N., & Tee, W. (2019). Emg feature selection and classification using a pbest-guide binary particle swarm optimization. *Computation*, 7(1), 12.
- Too, J., Abdullah, A. R., & Saad, N. M. (2019). Classification of Hand Movements based on Discrete Wavelet Transform and Enhanced Feature Extraction. *Int. J. Adv. Comput. Sci. Appl.*, 10(6).

- Ülker, O., Akgün, G., & Kaplanoğlu, E. (2017). *Real time robotic arm control using wearable gesture armband*. Paper presented at the Proc. 2nd International Mediterranean Science and Engineering Congress (IMSEC 2017).
- Verma, C., Parikh, R., Nadkar, M., & Mehta, A. (2017). Correlation of functional ability of the hand with upper limb function and quality of life in patients with rheumatoid arthritis. *J Assoc Physicians India*, 65, 20-24.
- Visconti, P., Gaetani, F., Zappatore, G., & Primiceri, P. (2018). Technical features and functionalities of Myo armband: An overview on related literature and advanced applications of myoelectric armbands mainly focused on arm prostheses. *International Journal on Smart Sensing and Intelligent Systems*, 11(1), 1-25.
- Wahid, M. F., Tafreshi, R., Al-Sowaidi, M., & Langari, R. (2018). Subject-independent hand gesture recognition using normalization and machine learning algorithms. *Journal Of Computational Science*, 27, 69-76.
- Widodo, A., & Yang, B.-S. (2007). Support vector machine in machine condition monitoring and fault diagnosis. *Mechanical systems and signal processing*, 21(6), 2560-2574.
- Xu, Y., Yang, C., Liu, X., & Li, Z. (2018). *A Teleoperated Shared Control Scheme for Mobile Robot Based sEMG*. Paper presented at the 2018 3rd International Conference on Advanced Robotics and Mechatronics (ICARM).
- Yang, J., Pan, J., & Li, J. (2017). *sEMG-based continuous hand gesture recognition using GMM-HMM and threshold model*. Paper presented at the 2017 IEEE International Conference on Robotics and Biomimetics (ROBIO).
- Zhang, X., Chen, X., Li, Y., Lantz, V., Wang, K., & Yang, J. (2011). A framework for hand gesture recognition based on accelerometer and EMG sensors. *IEEE Transactions on Systems, Man, and Cybernetics-Part A: Systems and Humans*, 41(6), 1064-1076.
- Zhang, Z., Su, Z., & Yang, G. (2019). *Real-Time Chinese Sign Language Recognition Based on Artificial Neural Networks*. Paper presented at the 2019 IEEE International Conference on Robotics and Biomimetics (ROBIO).
- Zhang, Z., Yu, X., & Qian, J. (2020). Classification of Finger Movements for Prosthesis Control with Surface Electromyography. *Sensors and Materials*, 32(4), 1523-1532.

ÖZ GEÇMİŞ

Sinop Boyabat Anadolu Öğretmen Lisesi'ni 2012 yılında bitirdikten sonra Gazi Üniversitesi Mühendislik Fakültesi Elektrik Elektronik Mühendisliği'nden 2017 yılında mezun oldu. 2018 yılında OMÜ LEE Yüksek Lisans programını girdi.

ORCID ID : 0000 0001 7467 3249

Yayınlanmış Çalışmalar:

1. Tepe, C., & Erdim, M. (2020). Classification of EMG Finger Data Acquired with Myo Armband. Paper presented at the 2020 International Congress on Human-Computer Interaction, Optimization and Robotic Applications (HORA).

