

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



**EL HAREKETLERİNE AİT YÜZEY EMG SİNYALLERİNİN
İŞLENMESİ VE SINIFLANDIRILMASI**

Yüksek Lisans Tezi

Mehmet Can DEMİR

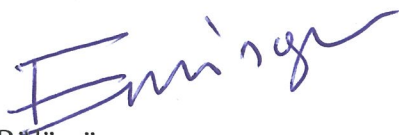


Danışman

Dr. Öğr. Üyesi Cengiz TEPE

SAMSUN
2021

TEZ KABUL VE ONAYI

Mehmet Can DEMİR tarafından, Dr. Öğr. Üyesi Cengiz TEPE danışmanlığında hazırlanan **El Hareketlerine Ait Yüzey EMG Sinyallerinin İşlenmesi ve Sınıflandırılması** başlıklı bu çalışma, jürimiz tarafından 2.2.2021 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 Ondokuz Mayıs Üniversitesi Mühendislik Fakültesi Elektrik-Elektronik Mühendisliği Bölümü		<input checked="" type="checkbox"/> Kabul <input type="checkbox"/> Ret
Üye (Danışman)	Dr. Öğr. Üyesi Cengiz TEPE Ondokuz Mayıs Üniversitesi Mühendislik Fakültesi Elektrik-Elektronik Mühendisliği Bölümü		<input checked="" type="checkbox"/> Kabul <input type="checkbox"/> Ret
Üye	Dr. Öğr. Üyesi Ahmet TURAN Samsun Üniversitesi Mühendislik Fakültesi Biyomedikal Mühendisliği Bölümü		<input checked="" type="checkbox"/> 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 davranılmadığımı taahhüt ve beyan ederim.

02 /02 /2021
Mehmet Can DEMİR

TEZ ÇALIŞMASI ÖZGÜNLÜK RAPORU BEYANI

Tez Başlığı : El Hareketlerine Ait Yüzey EMG Sinyallerinin İşlenmesi ve Sınıflandırılması

Yukarıda başlığı belirtilen tez çalışması için şahsım tarafından 25 /12 /2020 tarihinde intihal tespit programından alınmış olan özgünlük raporu sonucunda;

Benzerlik oranı : % 4

Tek kaynak oranı : % 2 çıkmıştır.

26 /02 / 2021
Dr. Öğr. Üyesi Cengiz TEPE

ÖZET

EL HAREKETLERİNE AİT YÜZEY EMG SİNYALLERİNİN İŞLENMESİ VE SINIFLANDIRILMASI

Mehmet Can DEMİR

Ondokuz Mayıs Üniversitesi

Lisansüstü Eğitim Enstitüsü

Elektrik-Elektronik Mühendisliği Ana Bilim Dalı

Yüksek Lisans, Şubat/2021

Danışman: Dr. Öğr. Üyesi Cengiz TEPE

Ampute bireyler için protez kol tasarımında yüzey EMG işaretlerinin işlenmesi ve sınıflandırılması sıkça yapılan bir uygulamadır. Bu tez çalışmasında ampute bireylerdeki kas kayıpları dikkate alınarak daha az kasa ait veriler ile güvenilir sınıflandırma sonuçları elde edilmeye çalışılmıştır. Sınıflandırma performansının artırılması için literatürde kullanımına rastlanılmayan jiroskop öznitelikleri de kullanılmıştır. Veri setinde 7 el hareketi için 10 sağlıklı kişiden Myo kol bandı ile alınmış yüzey EMG ve jiroskop verileri bulunmaktadır. Bu 7 el hareketi: yumruk, parmak açma, bilek içeri bükme, bilek dışarı bükme, pronasyon, supinasyon ve dinlenmedir. Denekler her bir hareketi 30' ar kez tekrarlamışlardır. Yüzey EMG ve jiroskop işaretlerinin öznitelikleri çıkarılmadan önce önışlemeden geçirilmiştir. Önışleme süreci yüzey EMG verileri için iki aşamadan oluşmaktadır. Birinci aşamada yüzey EMG işareti 10 Hz yüksek geçiren filtreden geçirilmiştir. İkinci aşamada ise işaret içinde hareketin gerçekleştiği aralık bulunarak harekete ait olmayan kısımlar çıkarılmıştır. Jiroskop verilerinin önışlemesinde filtre uygulanmamış, yalnızca hareketin gerçekleştiği aralık bulunmuştur. Önışlemeleri yapılan yüzey EMG ve jiroskop verilerinin öznitelikleri çıkarılmıştır. Öznitelik matrisinde 14 adet zaman düzlemi, 6 adet frekans düzlemi olmak üzere 20 adet öznitelik kullanılmıştır. Bunların arasından en yüksek doğruluğu verenlerin belirlenmesi için ardışıl ileri yönlü öznitelik seçimi yapılmıştır. Sınıflandırma algoritması olarak Destek Vektör Makinesi ve k-En Yakın Komşuluk kullanılmıştır. Sınıflandırmada Matlab® içerisinde bulunan ClassificationLearner uygulamasından yararlanılmıştır. Tüm yüzey EMG kanalları kullanılarak elde edilen en yüksek doğruluk % 98,38'dir. Öznitelik seçimi sonucunda elde edilen öznitelik seti ve sınıflandırıcı kullanılarak kanal sayısı azaltılmış ve doğrulukları kontrol edilmiştir. Kanal sayısı 3' e kadar düşüldüğünde doğruluğun % 90' ın üzerinde olduğu görülmüştür. Özellikle az sayıda yüzey EMG kanalı kullanıldığında jiroskop özniteliklerinin performansı artırdığı görülmüştür. Elde edilen bu sonuçların ardından tüm veri seti eğitim kümesinde kullanılarak sınıflandırma modeli oluşturulmuş ve test verileri sisteme gerçek zamanlı gönderilmiştir. Veri setindeki sekiz kişi için yapılan gerçek zamanlı uygulama sonucunda % 95,83 ortalama doğruluk elde edilmiştir.

Anahtar Sözcükler: El hareketleri, Myo kol bandı, öznitelik çıkarma, öznitelik seçimi, sınıflandırma, jiroskop, EMG işaretleri

ABSTRACT

PROCESSING AND CLASSIFICATION OF SURFACE EMG SIGNALS OF HAND GESTURES

Mehmet Can DEMİR
Ondokuz Mayıs University
Institute of Graduate Studies
Department of Electrical and Electronics Engineering
Master, February/2021
Supervisor: Asst. Prof. Dr. Cengiz TEPE

Processing and classification of surface EMG signals is a common practice in prosthetic arm design for amputated individuals. In this thesis study, it has been tried to obtain reliable classification results with less muscle data considering the muscle losses in amputated individuals. Gyroscope features, which are not used in the literature, are also used to increase the classification performance. The data set includes surface EMG and gyroscope data taken from 10 healthy subjects with Myo armband for 7 hand gestures. These 7 hand gestures are: fist, fingers spread, wave-in, wave-out, pronation, supination and rest. Subjects repeated each gesture 30 times. surface EMG and gyroscope signals were preprocessed before their features were extracted. The preprocessing consists of two stages for surface EMG data. In the first stage, the surface EMG signal was passed through a 10 Hz high-pass filter. In the second stage, the region in the signal where the gesture takes place was found and the parts that do not belong to the gesture were removed. In the preprocessing of the gyroscope data, no filter was applied, only the region at which the gesture occurred was found. The features of the preprocessed surface EMG and gyroscope data were extracted. In the feature matrix, 20 features including 14 time domain and 6 frequency domain were used. Sequential forward selection was made to determine the highest accuracy among these. Support Vector Machine and k-Nearest Neighbors was used as the classification algorithm. ClassificationLearner application in Matlab® was used for classification. The highest accuracy achieved by using all surface EMG channels is 98.38%. Using the feature set and classifier obtained as a result of the feature selection, the number of channels was reduced and their accuracy was checked. When the number of channels is reduced up to 3, it has been observed that the accuracy is over 90%. Especially when using a small number of surface EMG channels, it has been observed that gyroscope features increase the performance. After these results, the classification model was created by using the entire data set and the test data was sent to the system in real time. As a result of the real-time application performed for eight subjects in the data set, an average accuracy of 95.83% was obtained.

Keywords: Hand gestures, Myo armband, feature extraction, feature selection, classification, gyroscope, EMG signals

ÖNSÖZ VE TEŞEKKÜR

Bu tez çalışmasının ortaya çıkmasında değerli görüş ve önerileriyle beni destekleyen ve değerli vaktini ayıran danışmanım Sayın Dr. Öğretim Üyesi Cengiz TEPE' ye, veri setinin oluşturulmasında katkısı olan arkadaşlarım Güler AKBULAT ve Muhammed ERDİM' e, yine veri setinin oluşturulmasında katkısı olan aile üyelerim Alparslan MADEN, Damla KURAL, Hülya DEMİR, İrem HOŞNUT, Kumru MADEN, Merve DEMİR ve Vildan DEMİR' e sonsuz teşekkürlerimi sunarım.

Mehmet Can DEMİR

İÇİNDEKİLER

1. GİRİŞ.....	1
1.1. Tezin Amacı ve Kapsamı	3
2. KAYNAK ÖZETLERİ.....	4
3. MATERYAL VE YÖNTEM.....	12
3.1. Myo Kol Bandı	12
3.2. Veri Alma Protokolü ve Veri Setinin Oluşturulması	13
3.3. Önışleme	15
3.3.1. Yüzey EMG İşaretine Filtre Uygulanması.....	15
3.3.2. El Hareketinin Başlangıç ve Bitiş Anlarının Bulunması.....	17
3.3.3. Jiroskop Verilerinin Önışlemesi	20
3.4. Pencereleme.....	21
3.5. Özniteliklerin Çıkarılması	23
3.5.1. Zaman Düzlemi Öznitelikleri	23
3.5.1.1. Karesel Ortalama Kök.....	24
3.5.1.2. Ortalama Mutlak Değer	24
3.5.1.3. Sıfır Geçişı.....	25
3.5.1.4. Dalga Formu Uzunluğu	26
3.5.1.5. Eğim İşareti Değişikliği.....	26
3.5.1.6. EMG Varyansı	27
3.5.1.7. Willison Genliğı.....	28
3.5.1.8. Ortalama Genlik Değişimi.....	29
3.5.1.9. Basit Kare İntegrali	30
3.5.1.10. Mutlak Standart Sapma Değerlerinin Farkı	30
3.5.1.11. EMG İntegrali	31
3.5.1.12. Modifiye Edilmiş Ortalama Mutlak Değer Tip 1.....	32
3.5.1.13. Modifiye Edilmiş Ortalama Mutlak Değer Tip 2.....	32
3.5.1.14. Miyo Atım Yüzdellik Oranı.....	33
3.5.2. Frekans Düzlemi Öznitelikleri	34
3.5.2.1. Tepe Frekansı	34
3.5.2.2. Ortalama Güç.....	34
3.5.2.3. Toplam Güç	35
3.5.2.4. Spektral Aralıklar	36
3.5.2.5. Ortalama Frekans	37
3.6. İstatiksel Parametreler	37
3.7. Öznitelik Matrisinin Oluşturulması	38
3.8. Sınıflandırma	39

3.8.1. Öznitelik Matrisinin Eğitim ve Test Kümelerine Ayrılması	39
3.8.2. K-Fold Çapraz Doğrulama Yöntemi.....	40
3.8.3. Destek Vektör Makinesi (SVM).....	40
3.8.4. K-En Yakın Komşular (KNN).....	42
3.8.5. Gerçek Zamanlı Sınıflandırma	43
3.9. Ardışıl İleri Yönlü Öznitelik Seçimi	44
3.10. Başarım Değerlendirme Ölçütlerinin Hesaplanması	45
3.10.1. Hassasiyet (Sensitivity).....	45
3.10.2. Özgünlük (Specificity).....	46
3.10.3. Pozitif Tahmin Değeri (Positive Predictive Value)	46
3.10.4. Negatif Tahmin Değeri (Negative Predictive Value).....	46
3.10.5. Doğruluk (Accuracy – Correct Rate).....	46
4. BULGULAR 1 – GERÇEK ZAMANLI OLMAYAN UYGULAMA	47
4.1. Ardışıl İleri Yönlü Öznitelik Seçimi Sonuçları	47
4.2. Elde Edilen Başarımlar	49
4.2.1. Yumruk Başarımları	50
4.2.2. Parmak Açma Başarımları	50
4.2.3. Bilek İçeri Bükme Başarımları.....	51
4.2.4. Bilek Dışarı Bükme Başarımları.....	52
4.2.5. Pronasyon Başarımları	52
4.2.6. Supinasyon Başarımları	53
4.2.7. Dinlenme Başarımları	53
4.2.8. Ortalama Başarımlar	54
4.3. Kişi Başına Elde Edilen Başarımlar.....	54
4.4. Farklı Pencere Uzunluklarının, İstatiksel Parametrelerin ve Kas Aktivasyon Bölgesi Bulma Yöntemlerinin Karşılaştırılması	57
4.5. Jiroskop Verilerinin Eklenmesi ve Özniteliklerinin Karşılaştırılması	58
4.6. Kullanılan Kanal Sayısının Azaltılması	61
5. BULGULAR 2 – GERÇEK ZAMANLI UYGULAMA	75
6. TARTIŞMA.....	78
6.1. Öznitelik Seçimi ve Sınıflandırma Performanslarının İncelenmesi	78
6.2. Jiroskop Özniteliklerinin Sınıflandırma Performansına Etkilerinin İncelenmesi	78
6.3. Kullanılan Kanal Sayısının Azaltılması ile Elde Edilen Bulguların İncelenmesi....	79
6.4. Gerçek Zamanlı Sınıflandırma Sonuçlarının İncelenmesi.....	79
6.5. Gerçek Zamanlı Olmayan Sınıflandırma Doğruluklarının Literatürdeki Çalışmalar ile Karşılaştırılması.....	80
6.6. Gerçek Zamanlı Sınıflandırma Doğruluklarının Literatürdeki Çalışmalar ile Karşılaştırılması.....	82

7. SONUÇ	84
----------------	----

SİMGELER VE KISALTMALAR

SİMGELER

\bar{x}	Ortalama
σ	Standart sapma
σ^2	Varyans
S	Çarpıklık
K	Basıklık
s	saniye

KISALTMALAR

EMG	Elektromiyogram
IMU	Ataletsel Ölçüm Birimi
PCA	Temel Bileşen Analizi
SOFM	Kendi Kendini Düzenleyen Özellik Haritası
MLP	Çok Katmanlı Algılayıcı
LDA	Doğrusal Ayırma Analizi
NLDA	Doğrusal Olmayan Ayırma Analizi
SC	Altuzay Kümeleme
CRC	İşbirliği Temsiline Dayalı Sınıflandırma
DTW	Dinamik Zaman Atlama
CNN	Evrışimli Sinir Ağı
GMM	Gauss Karışım Modeli
HMM	Gizli Markov Modeli
DMAV	Ortalama Mutlak Değer Farkı
RF	Rastgele Orman
NB	Naive Bayes
YSA	Yapay Sinir Ağları
SVM	Destek Vektör Makinesi
KNN	K-En Yakın Komşuluk
Gyro	Jiroskop
K1	Yüzey EMG Kanal 1
K2	Yüzey EMG Kanal 2
K3	Yüzey EMG Kanal 3
K4	Yüzey EMG Kanal 4
K5	Yüzey EMG Kanal 5
K6	Yüzey EMG Kanal 6
K7	Yüzey EMG Kanal 7
K8	Yüzey EMG Kanal 8
RMS	Karesel Ortalama Kök
MAV	Ortalama Mutlak Değer
ZC	Sıfır Geçişi
WL	Dalga Formu Uzunluğu
SSC	Eğim İşareti Değişikliği
VAR	EMG Varyansı
WAMP	Willison Genliği
AAC	Ortalama Genlik Değişimi
SSI	Basit Kare İntegrali

DASDV	Mutlak Standart Sapma Deęerlerinin Farkı
IEMG	EMG İntegrali
MMAV1	Modifiye Edilmiş Ortalama Mutlak Deęer Tip 1
MMAV2	Modifiye Edilmiş Ortalama Mutlak Deęer Tip 2
MYOP	Miyotatım Yüzdelik Oranı
PKF	Tepe Frekansı
MNP	Ortalama Güç
TTP	Toplam Güç
SM1	Spektral Aralık 1
SM2	Spektral Aralık 2
MNF	Ortalama Frekans
TP	Doęru Pozitif
TN	Doęru Negatif
FP	Yanlış Pozitif
FN	Yanlış Negatif
YUM	Yumruk
PA	Parmak açma
BİB	Bilek içeri bükme
BİD	Bilek dışarı bükme
PRO	Pronasyon
SPN	Supinasyon
DN	Dinlenme
Q-SVM	İkinci Dereceden SVM
C-SVM	Üçüncü Dereceden SVM
M-SVM	Orta Gauss SVM
F-KNN	Saf KNN
W-KNN	Ağırlıklandırılmış KNN
S-KNN	Alt Uzay KNN

ŞEKİLLER DİZİNİ

Şekil 1.1. Sağ önkol iç taraf kasları (a) Birinci katman (b) İkinci katman (c) Üçüncü katman (d) Dördüncü katman (Moore, Agur, & Dalley, 1995)	1
Şekil 1.2. Sağ önkol dış taraf kasları (a) Yüzeydeki kaslar (b) Derindeki kaslar (Moore et al., 1995)	2
Şekil 3.1. Myo kol bandı ve sağ önkol üzerindeki yerleşimi	12
Şekil 3.2. Myo kol bandı yüzey EMG kanallarının kol kasları üzerindeki yerleşimi (Moore et al., 1995).....	13
Şekil 3.3. Sınıflandırılan el hareketleri (a) yumruk (b) parmak açma (c) bilek içeri bükme (d) bilek dışarı bükme (e) pronasyon (f) supinasyon (g) dinlenme	14
Şekil 3.4. Yumruk hareketine ait bir yüzey EMG işareti örneği	15
Şekil 3.5. Yumruk hareketine ait bir jiroskop işareti örneği	15
Şekil 3.6. Yüksek geçiren filtre uygulanmamış yüzey EMG işaretinin genlik spektrumu.....	16
Şekil 3.7. Yüksek geçiren filtre uygulanmış yüzey EMG işareti	17
Şekil 3.8. Yüksek geçiren filtre uygulanmış yüzey EMG işaretinin genlik spektrumu	17
Şekil 3.9. Bir yüzey EMG işaretine ait dalga formu uzunluğu	18
Şekil 3.10. Dalga formu uzunluğu üzerinde başlangıç ve bitiş anlarının bulunması .	19
Şekil 3.11. Yüzey EMG işaretinde el hareketinin başlangıç ve bitiş anlarının bulunması	20
Şekil 3.12. Bir yüzey EMG işaretinde el hareketinin gerçekleştiği aralık	20
Şekil 3.13. Bir jiroskop işaretinde el hareketinin gerçekleştiği aralık	21
Şekil 3.14. Bitişik pencereler (Englehart & Hudgins, 2003)	22
Şekil 3.15. Örtüşmeli pencereler (Englehart & Hudgins, 2003)	22
Şekil 3.16. Yüzey EMG işaretinin RMS özniteliğine ait 8 kanallı örnek çizim	24
Şekil 3.17. Yüzey EMG işaretinin MAV özniteliğine ait 8 kanallı örnek çizim	25
Şekil 3.18. Yüzey EMG işaretinin ZC özniteliğine ait 8 kanallı örnek çizim.....	25
Şekil 3.19. Yüzey EMG işaretinin WL özniteliğine ait 8 kanallı örnek çizim.....	26
Şekil 3.20. Yüzey EMG işaretinin SSC özniteliğine ait 8 kanallı örnek çizim.....	27
Şekil 3.21. Yüzey EMG işaretinin VAR özniteliğine ait 8 kanallı örnek çizim	28
Şekil 3.22. Yüzey EMG işaretinin WAMP özniteliğine ait 8 kanallı örnek çizim.....	29
Şekil 3.23. Yüzey EMG işaretinin AAC özniteliğine ait 8 kanallı örnek çizim	29
Şekil 3.24. Yüzey EMG işaretinin SSI özniteliğine ait 8 kanallı örnek çizim	30
Şekil 3.25. Yüzey EMG işaretinin DASDV özniteliğine ait 8 kanallı örnek çizim ...	31
Şekil 3.26. Yüzey EMG işaretinin IEMG özniteliğine ait 8 kanallı örnek çizim.....	31
Şekil 3.27. Yüzey EMG işaretinin MMAV1 özniteliğine ait 8 kanallı örnek çizim ..	32
Şekil 3.28. Yüzey EMG işaretinin MMAV2 özniteliğine ait 8 kanallı örnek çizim ..	33
Şekil 3.29. Yüzey EMG işaretinin MYOP özniteliğine ait 8 kanallı örnek çizim	33
Şekil 3.30. Yüzey EMG işaretinin PKF özniteliğine ait 8 kanallı örnek çizim	34
Şekil 3.31. Yüzey EMG işaretinin MNP özniteliğine ait 8 kanallı örnek çizim	35
Şekil 3.32. Yüzey EMG işaretinin TTP özniteliğine ait 8 kanallı örnek çizim.....	35
Şekil 3.33. Yüzey EMG işaretinin SM1 özniteliğine ait 8 kanallı örnek çizim	36
Şekil 3.34. Yüzey EMG işaretinin SM2 özniteliğine ait 8 kanallı örnek çizim	36
Şekil 3.35. Yüzey EMG işaretinin MNF özniteliğine ait 8 kanallı örnek çizim	37
Şekil 3.36. Öznitelik matrisinin oluşturulması	39
Şekil 3.37. Birden fazla özniteliğin birleştirilmesi	39
Şekil 3.38. $k = 5$ için k -fold çapraz doğrulama yöntemi.....	40

Şekil 3.39. İki sınıfı birbirinden ayıran doğrusal SVM örneği (Kazan & Karakoca, 2019).....	41
Şekil 3.40. Çekirdek fonksiyonu kullanarak verilerin ayrı bir uzaya taşınması (Karakoyun & Hacıbeyoğlu, 2014).....	42
Şekil 3.41. (a) $k = 1$ (b) $k = 5$ değerleri için KNN örneği (Okun & Skarlas, 2011) ...	42
Şekil 3.42. Yüzey EMG işareti üzerinde 150 ms uzunluğundaki pencereler.....	43
Şekil 3.43. Gerçek zamanlı sınıflandırma süreci akış şeması	44
Şekil 3.44. Ardışıl ileri yönlü öznitelik seçimi akış seması	45
Şekil 4.1. Adımlara göre sınıflandırma doğruluklarının değişimi	49
Şekil 4.2. Bir yüzey EMG özniteliği için jirosop özniteliklerinin sınıflandırma doğruluk değişimleri.....	59
Şekil 4.3. Üç yüzey EMG özniteliği için jirosop özniteliklerinin sınıflandırma doğruluk değişimleri.....	60
Şekil 4.4. G9 özniteliği grafiksel gösterimi.....	60
Şekil 4.5. G15 özniteliği grafiksel gösterimi.....	60
Şekil 4.6. G6 özniteliği grafiksel gösterimi.....	61
Şekil 4.7. G19 özniteliği grafiksel gösterimi.....	61
Şekil 4.8. Bir yüzey EMG özniteliği ile elde edilen en yüksek doğrulukların grafiksel gösterimi	73
Şekil 4.9. Üç yüzey EMG özniteliği ile elde edilen en yüksek doğrulukların grafiksel gösterimi	74
Şekil 5.1. Beşinci kişi gerçek zamanlı sınıflandırma doğrulukları	76
Şekil 5.2. Yedinci kişi gerçek zamanlı sınıflandırma doğrulukları	76


TABLULAR DİZİNİ

Tablo 3.1. Özniteliklerin kısaltmaları	23
Tablo 3.2. İstatiksel Parametreler	38
Tablo 4.1. Ardışıl ileri yönlü öznitelik seçimi birinci adım	47
Tablo 4.2. Ardışıl ileri yönlü öznitelik seçimi ikinci adım	48
Tablo 4.3. Ardışıl ileri yönlü öznitelik seçimi üçüncü adım	48
Tablo 4.4. Karmaşıklık matrisi	49
Tablo 4.5. Her bir kişi için elde edilen doğruluk yüzdeleri	50
Tablo 4.6. Yumruk hareketi TP, TN, FP, FN değerleri	50
Tablo 4.7. Parmak açma hareketi TP, TN, FP, FN değerleri	51
Tablo 4.8. Bilek içeri bükme hareketi TP, TN, FP, FN değerleri.....	51
Tablo 4.9. Bilek dışarı bükme hareketi TP, TN, FP, FN değerleri.....	52
Tablo 4.10. Pronasyon hareketi TP, TN, FP, FN değerleri.....	52
Tablo 4.11. Supinasyon hareketi TP, TN, FP, FN değerleri	53
Tablo 4.12. Dinlenme hareketi TP, TN, FP, FN değerleri	54
Tablo 4.13. Ortalama başarımlar	54
Tablo 4.14. Birinci kişi için elde edilen başarımlar	55
Tablo 4.15. İkinci kişi için elde edilen başarımlar.....	55
Tablo 4.16. Üçüncü kişi için elde edilen başarımlar.....	55
Tablo 4.17. Dördüncü kişi için elde edilen başarımlar	55
Tablo 4.18. Beşinci kişi için elde edilen başarımlar	56
Tablo 4.19. Altıncı kişi için elde edilen başarımlar	56
Tablo 4.20. Yedinci kişi için elde edilen başarımlar	56
Tablo 4.21. Sekizinci kişi için elde edilen başarımlar	56
Tablo 4.22. Dokuzuncu kişi için elde edilen başarımlar	57
Tablo 4.23. Onuncu kişi için elde edilen başarımlar	57
Tablo 4.24. Farklı pencere uzunluklarının karşılaştırılması.....	57
Tablo 4.25. Farklı istatiksel parametrelerin karşılaştırılması	57
Tablo 4.26. Farklı kas aktivasyon bölgesi bulma yöntemleri ile elde edilen bulgular	58
Tablo 4.27. Bir yüzey EMG özniteliği için jiroskop özniteliklerinin sınıflandırma doğrulukları.....	58
Tablo 4.28. Üç yüzey EMG özniteliği için jiroskop özniteliklerinin sınıflandırma doğrulukları.....	59
Tablo 4.29. Bir yüzey EMG özniteliği ve iki kanal ile elde edilen sınıflandırma doğruluk yüzdeleri.....	62
Tablo 4.30. Bir yüzey EMG özniteliği ve üç kanal ile elde edilen sınıflandırma doğruluk yüzdeleri.....	62
Tablo 4.31. Bir yüzey EMG özniteliği ve dört kanal ile elde edilen sınıflandırma doğruluk yüzdeleri.....	64
Tablo 4.32. Bir yüzey EMG özniteliği ve beş kanal ile elde edilen sınıflandırma doğruluk yüzdeleri.....	65
Tablo 4.33. Bir yüzey EMG özniteliği ve altı kanal ile elde edilen sınıflandırma doğruluk yüzdeleri.....	66
Tablo 4.34. Bir yüzey EMG özniteliği ve yedi kanal ile elde edilen sınıflandırma doğruluk yüzdeleri.....	67
Tablo 4.35. Üç yüzey EMG özniteliği ve iki kanal ile elde edilen sınıflandırma doğruluk yüzdeleri.....	67


Tablo 4.36. Üç yüzey EMG özneliđi ve üç kanal ile elde edilen sınıflandırma doğruluk yüzdeleri.....	68
Tablo 4.37. Üç yüzey EMG özneliđi ve dört kanal ile elde edilen sınıflandırma doğruluk yüzdeleri.....	69
Tablo 4.38. Üç yüzey EMG özneliđi ve beş kanal ile elde edilen sınıflandırma doğruluk yüzdeleri.....	70
Tablo 4.39. Üç yüzey EMG özneliđi ve altı kanal ile elde edilen sınıflandırma doğruluk yüzdeleri.....	71
Tablo 4.40. Üç yüzey EMG özneliđi ve yedi kanal ile elde edilen sınıflandırma doğruluk yüzdeleri.....	72
Tablo 4.41. Bir yüzey EMG özneliđi ile elde edilen en yüksek doğruluklar	72
Tablo 4.42. Üç yüzey EMG özneliđi ile elde edilen en yüksek doğruluklar	73
Tablo 5.1. Zaman düzlemi özneliklerinin gerçek zamanlı sınıflandırma sonuçları .	75
Tablo 5.2. Veri setindeki kişiler için elde edilen gerçek zamanlı sınıflandırma doğrulukları.....	77
Tablo 6.1. Tüm veri seti kullanılarak yapılan çalışmaların karşılaştırılması	81
Tablo 6.2. Veri setindeki kişilere ait doğrulukların ortalamasının verildiđi çalışmalar ile karşılaştırma	82
Tablo 6.3. Gerçek zamanlı uygulamalar ile karşılaştırma	83

1. GİRİŞ

EMG kasların kasılması sonucu ortaya çıkan biyolojik işaretlerdir. İstemli kas hareketleri, elektriksel iletilerin sinirler yoluyla beyinden kaslara ulaşması sonucu oluşurlar. Kas liflerinin kasılması elektriksel iletimlerle ortaya çıktığı gibi, kasılmalar sonucunda da elektriksel işaretler oluşur. Oluşan bu işaretler EMG işaretleridir (Kocuyigit and Kilic, 2008). EMG işaretlerinin algılanmasında iki ana elektrot türü kullanılır: iğne ve yüzey elektrotları (Hassan et al., 2019). Daha konforlu olması ve cerrahi müdahale gerektirmemesi nedeniyle yüzey elektrotları yapay uzuvların kontrolünde kullanılmaktadır (Barioul et al., 2019; Rafiee et al., 2011). Üzerinde 8 adet kuru yüzey elektrotu bulunan Myo kol bandı literatürdeki birçok çalışmada tercih edilmektedir (Côté-Allard et al., 2019; Kanoga et al., 2020; Said et al., 2020; Wahid et al., 2018). Kuru elektrotlar ile veri alması deneklerin hazırlık yapmadan kolaylıkla kol bandını kullanmasını sağlamaktadır (Cote-Allard et al., 2017). Bu tez çalışmasında Myo kol bandı sağ önkola takılarak buradan yüzey EMG işaretleri alınmıştır. Sağ önkolda bulunan kaslar Şekil 1.1 ve Şekil 1.2’ de gösterilmiştir.



Şekil 1.1. Sağ önkol iç taraf kasları (a) Birinci katman (b) İkinci katman (c) Üçüncü katman (d) Dördüncü katman (Moore et al., 1995)



Şekil 1.2. Sağ önkol dış taraf kasları (a) Yüzeydeki kaslar (b) Derindeki kaslar (Moore et al., 1995)

Yüzey EMG işaretleri durağan ve doğrusal olmayan işaretlerdir. Bu nedenle yüzey EMG işaretleri ham olarak işlenemez haldedir (Barioul et al., 2019). Bu sorunun aşılması için her bir yüzey EMG işaretinin öznelikleri çıkarılmıştır. Öznelik çıkarmanın amacı aynı sınıfa ait işaretler için benzer, farklı sınıfa ait işaretler içinse farklı ölçümler elde ederek yüzey EMG işaretlerini karakterize etmektir (Mokhlesabadifarahani and Gunjan, 2015). Karakterize edilen yüzey EMG işaretleri arasındaki farklılıklar belirli algoritmalar sayesinde algılanarak hangi hareket sınıfına ait olduğu tespit edilebilir. Buna sınıflandırma adı verilir. Veri setinde yer alan her bir yüzey EMG işareti için sınıflandırma yapılır ve sonuçlar doğru hareket ile karşılaştırılır. Bu karşılaştırma sonucunda doğru sonuçlar tüm verilere oranlanarak doğruluk değerleri elde edilir.

1.1. Tezin Amacı ve Kapsamı

Bu tez çalışmasının amacı mümkün olan en az sayıda yüzey EMG kanalı kullanarak güvenilir sınıflandırma sonuçları elde etmektir. Kanal sayısının azaltılmak istenmesinin nedeni el ampütasyonu olan bireylerde protez kol kullanımını kolaylaştırmaktır. Ampüte bireyler ellerini kaybettiklerinde ön kollarında kas kayıpları ile kalan kaslarda zayıflama sorunu yaşayabilmektedirler. Bu durum çok kanallı yüzey EMG verilerinin alınmasını zorlaştırmaktadır. Bu sorunun önüne geçmek için Myo kol bandı üzerinde mümkün olan en az sayıda yüzey EMG kanalını kullanarak güvenilir sınıflandırma sonuçları elde edilmeye çalışılmıştır. Kanal sayısı azaltılırken 2 kanaldan başlanarak 7 kanala kadar artırılmış ve tüm kanal kombinasyonlarının sınıflandırma sonuçları incelenmiştir. Kanal sayısının azaltılmasının yanı sıra Myo kol bandı üzerinden elde edilebilen jiroskop verilerinin sınıflandırma sonuçları üzerindeki etkileri de araştırılmıştır.

Yapılan literatür taramasında Myo kol bandı üzerindeki kanal sayısının azaltılması ve jiroskop verilerinin sınıflandırma sonuçları üzerindeki etkilerinin incelenmesi ile ilgili çalışmalara rastlanmamıştır. Böylece Myo kol bandında daha az kanal kullanılıp kullanılmayacağını sorunun cevabı araştırılarak literatüre katkı sağlanmıştır. Ayrıca jiroskop verilerinin etkileri incelenerek literatüre yeni bir öznitelik kazandırılmaya çalışılmıştır.

Bu tez çalışmasında kullanılan veri seti 10 sağlıklı kişiden Myo kol bandı ile alınan EMG ve jiroskop verileri ile oluşturulmuştur. Hazır veri seti kullanılmamıştır. Her bir kayıt sonrası alınan veri kontrol edilmiştir.

2. KAYNAK ÖZETLERİ

Bu tez çalışması hazırlanırken literatürdeki benzer çalışmalar incelenmiş ve özetlenmiştir. Çalışmaların literatüre katkıları, kullanılan veri setlerinin içeriği ile oluşturulma şekli, yüzey EMG işaretlerinin pencerelemesi, öznitelik vektörlerinin oluşturulması, kullanılan sınıflandırma algoritmaları ve elde edilen doğruluklar araştırılmıştır.

Chu ve arkadaşları çalışmalarında gerçek zamanlı çok fonksiyonlu sanal el kontrolü yapmışlardır. 6 erkek ve 4 kadın ($31 \pm 4,3$ yaş) olmak üzere 10 kişiden yüzey EMG verilerini, 4 kanallı olarak 1024 Hz örnekleme frekansı ile almışlardır. 9 farklı el hareketinde ait verileri 20 seans halinde almışlar ve her bir seansta hareketleri birer kez tekrarlamışlardır. Yüzey EMG işaretlerinin işlenmesinde 250 ms uzunluğunda %50 örtüşmeli kayan pencere kullanmışlardır. Öznitelik vektörünü dalgacık dönüşümünün genelleştirilmiş hali olan dalgacık paket dönüşümünden yararlanarak çıkarmışlardır. Öznitelik matrisinin boyutunu azaltmak için doğrusal (PCA) ve doğrusal olmayan (SOFM) öznitelik yansıtma yöntemi ortaya koymuşlardır. Bu yöntemde PCA ile boyutsallık azaltılmış ve SOFM ile sınıflar arası ayırım artırılmıştır. Daha sonra MLP ile sınıflandırma yapmışlardır. Bu yöntem ile ortalama % 97,024 doğruluk ve 5 ms sınıflandırma süresi elde etmişlerdir. Tüm süreç 100 ms sürmüş ve gerçek zamanlı kontrol için uygun olduğu sonucuna ulaşmışlardır (J-U Chu et al., 2006).

Chu ve arkadaşları çalışmalarında, LDA kullanan bir öznitelik yansıtma yöntemi önermişlerdir. 7erkek ve 3 kadın olmak üzere ($27 \pm 3,3$ yaş) olmak üzere 10 kişiden, 9 hareket için, 4 kanallı olarak, 1024 Hz örnekleme frekansı ile yüzey EMG verilerini almışlardır. Her denek için 20 seans- 10 seans eğitim,10 seans test- olmak üzere almışlardır. Her seansta her hareket 5 saniye boyunca 1 kez gerçekleştirilmiştir. Yüzey EMG işaretlerinin işlenmesinde 250 ms uzunluğunda %50 örtüşmeli kayan pencere kullanmışlardır. Öznitelik vektörünü dalgacık paket dönüşümü kullanarak bulmuşlardır. Öznitelik vektörünün boyutunu azaltmak için doğrusal denetimli bir öznitelik yansıtma yöntemi olan LDA kullanmışlardır. Daha sonra MLP kullanarak sınıflandırma yapmış ve % 97,4' lük sınıflandırma doğruluğu elde etmişlerdir. Bu yöntemi PCA, NLDA, SOFM gibi öznitelik yansıtma yöntemleriyle karşılaştırmış ve bu yöntemlerden daha yüksek doğruluk elde etmişlerdir. Tüm bu süreçlerin 97 ms sürdüğünü tespit etmiş ve bu yöntemin gerçek zamanlı uygulamalar için kullanılabilir

olduğu sonucuna ulaşmışlardır (Jun-Uk Chu et al., 2007).

Boyali ve arkadaşları SC ve CRC yöntemlerini kullanarak sürekli bir işaret üzerinde altı farklı el hareketini sınıflandırmaya çalışmışlardır. Yüzey EMG verilerini Myo kol bandı ile tek kayıta iki aynı hareketi gerçekleştirerek almışlardır. Her bir hareket çiftini beşer kez tekrarlamışlardır. İlk hareketleri eğitim, ikinci hareketleri test için kullanmışlardır. Alınan işaretlere herhangi bir ön işleme ve öz nitelik çıkarımı yapmadan doğrudan ham veriler üzerinden çalışmışlardır. Her bir kanaldaki işaretlere kayan pencere uygulayarak 1 boyutlu vektörler elde etmişler ve bu vektörleri eğitim kümesinde kullanmışlardır. Bir SC yöntemi kullanarak her bir sınıfa karşılık gelen verileri kümelemişlerdir. Daha sonra CRC ile verileri sınıflandırmışlar ve % 97 doğruluk elde etmişlerdir (Boyali et al., 2015).

Ploengpit ve arkadaşları çalışmalarında taş-kağıt-makas hareketlerini sınıflandırmış ve bu hareketler içerisinde kazananı belirlemişlerdir. Yüzey EMG verilerini Myo kol bandıyla 1 kişiden 3 farklı hareketin 20'şer kez tekrarlanması şeklinde almışlardır. Bu 20 tekrarın 10 tanesini sağ, 10 tanesini sol koldan almışlardır. Veri kayıt süresi için 5-10-15-20-25 saniyelik kayıtları denemişler ve en yüksek doğruluğu 15 saniyelik veri kaydında yakalamışlardır. Bu nedenle veri setinde 15 saniye uzunluğundaki verileri kullanmışlardır. Öz nitelik matrisinde en küçük değer, en büyük değer ve ortalama değer kullanmışlardır. Verilerin eğitilmesinde karar ağacı algoritmasını kullanmışlardır. Karar ağacını takip ederek bir karar fonksiyonu oluşturmuşlar ve kazananı belirlemek için bir algoritma belirlemişlerdir. Çalışma sonucunda % 78' lik doğruluk elde etmişlerdir (Ploengpit and Phienthrakul, 2016).

Akhmadeev ve arkadaşları çalışmalarında miyoelektrik kontrol için örüntü tanıma stratejilerinin test sisteminin geliştirilmesini amaçlamışlardır. Yüzey EMG verilerini Myo kol bandı ile 23-28 yaş aralığındaki 2 kadın ve 7 erkekten, 6 farklı el hareketi için almışlardır. İşaretlerin işlenmesinde 250 ms uzunluğunda % 50 örtüşmeli kayan pencereler kullanmışlardır. Öz nitelik matrisinde MAV, ZC, SSC, WL ve AR olmak üzere 5 farklı öz nitelik kullanmışlardır. Elde edilen öz nitelik matrisinin boyutunu PCA kullanarak azaltmışlardır. Sınıflandırma yapmadan önce öz nitelik matrisinin elemanlarını 0-1 arasında ölçeklendirmişlerdir. Sınıflandırma için SVM ve RBF algoritmalarını kullanmışlardır. Her bir denek için doğrulukları kontrol etmiş ve en düşük % 97,4 en yüksek % 99,81 doğruluğa ulaşmışlardır (Akhmadeev et al., 2017).

Benalcázar ve arkadaşları çalışmalarında, kas aktivasyon bölgesinin (el hareketinin başlangıç ve bitiş anları) tespitini içeren bir iyileştirme yöntemi önermişlerdir. Yüzey EMG verilerini Myo kol bandı ile 10 kişiden 5 el hareketi için her hareketin 10'ar kez tekrarlanması şeklinde almışlardır. 10 tekrarın 5 tanesi eğitim, 5 tanesi test için kullanılmıştır. Eğitim verileri 2 saniye, test verileri 5 saniye uzunluğunda kaydetmişlerdir. El hareketinin başlangıç ve bitiş anlarını tespit etmek için yüzey EMG işaretinin zarfını ve spektrumunu kullanmışlardır. Öznitelik matrisinde, önışlemede elde ettikleri EMG zarfını kullanmışlardır. Yüzey EMG işaretinin zarfını çıkarmak için 5 Hz alçak geçiren filtre kullanmışlardır. Sınıflandırma için KNN ve DTW algoritmalarını kullanmış ve % 89,5 doğruluk elde etmişlerdir. Tüm sürecin 193,1 ms sürdüğünü tespit etmiş ve bu modelin gerçek zamanlı uygulama için kullanılabilir olduğu sonucuna ulaşmışlardır (Benalcázar et al., 2017).

Cote-Allard ve arkadaşları çalışmalarında transfer öğrenme teknikleriyle gerçekleştirilen yeni bir CNN mimarisi sunmaktadır. Yüzey EMG verilerini Myo kol bandı ile iki farklı veri seti şeklinde almışlardır. Birinci veri setinde 7 farklı el hareketini 18 kişi yapmıştır. İkinci veri seti değerlendirme veri seti olarak adlandırılmış ve her biri 20 saniye süren 7 farklı el hareketi için 3 tur olarak 17 kişiden alınan verilerle oluşturulmuştur. Verilerin önışlemesini basitçe yüzey EMG verilerinin spektogramlarının hesaplanmasına indirgemişlerdir. İşaretlerin pencerelenmesinde 260 ms pencere uzunluğu ve 235 ms örtüşme miktarı uygulamışlardır. Öznitelik çıkarımı CNN'nin bir parçası olduğundan ayrıca öznitelik çıkarımı yapmamışlardır. Ayrıca elde edilen verilere toplu normalizasyon (batch normalization) uygulamışlardır. Sınıflandırma sonucunda % 97,81 doğruluk ve 84 ms işlem süresi elde etmişlerdir. Bu sonuçları bir robot kolun kontrolü için joystick kullanımı ile karşılaştırmışlar ve Myo kol bandının da aynı hassasiyette kontrol sağladığı sonucuna ulaşmışlardır (Cote-Allard et al., 2017).

Wibawa ve arkadaşları çalışmalarında işaret dili hareketlerinin tanınmasını ve çevrilmesini sağlayan bir uygulama yapmışlardır. Yüzey EMG verilerini Myo kol bandı ve sıçrama hareketi (leap montion) sensörleriyle almışlardır. Her iki sensörden alınan verileri belirli bir zaman işaretine dayanarak birbirine senkronize etmişlerdir. Veriler 3 kişinin 10 farklı el ve parmak hareketini 20' şer kez tekrarlamasıyla elde edilmiştir. Sıçrama hareketi bir çerçevenin tamamlandığını algılar ve öznitelikleri çıkarılmaya hazır bir veri satırı elde edilmiş olur. Her iki sensör için farklı öznitelikler çıkarılmıştır. Sıçrama hareketi için; parmak uçlarının açısı, parmak uçlarının uzaklığı,

parmak uçlarının yüksekliği olmak üzere üç öznitelik kullanılmıştır. Myo kol bandı içinse; MAV, WL, ZC, RMS, VAR olmak üzere beş adet öznitelik kullanılmıştır. Bu iki öznitelik seti birleştirilerek sınıflandırıcıya gönderilmiştir. Sınıflandırma aşamasında, öznitelik seti %60-%40 oranında sırasıyla eğitim-test diye ayrılmıştır. Elde edilen öznitelikler Naive Bayes sınıflandırma algoritması kullanılarak sınıflandırılmıştır. Yapılan işlemler sonucunda % 98,63 doğruluk elde edilmiştir (Wibawa and Sumpeno, 2017).

Yang ve arkadaşları çalışmalarında 1 kişiden 6 farklı harekete verileri Myo kol bandı ile almışlardır ve her bir hareketi 100 kez tekrarlamışlardır. El hareketinin başlangıç ve bitiş anının tespiti için, kısa zaman enerji ve sıfır geçiş oranından yararlanarak çift eşikleme yöntemi kullanmışlardır. İşaret işleme sürecinde 100 ms uzunluğunda, % 50 örtüşmeli kayan pencere kullanmışlardır. Öznitelik matrisinde yalnızca RMS özniteliğini kullanmışlardır. Sınıflandırıcı olarak GMM-HMM kullanmış ve % 99 doğruluk elde etmişlerdir (Yang et al., 2017).

Cagnolato ve arkadaşları çalışmalarında ampute bireylerdeki el hareketlerinin sınıflandırma doğruluklarını incelemişlerdir. Üç adet ampute bireyden 5 farklı el hareketine ait yüzey EMG verilerini 9 tekrar şeklinde Myo kol bandı ile almışlardır. Birinci denekte ön kolun % 90' ı, ikinci denekte ön kolun % 52' si, üçüncü denekte ön kolun % 27' si bulunmaktadır. 5 farklı el hareketinden 4 tanesinin sınıflandırmasını dahili Myo sınıflandırıcısı ile yapmışlardır ve doğrulukları her bir denek için ayrı ayrı hesaplamışlardır. Birinci denek için % 97,2; ikinci denek için % 66,7; üçüncü denek için % 50 doğruluk elde etmişlerdir. Böylece sınıflandırma doğruluğu ile uzvun ne kadarının kaybedildiği arasında bir bağlantı olduğu ve ampute bireylerde de yüksek sınıflandırma doğruluğu elde edilebileceği sonucuna varmışlardır (Cagnolato et al., 2018).

İşcan ve arkadaşları çalışmalarında dinamik yapısal sinir ağları tabanında dört farklı el hareketini ayırabilen ve kendini gerektiğinde genişletebilen bir algoritma sunmuşlardır. Yüzey EMG verilerini Myo kol bandı ile almışlardır. Modelin eğitilmesi için 1 kişiden tüm hareketler (4 farklı el hareketi) için toplam 536 veri alınmıştır. Test için 2 kişiden toplanmış 6 ayrı veri kullanılmıştır. Önışlemede herhangi bir filtre işlemi kullanmaksızın yüzey EMG değerlerinin mutlak değerlerini almışlardır. Daha sonra işareti 100 ms'lik pencerelerde mutlağı alınan değerlerin maksimum değerlerini almış ve sinir ağının girişine bu değerleri göndermişlerdir. Gerektiğinde ağın kendini genişletebilmesi için bir genişleme algoritması kullanmışlardır. Genişleme algoritması

eğitimin artık yapılamayacağı durumda uygulanmış ve hata değişimi belli bir değerin üstüne çıktığında gizli katmanda bir nöron artışı yapılmıştır. Gerçek zamanlı uygulamalar için işlem hızının artırılması amacıyla Myo kol bandının tüm kanallarını işleme katmak yerine en iyi ayrımı veren 1-6-8 numaralı kanalları kullanmışlar ve diğer kanalları hesaba katmamışlardır. İşlemler sonucunda % 94'lük doğruluk ve 100 ms işlem süresi elde etmişlerdir (İşcan et al., 2018).

Kunapipat ve arkadaşları çalışmalarında sensör destekli yüzey EMG veri kayıt sistemi önermişlerdir. Veri toplamak için Myo kol bandı ve yanında sensör desteği olarak 5DT eldiveni kullanmışlardır. 5DT veri eldiveni tıpkı Myo kol bandı gibi 200 Hz örnekleme frekansı ile veri toplamaktadır. Yüzey EMG verilerini 20 sağlıklı bireyden, 3 farklı el hareketi için 10 farklı kol pozisyonunda almışlardır ve bu 3 el hareketini sınıflandırmışlardır. Her bir bireyden 200 kayıt veri almışlardır. Öznitelik matrisinde RMS, MAV, VAR, WL ve DMAV olmak üzere 5 adet zaman düzlemi özniteliği kullanmışlardır. Öznitelik matrisini elde ettikten sonra PCA ile boyutsallık azaltmış ve SVM ile sınıflandırma yapmışlardır. Sınıflandırma doğruluklarını % 0, % 25, % 50 ve % 75 örtüşme miktarı için kontrol etmiş ve en yüksek doğruluğu % 50 örtüşme ve % 91 doğruluk ile almışlardır. Pencere uzunluğunu ise 500 ms seçmişlerdir (Kunapipat et al., 2018).

Kurniawan ve arkadaşları çalışmalarında yapay sinir ağları ve Myo kol bandı kullanarak bir robot kolu kontrol etmeye çalışmışlardır. Elde edilen yüzey EMG işaretlerine hareketli ortalama filtre uygulamışlar ve öznitelik vektöründe yalnızca RMS kullanmışlardır. Yapay sinir ağının eğitilmesi için 20 yaşındaki erkek bir birey 2 el hareketini beşer kez tekrarlamıştır. Elde edilen model ile Arduino UNO üzerinden bir robot kolu kontrol etmişlerdir. Denek iki el hareketi için 30 kez deneme yapmış ve bunun sonucunda % 92,68'lik doğruluk elde etmişlerdir (Kurniawan and Pamungkas, 2018).

Phinyomark ve arkadaşları çalışmalarında yüzey EMG verilerini düşük (200 Hz) ve yüksek (1000 Hz) örnekleme frekanslarıyla alıp doğruluklarını karşılaştırmışlardır. 20 farklı kişiden 8 farklı el hareketi için yüzey EMG verilerini almışlardır. Her bir denekten 4 gün boyunca, günde 3 seans el hareketlerini yapmaları istenmiştir. Her seansta 5 deneme yapılmıştır. Her hareket sırasında 2 saniye dinleme ve 2 saniye hareket süresi vardır. 11 adet zaman düzlemi özniteliği ve özniteliklerin çıkarılmasında 250 ms uzunluğunda % 50 örtüşmeli kayan pencereler kullanmışlardır. Düşük örnekleme frekansında LDA ve SVM sınıflandırıcılarının doğruluklarının düştüğünü

ve WL özniteliğinin hem düşük hem de yüksek örnekleme frekansında en iyi doğruluğu veren öznitelik olduğunu gözlemlemişlerdir. Çalışmanın sonucunda örnekleme frekansının sınıflandırma performansı üzerinde önemli bir etkisi olduğu ve 200 Hz örnekleme frekansı için yeni ve sağlam öznitelik çıkarma yöntemlerinin gerekli olduğunu görmüşlerdir (Phinyomark and Scheme, 2018).

Wahid ve arkadaşları çalışmalarında yüzey EMG verilerinin normalize edilmesinin doğruluğa etkisini incelemişlerdir. Yüzey EMG verilerini Myo kol bandı ile 3 hareket için 20-37 yaş aralığındaki 10 erkek bireyden her bir hareketin 10-12 kez tekrarlanmasıyla almışlardır. El hareketinin başlangıç ve bitiş anının tespiti için 300 ms uzunluğunda % 50 örtüşmeli kayan pencereler ile hesaplanmış RMS özniteliğinden faydalanmışlardır. Öznitelik çıkarımında ise kayan pencere kullanmamışlardır. Elde ettikleri verileri iki farklı şekilde normalize etmişlerdir. Birincisi, yüzey EMG işaretindeki her bir değeri işaretin en büyük değerine bölmüşlerdir. İkincisi, RMS grafiğinin altında kalan alanı her bir öznitelik değerine bölmüşlerdir. Öznitelik matrisinde MAV, ZC, WL ve SSC kullanmışlardır. Yapılan normalize işlemi sonucunda, normalize edilmemiş yüzey EMG işaretine göre daha yüksek doğruluğa elde ettikleri görülmüştür. Sınıflandırma yaparken LDA, SVM, KNN, RF, NB sınıflandırma algoritmalarını kullanmışlardır. En yüksek doğruluğu, RMS alanına normalize ederek ve RF sınıflandırıcı kullanarak % 96,4 olarak bulmuşlardır (Wahid et al., 2018).

Chen ve arkadaşları çalışmalarında sınıflandırma için 5 alt model içeren bir SVM sınıflandırıcısı önermişlerdir. Yüzey EMG verilerini Myo kol bandı ile almışlardır. Veri kümesinin oluşturulması için 9 sağlıklı birey, 5 farklı el hareketini 5'er kez tekrarlamışlardır. Önışlemede öncelikle gürültülerin giderilmesi için yüzey EMG işaretinin mutlak değerini almış ve daha sonra 5 Hz kesim frekansında yüksek geçiren filtre kullanmışlardır. El hareketinin başlangıç ve bitiş anlarının bulunması için öncelikle 8 kanalı toplamış daha sonra spektogramı elde etmek için zaman-frekans aralıkları 26 noktaya ayırmışlardır. Spektogramın I^2 formu 26×26 ' lık bir matris elde etmek için hesaplamış ve bir vektör oluşturmak için bu matrisin sütunlarını toplamışlardır. Vektörün sabit olarak belirlenen bir eşikten daha büyük olan bileşenleri hareketin gerçekleştiği kısım olarak alınmıştır. Öznitelik vektöründe MAV, SSC, WL, RMS ve Hjorth parametreleri kullanmışlardır. Elde edilen öznitelik vektörünü % 70 eğitim, % 30 test olarak ayırmışlardır. Tanınabilirlikten emin olmak için tüm test kümesini 5 SVM alt modeli ile tek tek sınıflandırmışlardır. Yani 5 farklı el hareketinde

her bir hareketi farklı bir SVM alt modeli ile sınıflandırmışlardır. Çalışma sonucunda % 89 doğruluk elde etmişlerdir (Chen and Zhang, 2019).

Cote-Allard ve arkadaşları çalışmalarında yüzey EMG tabanlı el hareketi tanımada kullanıcılar arası verilerden yararlanmak için CNN kullanan bir transfer öğrenme şeması sunmuşlardır. Çalışmada Myo kol bandı ile kaydedilmiş iki farklı veri seti kullanmışlardır. Birinci veri seti, iki alt kümeden oluşmaktadır. Birinci alt küme, 19 sağlıklı kişiden veri toplanarak elde edilmiş ve sınıflandırma tekniklerini oluşturmak, doğrulamak, optimize etmek için kullanılmıştır. İkinci alt küme, 17 sağlıklı kişiden veri toplanarak elde edilmiş ve yalnızca test için kullanılmıştır. Birinci veri setinin her iki alt kümesinde 7 farklı el hareketine ait veriler toplanmıştır. Birinci alt kümede hareketler 1' er kez, ikinci alt kümede ise 3'er kez tekrarlanmıştır. Çalışmada kullanılan ikinci veri seti NinaProDB5 olarak adlandırılan veri setidir. Bu veri seti toplamda 3 farklı egzersiz setine bölünmüş toplam 53 farklı el hareketinin 10 kişi tarafından 6' şar kez yapılmasıyla oluşturulmuştur. Öznitelik setinde RMS, MAV, ZC, WL, SSC, IEMG, AR katsayıları, hjort parametreleri, EMG histogramları, sürekli dalgacık dönüşümü gibi öznitelikler kullanılmıştır. Özniteliklerin çıkarılmasında 235 ms örtüşmeli, 260 ms uzunluğundaki kayan pencereler kullanılmıştır. Sınıflandırmada; LDA, KNN ve CNN gibi sınıflandırıcılar denenmiştir. En yüksek doğruluk sürekli dalgacık dönüşümü ve transfer öğrenmeyle geliştirilmiş CNN ile % 98,31 olarak elde edilmiştir. Ayrıca model gerçek zamanlı olarak da test edilmiş ve % 95,42 doğruluk elde edilmiştir (Côté-Allard et al., 2019).

Hassan ve arkadaşları çalışmalarında Myo kol bandı ile elde edilen yüzey EMG verilerini kullanarak bir robot kolu (5-DoF Aideepen ROT3U) hareket ettirmeye çalışmışlardır. Yüzey EMG verilerini 6 sağlıklı bireyin 7 farklı el hareketini 8'er kez tekrarlaması şeklinde almışlardır. Öznitelik matrisinde RMS, MAV, SSC, WL ve AR öznitelikleri ve bunların çıkarılmasında 240 ms uzunluğunda % 50 örtüşmeli pencereler kullanmışlardır. Sınıflandırma için SVM, LDA ve KNN algoritmalarını kullanmışlardır. Gerçek zamanlı olmayan sınıflandırma sonuçlarında en yüksek doğruluğu SVM sınıflandırıcısı için 95,26 olarak bulmuşlardır. Robot kolun gerçek zamanlı kontrolünde ise sistemin hızını artırmak için Myo kol bandının ikinci kanalını kullanmamışlardır. Robot kolun gerçek zamanlı kontrolünde yaklaşık % 94'lük doğruluk elde etmişlerdir (Hassan et al., 2019).

Hussain ve arkadaşları çalışmalarında Myo kol bandı ile tanınan hareketleri artırmayı amaçlamışlardır. Myo kol bandı ile tanınan 5 temel el hareketine 9 yeni hareket ekleyerek toplamda 14 hareket üzerinden sınıflandırma yapmışlardır. Yüzey EMG verilerini Myo kol bandı ile 3 sağlıklı kişinin 14 farklı el hareketini 2' şer kez tekrarlaması şeklinde almışlardır. Öznitelik matrisinde RMS, standart sapma, en küçük değer ve en büyük değer kullanmışlardır. Sınıflandırma için MLP kullanmışlar ve % 90,5' lik doğruluk elde etmişlerdir. Bu nedenle 14 farklı el hareketinin Myo kol bandı ile güvenli bir şekilde sınıflandırılabilceği sonucuna varmışlardır (Hussain et al., 2020).

Kanoga ve arkadaşları çalışmalarında Miyoelektrik kontrol sistemlerinde sensör yerleşiminin etkisini araştırmışlardır. Yüzey EMG verilerini Myo kol bandı ile 5 sağlıklı erkek bireyden 22 farklı el hareketi için almışlardır. Her bir denekten üç farklı sensör yerleşimi için 30 ardışık gün (hafta sonları hariç) boyunca veri kaydı alınmasıyla veri setini oluşturmuşlardır. Her bir günde denekler 22 farklı el hareketini 4' er kez tekrarlamışlardır. Üç farklı sensör yerleşimi: normal pozisyon, kol bandının saat yönünde 8 mm döndürülmesi ve kol bandının saatin ters yönünde 8 mm döndürülmesi şeklindedir. Özniteliklerin çıkarılması için 250 ms uzunluğunda % 80 örtüşmeli pencereler ile MAV, ZC, SSC, WL, RMS, AR katsayıları özniteliklerini kullanmışlardır. Sınıflandırma algoritması olarak LDA kullanmışlardır. Performans değerlendirmesini hem gün içi hem de günler arası olarak yapmışlardır. Gün içi değerlendirmelerde sensör yerleşiminin önemli bir etkisini göremezken, günler arası değerlendirmede sensör yerleşiminin önemli etkilerini gözlemlemişlerdir. Yapılan tüm değerlendirmelerde elde edilen sınıflandırma doğrulukları % 70-95 arasında değişiklik göstermiştir (Kanoga et al., 2020).


Said ve arkadaşları çalışmalarında 3 boyutlu yazıcı ile üretilmiş biyonik eli gerçek zamanlı kontrol etmişlerdir. Yüzey EMG verilerini Myo kol bandı ile 4 farklı el hareketinin 23 kişi tarafından 10' ar kez tekrarlanması şeklinde almışlardır. Öznitelik matrisinde MAV, standart sapma ve AR katsayılarını kullanmışlardır. Sınıflandırmada yapay sinir ağları, karar ağaçları ve SVM algoritmalarını denemişlerdir. Gerçek zamanlı olmayan sınıflandırma sonuçlarına göre en yüksek doğruluğu SVM sınıflandırıcısı ile % 89,93 olarak elde etmişlerdir. Gerçek zamanlı uygulamada ise 14 el hareketini 20' şer kez tekrarlamıştır ve bunun sonucunda % 95 doğruluk elde etmişlerdir (Said et al., 2020).

3. MATERYAL VE YÖNTEM

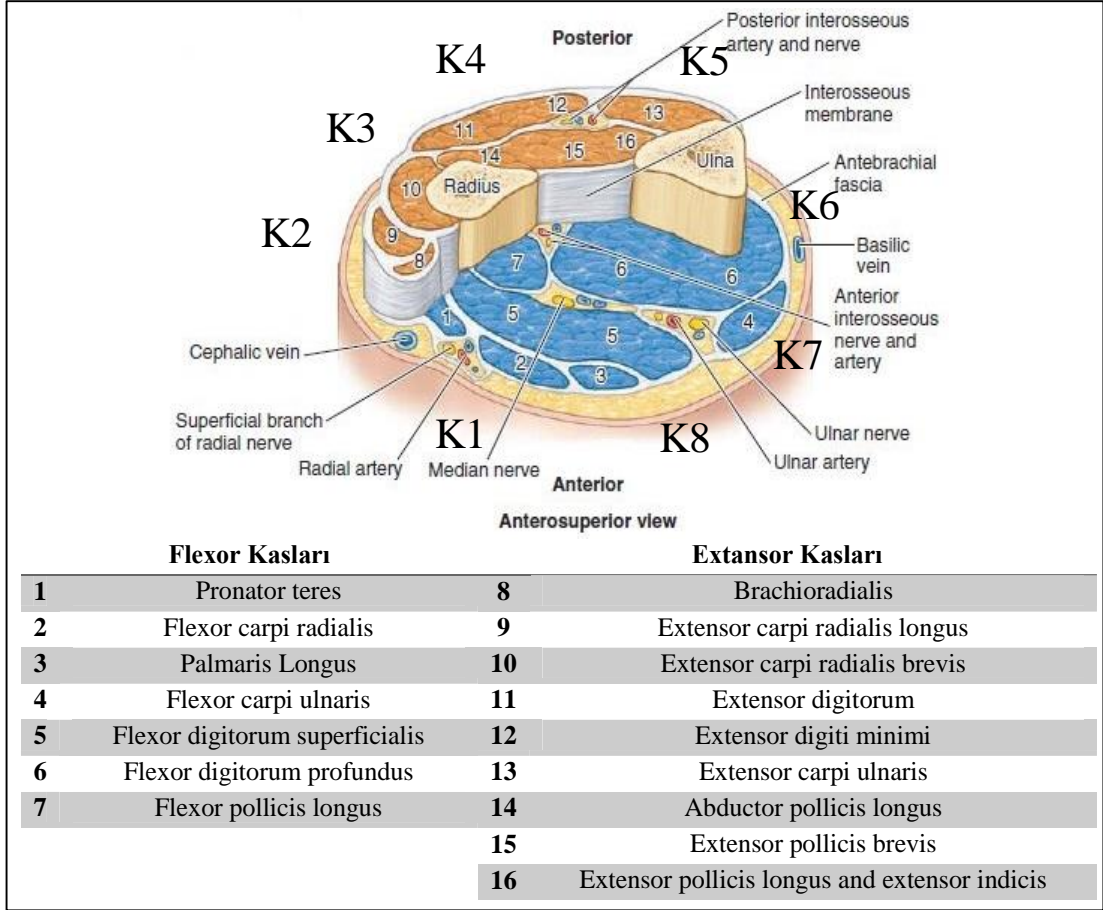
3.1. Myo Kol Bandı

Myo kol bandı yüzey EMG ve IMU verilerine dayanan, kablosuz, düşük maliyetli bir giyilebilir teknoloji cihazıdır. 93 gram ağırlığındadır ve 19-34 cm arasında ayarlanabilir çapa sahiptir (Cognolato et al., 2018). Myo kol bandı 8 adet yüzey EMG sensörüne ve 3 eksen jiroskop, 3 eksen ivmeölçer, 3 eksen manyetometre içeren 9 eksenli IMU sensörlerine sahiptir. Myo kol bandı yüzey EMG verilerini 200 Hz, IMU verilerini 50 Hz örnekleme frekansı ile almaktadır (Abduo and Galster, 2015). Myo kol bandı gömülü sistem kısıtlamaları nedeniyle yüzey EMG verilerini düşük frekansta örneklemektedir (Phinyomark and Scheme, 2018).

Şekil 3.1’ de Myo kol bandının kol üzerindeki yerleşimi ve hangi elektrotların hangi yüzey EMG kanallarını ifade ettiğini belirten numaralandırmalar gösterilmiştir. Bu elektrotların her biri ön kol yüzeyindeki kasların üzerlerinden yüzey EMG işaretlerini algılamaktadır. Her bir kanalın önkol yüzeyindeki hangi kaslardan işaretleri algıladığı ön kol kesiti üzerinden Şekil 3.2’ de gösterilmiştir.



Şekil 3.1. Myo kol bandı ve sağ önkol üzerindeki yerleşimi

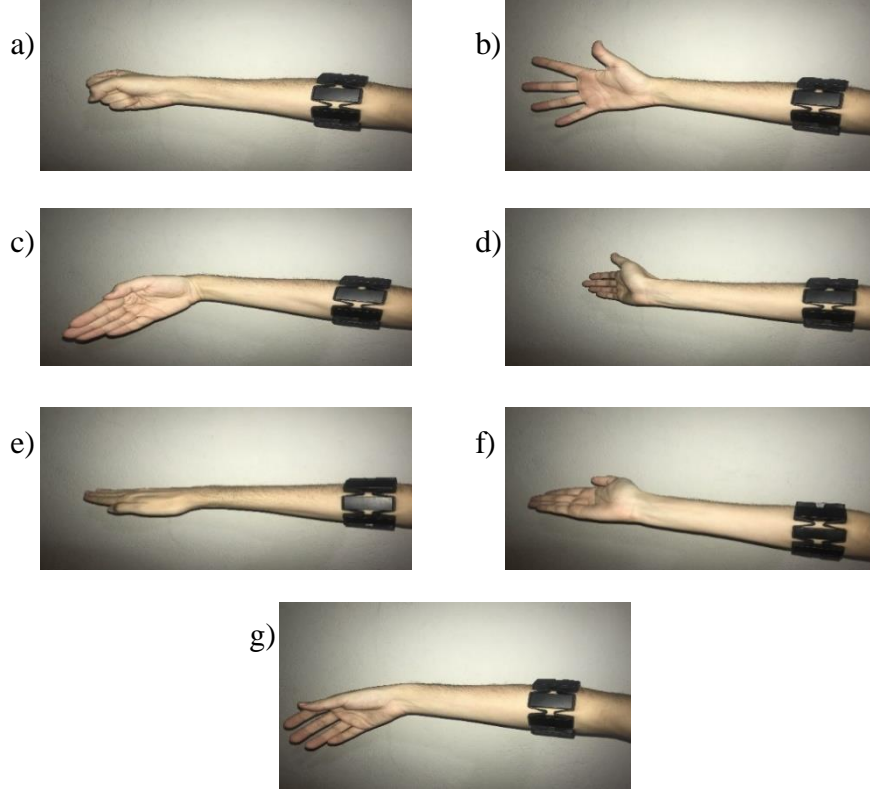


Şekil 3.2. Myo kol bandı yüzey EMG kanallarının kol kasları üzerindeki yerleşimi (Moore et al., 1995)

3.2. Veri Alma Protokolü ve Veri Setinin Oluşturulması

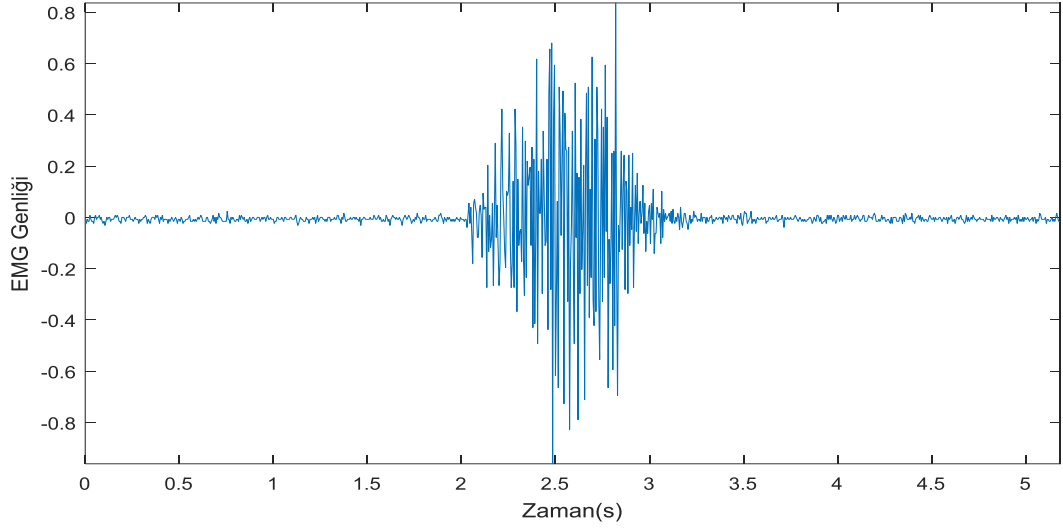
Verilerin elde edilmesinde Myo kol bandı kullanılmıştır. Myo kol bandı kişi sandalyeye dik durumda otururken sağ ön kola takılmış ve kişi kolunu zemine dik şekilde serbest bırakmıştır. Bir hareketin kaydı 5 saniye sürmüştür ve kişi 2. saniyede harekete başlayarak kendi isteğiyle hareketi bitirmiştir. Kayıt işleminde 8 kanallı yüzey EMG verileri ile 3 kanallı jiroskop verileri kaydedilmiştir. Ancak el hareketinin en belirgin olduğu kanal olması nedeniyle, jiroskop verilerinin yalnızca 1. kanalı kullanılmıştır.

Tüm veri setinin elde edilmesi için 33 ± 16 yaşlarında sağlıklı 3 erkek ve 7 kadın bireyden veri alınmıştır. Kişiler 6 farklı el hareketini 30' ar kez tekrarlamışlardır. Bu 6 hareket: yumruk, parmak açma, bilek içeri bükme, bilek dışarı bükme, pronasyon ve supinasyondur. Her veri kaydında hareket 2. saniyede başlamış ve ilk 2 saniyede kol dinlenme konumunda kalmıştır. Böylece her bir veride dinlenme durumuna ait veriler vardır ve dinlenme konumu 7. hareket olarak eklenip 7 hareket üzerinden sınıflandırma yapılmıştır. Sınıflandırılan bu 7 hareket Şekil 3.3' de gösterilmiştir.




Şekil 3.3. Sınıflandırılan el hareketleri (a) yumruk (b) parmak açma (c) bilek içeri bükme (d) bilek dışarı bükme (e) pronasyon (f) supinasyon (g) dinlenme

Ham bir yüzey EMG işareti 0-1000 Hz arasında değişen frekans bandına ve 0-2 mV arasında değişen tepeden tepeye genliklere sahiptir (Ghapanchizadeh et al., 2017). Şekil 3.4' de yumruk hareketine ait bir yüzey EMG işareti örneği gösterilmiştir. Bu örnek, yumruk hareketi yapıldığında Myo kol bandının 1. kanalından alınan bir yüzey EMG işaretidir. Bir hareket için bu örneğe benzer, farklı genliklerde 8 adet yüzey EMG işareti alınmaktadır. Ayrıca Şekil 3.5' de yumruk hareketine ait bir jiroskop işareti örneği gösterilmiştir.



Şekil 3.4. Yumruk hareketine ait bir yüzey EMG işareti örneđi



Şekil 3.5. Yumruk hareketine ait bir jiroskop işareti örneđi


3.3. Önışleme

Ham yüzey EMG verilerinin öznitelikleri çıkarılmadan önce önışlemeden geçirilmiştir. Yüzey EMG işaretleri için önışleme süreci iki aşamadan oluşmaktadır: işarete filtre uygulanması ve hareketin başlangıç-bitiş anlarının bulunarak diğer kısımların işareten çıkarılması. Ayrıca jiroskop verilerinde de hareketin başlangıç ve bitiş anları bulunup işareten çıkarılarak bir önışleme uygulanmıştır.

3.3.1. Yüzey EMG İşaretine Filtre Uygulanması


Ham bir yüzey EMG işaretinin frekans bandı 0-1000 Hz arasındadır (Ghapanchizadeh et al., 2017). Ancak yüzey EMG işaretinin anlamlı frekans bandı 0-400 Hz arasındadır (De Luca et al., 2010). Yüzey EMG verilerinin 200 Hz örnekleme frekansı ile alınması nedeniyle, Nyquist teoremi geređi, Myo kol bandı ile alınan bir

yüzey EMG işaretindeki en yüksek frekans bileşeni 100 Hz olmaktadır. Şekil 3.4' de gösterilen yüzey EMG işaretinin, fourier dönüşümü alınarak elde edilmiş genlik spektrumu Şekil 3.6' da gösterilmiştir. Buradan en yüksek frekans bileşeninin 100 Hz olduğu görülmektedir.




Şekil 3.6. Yüksek geçiren filtre uygulanmamış yüzey EMG işaretinin genlik spektrumu

Yüzey EMG işaretine karışmış olabilecek düşük frekanslı vücut iç gürültülerinin işaretten çıkarılması amacıyla yüksek geçiren filtre kullanılmıştır. Yüksek geçiren filtrenin kesim frekansı 10 Hz olarak seçilmiştir (Robertson et al., 2013). Ayrıca Myo kol bandının içerisinde 50 Hz çentik filtre bulunduğundan şebeke gürültülerinin çıkarılması amacıyla çentik filtre kullanılmamıştır (Pizzolato et al., 2017). Genlik spektrumu incelendiğinde 50 Hz' lik frekans bileşeni genliğinin sıfıra çok yakın olduğu görülebilmektedir. Şekil 3.4' de gösterilen yüzey EMG işaretinin, yüksek geçiren filtre uygulandıktan sonraki durumu Şekil 3.7' de gösterilmiştir. Bu işaretin fourier dönüşümü alınarak elde edilmiş genlik spektrumu Şekil 3.8' de gösterilmiştir.



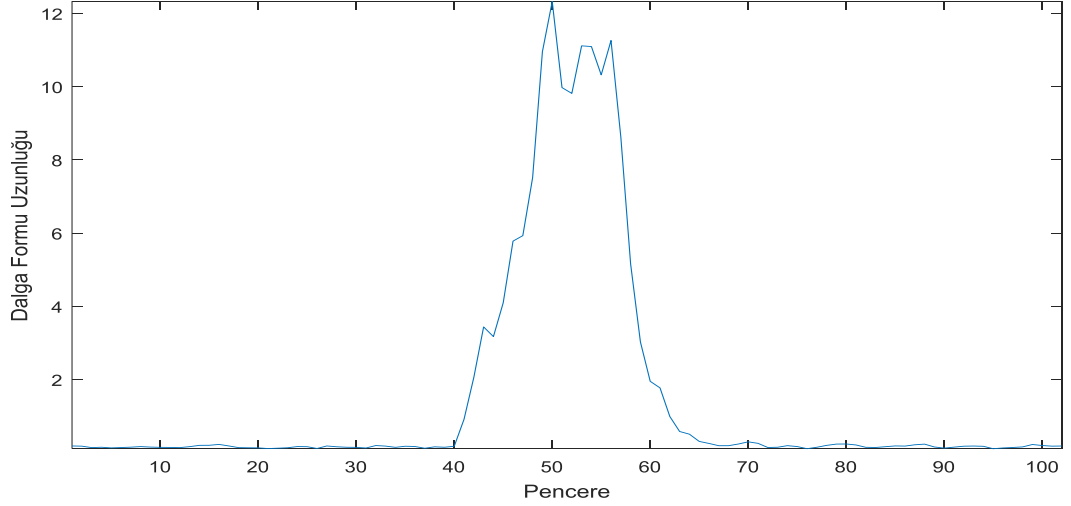
Şekil 3.7. Yüksek geçiren filtre uygulanmış yüzey EMG işareti



Şekil 3.8. Yüksek geçiren filtre uygulanmış yüzey EMG işaretinin genlik spektrumu

3.3.2. El Hareketinin Başlangıç ve Bitiş Anlarının Bulunması

El hareketinin başlangıç ve bitiş anlarının (kas aktivasyon bölgesinin) bulunması için öncelikle yüzey EMG işareti 100 ms uzunluğunda % 50 örtüşmeli pencerelere ayrılır ve her bir pencere için dalga formu uzunluğu değerleri hesaplanır. Dalga formu uzunluğunun hesaplanması için kullanılan eşitlik (3. 4)' de gösterilmiştir. Hesaplama sonucunda Şekil 3.9' daki gibi bir grafik elde edilir. Dalga formu uzunluğu değerleri el hareketinin başlangıç ve bitiş anlarının bulunmasında doğrudan kullanılmıştır.



Şekil 3.9. Bir yüzey EMG işaretine ait dalga formu uzunluğu

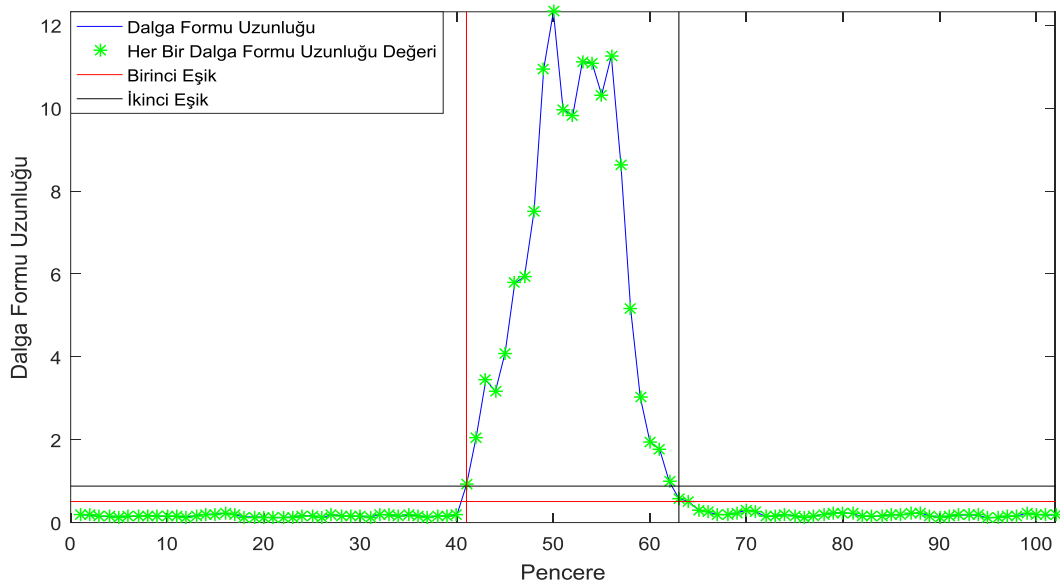
Elde edilen dalga formu uzunluğu değerleri üzerinden öncelikle bir eşik değeri belirlenir. Yaklaşık 100-110 değerden oluşan dalga formu uzunluğunun, dinlenme anını ifade eden ilk 38 değeri eşik bulmak için kullanılır. Bu ilk 38 değer içindeki en büyük değerın 2,2 katı birinci eşik olarak seçilir. Daha sonra 38. değerden başlayarak dalga formu uzunluğu değerleri kontrol edilir ve eşik değerinin geçildiği yer hareketin başlangıcı kabul edilir. Hareketin bittiği anı bulmak içinse ikinci bir eşik belirlenir. Bunun nedeni veri toplama esnasında, hareket bitirildiğinde kasların bir miktar kasılmaya devam ettiğinin gözlemlenmesidir. İkinci eşik, birinci eşikın 1,7 katı olarak belirlenmiştir. İkinci eşik de hesaplandıktan sonra hareketin başlangıcından itibaren dalga formu uzunluğu değerleri kontrol edilir ve eşik değerinin altına inilen ilk yer hareketin bitişi kabul edilir. Ancak dinlenme anındaki anlık yükselmelere veya hareket anındaki anlık düşmelere takılmamak için bulunan el hareketi aralığı kontrol edilir. Eğer başlangıç ile bitiş arasındaki fark 10 ve aşağısında ise başlangıç anından bir sonraki değerin de birinci eşikten büyük olup olmadığına bakılır. Eğer bir sonraki değer birinci eşikın altında kalıyorsa başlangıç kabul edilmez ve kontrol etmeye devam edilir. Aynı işlem hareketin bitişi için de yapılır. Hareketin bitişinden bir sonraki değerin de ikinci eşikın altında olup olmadığına bakılır. Eğer bir sonraki değer ikinci eşikın üstüne çıkıyorsa bitiş kabul edilmez ve kontrol etmeye devam edilir (Tepe and Demir, 2020).

Bazı verilerde bu yöntemin uygulamasında hareket başlangıcının tespit edilememesi sorunu ile karşılaşmıştır. Yalnızca bu sorunun görüldüğü verilere özel olarak ikinci bir eşik bulma yöntemi uygulanmıştır. Bu yöntemde başlangıç ve bitiş

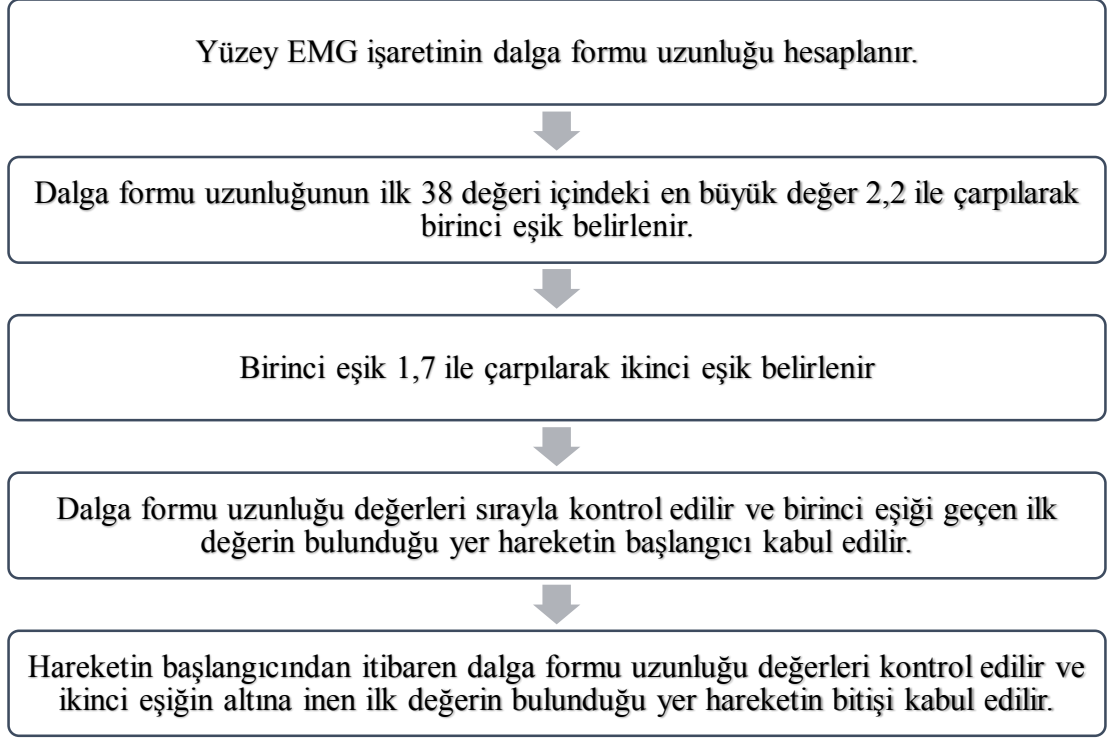
için ayrı ayrı eşik hesaplanmamış ve tek bir eşik kullanılmıştır. Bu eşik hesaplanırken dalga formu uzunluğundaki ilk 38 değerın ortalaması, yine bu ilk 38 değerin standart sapmasının 5 katı ile toplanmıştır (Fraıwan et al., 2011). Bu yöntemde kullanılan sayısal değeri deneme yanılma yoluyla bulunmuş ve yöntem tüm veri setinde tek tek denenerek kontrol edilmiştir.

Dalga formu uzunluęu üzerinden bulunan başlangıç ve bitiş anları, el hareketin gerçekteştięi aralıęın kaçınıcı pencerelele denk geldięini ifade etmektedir. Bu nedenle dalga formu uzunluęundan kurtulup yüzey EMG işareti üzerinden başlangıç ve bitiş anlarının ifade edilebilmesi için bulunan değeri pencere adımı ile çarpılmalıdır. Bunun yapılabilmesi için öncelikle pencere adımı saniye cinsinden değil, örnek cinsinden ifade edilmelidir. 100 ms uzunluęundaki % 50 örtüşmeli pencerede pencere adımı 50 ms' dir. 200 Hz örnekleme frekansı ile veri alındığı için örnek cinsinden pencere adımı 10 örnek olacaktır. Bunun anlamı dalga formu uzunluęu üzerinden bulunan başlangıç ve bitiş anları 10 ile çarpılarak yüzey EMG işareti üzerinde ifade edilebilir.


Yapılan işlemler sonucu bulunan eşik değeri ile başlangıç ve bitiş anları, bir yüzey EMG işaretine ait dalga formu uzunluęu üzerinden Şekil 3.10' da gösterilmiştir. Yapılan işlemlere ait akış şeması Şekil 3.11' de gösterilmiştir. Şekil 3.12' de bir yüzey EMG işareti üzerinden tespit edilen el hareketi aralıęı gösterilmiştir.



Şekil 3.10. Dalga formu uzunluęu üzerinde başlangıç ve bitiş anlarının bulunması



Şekil 3.11. Yüzey EMG işaretinde el hareketinin başlangıç ve bitiş anlarının bulunması

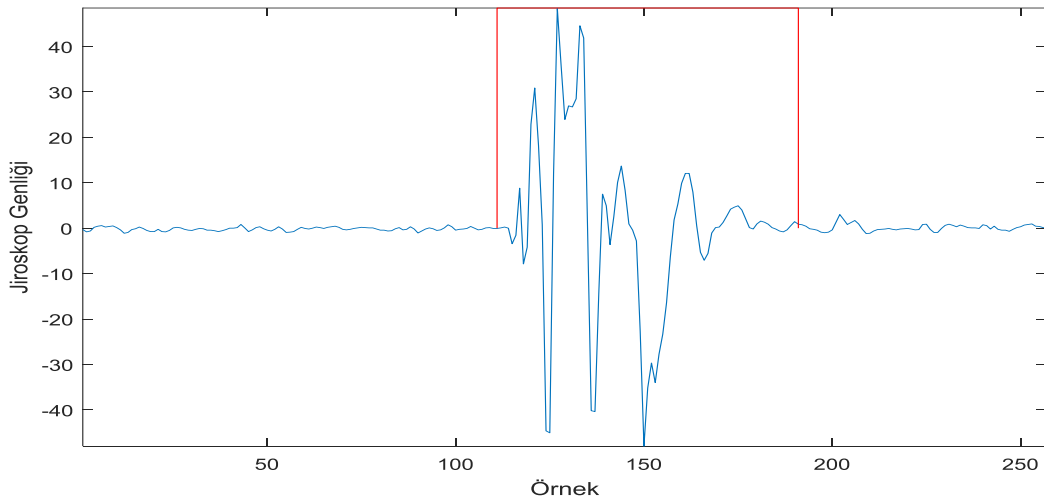


Şekil 3.12. Bir yüzey EMG işaretinde el hareketinin gerçekleştiği aralık

3.3.3. Jiroskop Verilerinin Önışlemesi

Yüzey EMG işaretinde el hareketinin başlangıç ve bitiş anlarının bulunması için kullanılan yöntem jiroskop işareti için de denenmiştir. Fakat hareketin başlangıç ve bitiş anları doğru bir şekilde bulunamamıştır. Bu nedenle yeni bir yöntem arayışına girilmiş ve deneme yanılma yoluyla birçok yöntem tüm veri setinde denenmiştir. En iyi sonucu veren yöntem jiroskop işaretlerinde kullanılmıştır. Bu yöntemde öncelikle

jiroskop işaretinin mutlak değeri alınır. Bu mutlak değerler içerisinde ilk 90 değerin (hareketin olmadığı ilk 2 saniye) en büyüğü eşik kabul edilir. Daha sonra işaret 200 ms uzunluğundaki bitişik pencerelere ayrılarak 2. saniyeden sonraki her bir pencere kontrol edilir. Bu pencereler içerisindeki en büyük değer, eşik değerini geçtiğinde o pencerenin başlangıcı el hareketinin başlangıcı olarak algılanır. El hareketinin başlangıcı algılandıktan sonra ise bu noktadan itibaren pencereler kontrol edilmeye devam edilir. Pencere içerisindeki en büyük değer eşik değerinin altına indiğinde, bu pencerenin başlangıç değeri el hareketinin bitişi kabul edilir. Şekil 3.13’ de bir jiroskop işareti üzerinde bu yöntem ile tespit edilen el hareketi aralığı gösterilmiştir.



Şekil 3.13. Bir jiroskop işaretinde el hareketinin gerçekleştiği aralık


3.4. Pencereleme

Bir yüzey EMG işaretinin anlık değerlerinin doğası gereği rastgele olması nedeniyle sınıflandırıcılar için yararlı bir giriş bilgisi olmadığı kabul edilir. Bu yüzden tanımlayıcı özniteliklerin çıkarılması için veri pencereleri gereklidir. Bu veri pencerelerinin olabildiğince uzun olması kontrol sistemine daha fazla yüzey EMG verisi sağlayacağından daha yüksek sınıflandırma doğruluğuna sahip olması beklenir (Smith et al., 2011). Ancak pencere uzunluğu arttıkça gecikme de artar ve gerçek zamanlı sistem kısıtlamaları nedeniyle pencere uzunluğu 300 ms üzerinde olamaz (Oskoei and Hu, 2007). Bu nedenle hem düşük gecikmeli hem de yeterli yüzey EMG bilgisini içerecek uzunlukta pencereler seçilmelidir.


Pencere uzunluğu seçilirken düşük pencere uzunluğunun tercih edilmesi özniteliklerin varyans değerini artıracığından sınıflandırma performansını düşürür (Englehart and Hudgins, 2003; Oskoei and Hu, 2007). Yapılan çalışmalarda 125 ms’

den daha düşük pencere uzunluğunun yüksek varyansa neden olduğu gözlemlenmiştir (Oskoei and Hu, 2007). Elde edilen bu bilgilerden yararlanılarak bu çalışmada öznitelikler çıkarılırken 150 ms pencere uzunluğu seçilmiştir. Pencere uzunluğu sistem gecikmesi ile de doğrudan bağlantılıdır. Çünkü sistemin gerçek zamanlı çalışabilmesi için 300 ms içerisinde işareti işleyerek sınıflandırma sonucunu elde etmesi gerekir. Bu nedenle pencere uzunluğu ile işaretin işlenmesi için gereken sürenin toplamı 300 ms' nin altında olmalıdır.(Oskoei and Hu, 2007).

Pencereleme iki farklı şekilde yapılabilir: bitişik ve örtüşen pencere. Bitişik pencerede bir pencerenin bittiği yerden diğer pencere başlar. Örtüşen pencerede ise bir pencere bitmeden diğer pencere başlar ve pencereler belli miktarda birbirleriyle örtüşür. Bu iki durum Şekil 3.14 ve Şekil 3.15' de gösterilmiştir.



Şekil 3.14. Bitişik pencereler (Englehart and Hudgins, 2003)



Şekil 3.15. Örtüşmeli pencereler (Englehart and Hudgins, 2003)

Literatür incelendiğinde birçok çalışmada örtüşme miktarının % 50 olarak seçildiği görülmüştür (Akhmadeev et al., 2017; Jun-Uk Chu et al., 2007; J-U Chu et al., 2006; Hassan et al., 2019; Phinyomark and Scheme, 2018; Yang et al., 2017). Bu nedenle bu çalışmada örtüşme miktarı % 50 olarak seçilmiştir.

3.5. Özniteliklerin Çıkarılması

Yüzey EMG ve jiroskop işaretlerinin özniteliklerinin çıkarılması için 20 adet öznitelik kullanılmıştır. Bunlardan 14 tanesi zaman, 6 tanesi ise frekans düzlemi öznitelikleridir. Hem yüzey EMG hem de jiroskop işaretlerinin özniteliklerinin çıkarılmasında aynı eşitlikler kullanılmıştır. Bu nedenle çıkarılan özneliğin yüzey EMG işaretine mi yoksa jiroskop işaretine mi ait olduğunun anlaşılması için belirli kısaltmalar kullanılmıştır. Bu kısaltmalar Tablo 3.1’de gösterilmiştir. Ayrıca yalnızca jiroskop işaretlerinde kullanılan ortalama özneliği için G21 kısaltması kullanılmıştır.

Tablo 3.1. Özniteliklerin kısaltmaları

Öznitelik	EMG Kısaltması	Jiroskop Kısaltması
RMS	F1	G1
MAV	F2	G2
ZC	F3	G3
WL	F4	G4
SSC	F5	G5
VAR	F6	G6
WAMP	F7	G7
AAC	F8	G8
SSI	F9	G9
DASDV	F10	G10
IEMG	F11	G11
MMAV1	F12	G12
MMAV2	F13	G13
MYOP	F14	G14
PKF	F15	G15
MNP	F16	G16
TTP	F17	G17
SM1	F18	G18
SM2	F19	G19
MNF	F20	G20


3.5.1. Zaman Düzlemi Öznitelikleri

Zaman düzlemi öznitelikleri hesaplanırken, bir yüzey EMG işareti pencerelere ayrılır. Pencerelerden elde edilen değerlerle bir öznitelik vektörü elde edilir. Denklemlerdeki N örnek cinsinden pencere uzunluğunu, x kullanımına göre yüzey EMG veya jiroskop işaretinin anlık değerini, i ise kaçınıcı değer ile işlem yapıldığını ifade etmektedir.

3.5.1.1. Karesel Ortalama Kök

Yüzey EMG işaretlerinin işlenmesinde oldukça yaygın kullanılan bir özneliktir. Etkin değer olarak da adlandırılır (Phinyomark et al., 2012). Matematiksel eşitliği aşağıdaki gibidir:

$$RMS = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2} \quad (3.1)$$




Şekil 3.16. Yüzey EMG işaretinin RMS özneliğine ait 8 kanallı örnek çizim

3.5.1.2. Ortalama Mutlak Değer

Yüzey EMG işaretlerinin işlenmesinde yaygın olarak kullanılan bir başka özneliktir (Phinyomark et al., 2012). Öncelikle yüzey EMG değerlerinin mutlak değeri alınır daha sonra ortalama hesaplanır. Matematiksel eşitliği aşağıdaki gibidir:

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




Şekil 3.17. Yüzey EMG işaretinin MAV özneliğine ait 8 kanallı örnek çizim

3.5.1.3. Sıfır Geçişi

Zaman alanında tanımlanan yüzey EMG işaretlerinin frekans bilgisinin bir ölçüsüdür. Yüzey EMG işaretlerinin sıfır genlikten kaç kez geçtiğinin ifade eder (Phinyomark et al., 2012). Matematiksel eşitliği aşağıdaki gibidir:

$$ZC = \sum_{i=1}^{N-1} [sgn(x_i * x_{i+1}) \cap |x_i - x_{i+1}|] \geq eşik \quad (3.3)$$

$$sgn(x) = \begin{cases} 1, & x \geq eşik \\ 0, & x < eşik \end{cases}$$




Şekil 3.18. Yüzey EMG işaretinin ZC özneliğine ait 8 kanallı örnek çizim

3.5.1.4. Dalga Formu Uzunluđu

Yüzey EMG işaretinin karmaşıklığının bir ölçüsüdür. Yüzey EMG dalga formunun bir zaman dilimi içindeki toplam uzunluđu olarak tanımlanır (Phinyomark et al., 2012). Matematiksel eşitliđi aşıđıdaki gibidir:

$$WL = \sum_{i=1}^{N-1} |x_{i+1} - x_i| \quad (3.4)$$




Şekil 3.19. Yüzey EMG işaretinin WL özneliđine ait 8 kanallı örnek çizim

3.5.1.5. Eğim İşareti Deđişikliđi

Yüzey EMG işaretinin eğim işaretinin kaç kez deđiştiđinin ölçüsüdür (Phinyomark et al., 2012). Matematiksel eşitliđi aşıđıdaki gibidir:

$$SSC = \sum_{i=2}^{N-1} [f[(x_i - x_{i-1}) * (x_i - x_{i+1})]] \quad (3.5)$$
$$f(x) = \begin{cases} 1, & x \geq \text{eşik} \\ 0, & x < \text{eşik} \end{cases}$$




Şekil 3.20. Yüzey EMG işaretinin SSC özniteliğine ait 8 kanallı örnek çizim

3.5.1.6. EMG Varyansı

Genel olarak varyans değişkenlerin ortalamadan sapmalarının kare değerlerinin ortalaması olarak tanımlanır. Yüzey EMG işareti için bir güç ölçüsüdür. Ancak yüzey EMG işaretlerinin ortalama değerleri sıfıra yakın olduğu için yüzey EMG varyansı aşağıdaki gibi tanımlanır (Phinyomark et al., 2012):

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




Şekil 3.21. Yüzey EMG işaretinin VAR özneliğine ait 8 kanallı örnek çizim

3.5.1.7. Willison Genliği

Yüzey EMG işaretinin sıfır geçiş özneliğindeki frekans bilgisinin bir ölçüsüdür. Yüzey EMG işaretinde eşik aşan iki bitişik indisin genliği arasındaki farktan kaynaklanır (Phinyomark et al., 2012). Matematiksel eşitliği aşağıdaki gibidir:

$$WAMP = \sum_{i=1}^{N-1} f(|x_i - x_{i+1}|)$$

$$f(x) = \begin{cases} 1, & x \geq \text{eşik} \\ 0, & x < \text{eşik} \end{cases} \quad (3.7)$$




Şekil 3.22. Yüzey EMG işaretinin WAMP özneliğine ait 8 kanallı örnek çizim

3.5.1.8. Ortalama Genlik Değişimi

Dalga formu uzunluğu özneliğine oldukça benzerdir. Yalnızca dalga formu uzunlularının ortalamaları alınır (Phinyomark et al., 2012). Matematiksel eşitliği aşağıdaki gibidir:

$$AAC = \frac{1}{N} \sum_{i=1}^{N-1} |x_{i+1} - x_i| \quad (3.8)$$




Şekil 3.23. Yüzey EMG işaretinin AAC özneliğine ait 8 kanallı örnek çizim

3.5.1.9. Basit Kare İntegrali

Yüzey EMG işaretinin genliklerinin karelerinin toplamıdır. Yüzey EMG işaretinin enerji indeksi olarak tanımlanır (Phinyomark et al., 2012). Matematiksel eşitliği aşağıdaki gibidir:

$$SSI = \sum_{i=1}^N x_i^2 \quad (3.9)$$




Şekil 3.24. Yüzey EMG işaretinin SSI özneliğine ait 8 kanallı örnek çizim

3.5.1.10. Mutlak Standart Sapma Değerlerinin Farkı

Dalga uzunluğunun standart sapma değeridir. RMS özneliğine benzer (Phinyomark et al., 2012). Matematiksel eşitliği aşağıdaki gibidir:

$$DASDV = \sqrt{\frac{1}{N-1} \sum_{i=1}^{N-1} (x_{i+1} - x_i)^2} \quad (3.10)$$




Şekil 3.25. Yüzey EMG işaretinin DASDV özneliğine ait 8 kanallı örnek çizim

3.5.1.11. EMG İntegrali

Yüzey EMG işareti genliklerinin mutlak değerlerinin toplamı olarak tanımlanır. Yüzey EMG işaret dizinin ateşleme noktası ile ilgilidir (Phinyomark et al., 2012). Matematiksel eşitliği aşağıdaki gibidir:

$$IEMG = \sum_{i=1}^N |x_i| \quad (3.11)$$




Şekil 3.26. Yüzey EMG işaretinin IEMG özneliğine ait 8 kanallı örnek çizim

3.5.1.12. Modifiye Edilmiş Ortalama Mutlak Değer Tip 1

Ortalama mutlak değer özneliğinin bir uzantısıdır. Ortalama mutlak değer özneliğinin sağlamlığını artırmak için w_i ağırlık fonksiyonu kullanılır (Phinyomark et al., 2012). Matematiksel eşitliği aşağıdaki gibidir:

$$MMAV1 = \frac{1}{N} \sum_{i=1}^N w_i * |x_i| \quad (3.12)$$
$$w_i = \begin{cases} 1, & 0.25N \leq i \leq 0.75N \\ 0, & \text{diğer durumlar} \end{cases}$$




Şekil 3.27. Yüzey EMG işaretinin MMAV1 özneliğine ait 8 kanallı örnek çizim

3.5.1.13. Modifiye Edilmiş Ortalama Mutlak Değer Tip 2

Modifiye edilmiş ortalama mutlak değer tip 1' in genişletilmiş halidir. Ancak w_i ağırlık fonksiyonu sürekli bir fonksiyondur ve düzgünlüğü artırır (Phinyomark et al., 2012). Matematiksel eşitliği aşağıdaki gibidir:

$$MMAV2 = \frac{1}{N} \sum_{i=1}^N w_i * |x_i| \quad (3.13)$$
$$w_i = \begin{cases} 1, & 0.25N \leq i \leq 0.75N \\ 4i/N, & i \leq 0.25N \\ 4(i - N)/N, & \text{diğer durumlar} \end{cases}$$




Şekil 3.28. Yüzey EMG işaretinin MMAV2 özneliğine ait 8 kanallı örnek çizim

3.5.1.14. Miyo Atım Yüzdilik Oranı

Yüzey EMG işaretinin mutlak değeri, önceden belirlenen bir eşik değerini her aştığında 1 çıkışı üreten miyo atımlarının ortalamasıdır (Phinyomark et al., 2012). Matematiksel eşitliği aşağıdaki gibidir:

$$MYOP = \frac{1}{N} \sum_{i=1}^N f(|x_i|) \quad (3.14)$$

$$f(x) = \begin{cases} 1, & x \geq \text{eşik} \\ 0, & x < \text{eşik} \end{cases}$$



Şekil 3.29. Yüzey EMG işaretinin MYOP özneliğine ait 8 kanallı örnek çizim


3.5.2. Frekans Düzlemi Öznitelikleri

Bir yüzey EMG işaretinin frekans düzlemi öznitelikleri hesaplanırken öncelikle işaret pencerelere ayrılır ve her bir pencereye hamming pencere fonksiyonu uygulanır. Daha sonra tüm pencerelerin güç spektrum yoğunlukları hesaplanır. Güç spektrum yoğunluğu değerleri kullanılarak öznitelikler hesaplanır. Hamming pencere fonksiyonunun kullanılmasının nedeni fourier dönüşümündeki spektral sızıntıların engellenmesidir (Kaya and İnce, 2010). Denklemlerdeki P güç spektrum yoğunluğunu, f frekansı, i ise kaçınıcı değer ile işlem yapıldığını ifade etmektedir.

3.5.2.1. Tepe Frekansı

Maksimum gücün meydana geldiği frekansı belirtir (Phinyomark et al., 2012). Matematiksel eşitliği aşağıdaki gibidir:

$$PKF = \max(P_i) \quad (3.15)$$




Şekil 3.30. Yüzey EMG işaretinin PKF öznitelğine ait 8 kanallı örnek çizim

3.5.2.2. Ortalama Güç

Yüzey EMG güç spektrumunun ortalama gücüdür (Phinyomark et al., 2012). Matematiksel eşitliği aşağıdaki gibidir:

$$MNP = \frac{\sum_{i=1}^N P_i}{N} \quad (3.16)$$




Şekil 3.31. Yüzey EMG işaretinin MNP özneliğine ait 8 kanallı örnek çizim

3.5.2.3. Toplam Güç

Yüzey EMG güç spektrumunun toplamı olarak tanımlanır. Spektral aralık 0 (SM0) olarak da adlandırılır (Phinyomark et al., 2012). Matematiksel eşitliği aşağıdaki gibidir:

$$TTP = \sum_{i=1}^N P_i \quad (3.17)$$




Şekil 3.32. Yüzey EMG işaretinin TTP özneliğine ait 8 kanallı örnek çizim

3.5.2.4. Spektral Aralıklar


Yüzey EMG güç spektrumundan öznitelik elde etmek için kullanılan alternatif istatistiksel metotlardır (Phinyomark et al., 2012). Matematiksel eşitlikleri aşağıdaki gibidir:

$$SM1 = \sum_{i=1}^N P_i f_i \quad (3.18)$$

$$SM2 = \sum_{i=1}^N P_i f_i^2 \quad (3.19)$$



Şekil 3.33. Yüzey EMG işaretinin SM1 özniteliğine ait 8 kanallı örnek çizim




Şekil 3.34. Yüzey EMG işaretinin SM2 özniteliğine ait 8 kanallı örnek çizim

3.5.2.5. Ortalama Frekans

Yüzey EMG güç spektrumlarının ve frekans spektrumlarının toplamının, toplam güç spektrumuna bölünmesiyle elde edilen ortalama bir frekanstır (Phinyomark et al., 2012). Matematiksel eşitliği aşağıdaki gibidir:

$$MNF = \frac{\sum_{i=1}^N P_i f_i}{\sum_{i=1}^N P_i} \quad (3.20)$$



Şekil 3.35. Yüzey EMG işaretinin MNF özniteliğine ait 8 kanallı örnek çizim

3.6. İstatiksel Parametreler

Yüzey EMG verileri elde edilirken, yapılan harekete bağlı olarak az kasılan kasların aynı zamanda daha kısa süre kasılabildiği de görülmüştür. Bu nedenle aynı veriye ait kanallardan elde edilen bir öznitelik vektörünün uzunluğu kanallara göre değişiklik gösterebilmektedir. Bu nedenle elde edilen öznitelik vektörleri istatistiksel parametreler yardımıyla tek bir skaler değere dönüştürülmüştür. Bunlardan ilk üçü: en küçük değer, en büyük değer ve ortanca değerdir. Diğerleri Tablo 3.2’de gösterilmiştir.

Tablo 3.2. İstatiksel Parametreler

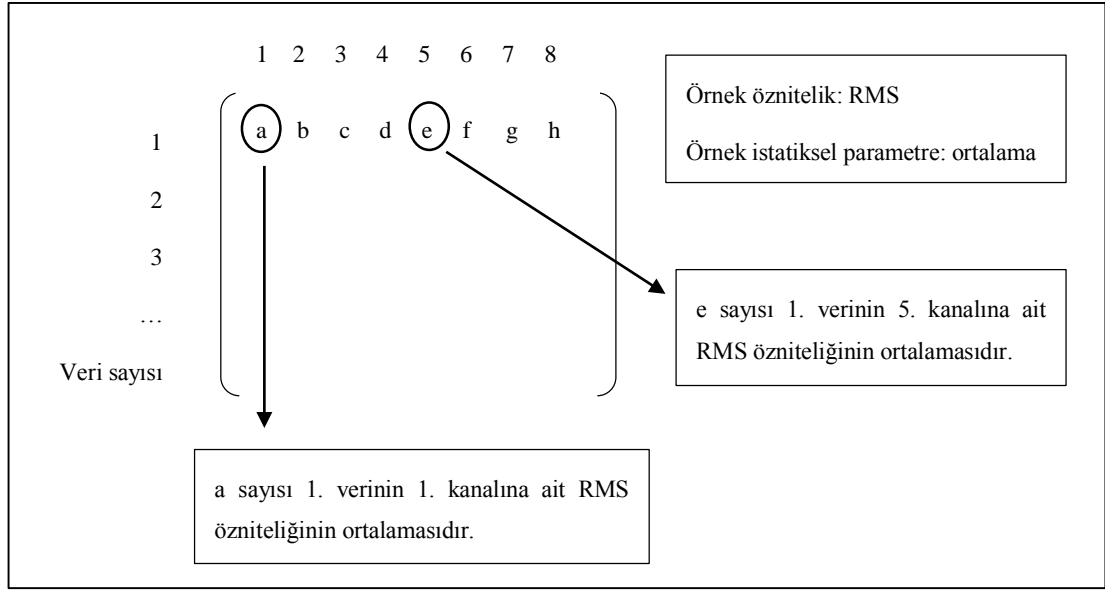
Ortalama	$\bar{x} = \frac{1}{N} \sum_{i=1}^N x_i$
Standart sapma	$\sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2}$
Varyans	$\sigma^2 = \frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2$
Çarpıklık	$S = \frac{1}{N} \sum_{i=1}^N \left[\frac{x_i - \bar{x}}{\sigma} \right]^3$
Basıklık	$K = \frac{1}{N} \sum_{i=1}^N \left[\frac{x_i - \bar{x}}{\sigma} \right]^4$
Etkin değer	$RMS = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2}$

3.7. Öznitelik Matrisinin Oluşturulması

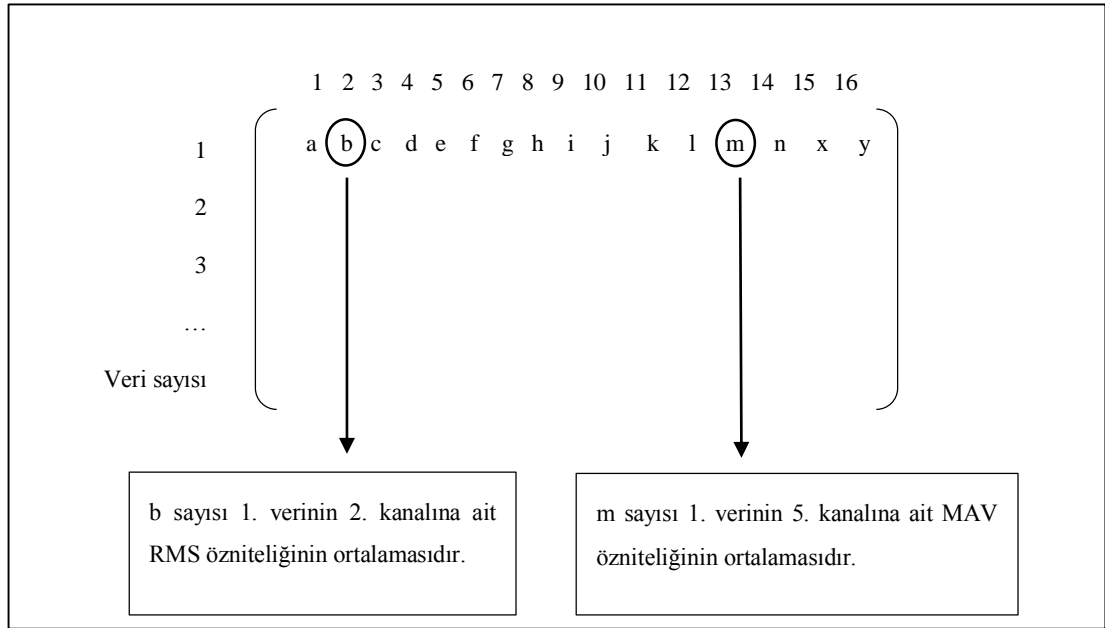
Öznitelik matrisi oluşturulurken ilk verinin ilk kanalına ait bir öznitelik vektörü hesaplanır. Daha sonra bu öznitelik vektörünün elemanları istatiksel parametrelerden bir tanesi kullanılarak skaler bir sayıya dönüştürülür ve öznitelik matrisinin 1. satır 1. sütununa yazılır. Daha sonra aynı işlemler 2. kanala uygulanır ve bulunan sonuç yanına (1. satır 2. sütun) yazılır. Bu işlemler 8 kanal için de uygulanarak 1x8 boyutunda bir matris elde edilmiş olur. Bu ilk veriye ait bir öznitelik matrisidir. Daha sonra 2. veri için aynı işlemler yapılarak 2. satır boyunca yazılır ve öznitelik matrisinin boyutu 2x8 olur. Bu işlemler tüm veri setine uygulandığında bir öznitelikten oluşan öznitelik matrisi elde edilmiş olur. Öznitelik matrisinde daha fazla öznitelik kullanılmak istendiğinde aynı işlemler o öznitelik içinde tekrarlanarak ilk matrisin yanına eklenir.

Genel olarak ifade edilirse, öznitelik matrisinin boyutu veri sayısı, kanal sayısı ve kullanılan öznitelik sayısına bağlıdır. Öznitelik çıkarma ve istatiksel parametreleri uygulama işlemlerinden sonra elde edilen öznitelik matrisinin satır sayısı veri sayısına, sütun sayısı ise kanal sayısı ile kullanılan öznitelik sayısının çarpımına eşittir. Tüm öznitelikleri içeren öznitelik matrisi elde edildikten sonra öznitelik matrisi sekizer sütunluk eşit parçalara bölünerek kullanılan öznitelikler ayrı ayrı sınıflandırılabilir. Şekil 3.36' de özniteliklerden RMS, istatiksel parametrelerden ise ortalama örnek gösterilerek bu süreç şekil üzerinden açıklanmıştır. Şekil 3.37' de birden fazla özniteliği içeren öznitelik matrisinin oluşturulması görsel olarak açıklanmıştır. Örnek

olarak, özniteliklerden RMS ve MAV, istatistiksel parametrelerden ise ortalama kullanılmıştır.



Şekil 3.36. Öznitelik matrisinin oluşturulması



Şekil 3.37. Birden fazla öznitelğin birleştirilmesi

3.8. Sınıflandırma

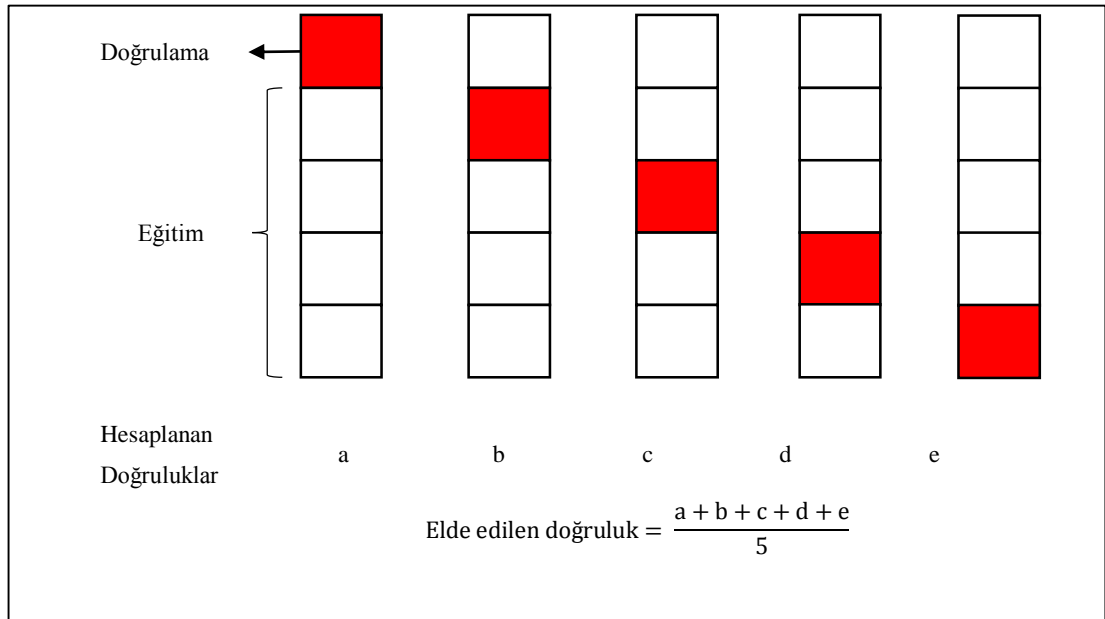
3.8.1. Öznitelik Matrisinin Eğitim ve Test Kümelerine Ayrılması

Yapılan işlemler sonucu elde edilen öznitelik matrisi eğitim ve test kümesi olmak üzere ikiye ayrılmıştır. İkiye ayırma işlemi tek sayılı satırlar eğitim kümesine, çift sayılı satırlar ise test kümesine gidecek şekilde yapılmıştır. Bunun sonucunda

eğitim ve test kümeleri eşit sayıda veri içermektedir. Eğitim kümesindeki veriler kullanılacak sınıflandırma modelini eğitmek için, test kümesindeki veriler ise eğitilen modelin doğruluğunu test etmek için kullanılmıştır. Sınıflandırma süreci için Matlab® içerisinde bulunan sınıflandırma öğreticisi (classificationlearner) uygulaması kullanılmıştır.

3.8.2. K-Fold Çapraz Doğrulama Yöntemi

Bir sınıflandırma algoritmasının performansını tahmin etmek için kullanılan popüler bir yöntemdir (Wong, 2015). K-fold çapraz doğrulamada, orijinal veri kümesi rastgele k adet altkümeye bölünür. K altkümelerden, sınıflandırıcıyı test etmek için doğrulama verileri olarak tek bir altküme tutulur ve kalan k-1 adet altküme eğitim verileri olarak kullanılır. Çapraz doğrulama işlemi daha sonra k kez tekrarlanır ve k altkümelerden her biri birer kez doğrulama verisi olarak kullanılmış olur (Moreno-Torres et al., 2012). Şekil 3.38’ de k = 5 seçilerek yapılan bir k-fold çapraz doğrulama yöntemi şeması ve doğruluğunun hesaplanması gösterilmiştir.




Şekil 3.38. k = 5 için k-fold çapraz doğrulama yöntemi

3.8.3. Destek Vektör Makinesi (SVM)


SVM sınıflandırma problemlerinin çözümünde uygulanacak kuralların üretilmesinde kullanılan bir eğitme algoritmasıdır. SVM’ de sınıfların birbirine en yakın örnekleri (destek vektörleri) bulunur ve bu örneklerin sınıflara uzaklığı maksimum yapılmaya çalışılır (Kazan and Karakoca, 2019). Böylece sınıfları birbirinden ayıracak hiper düzlemler elde edilir (Ayhan and Erdoğan, 2014). Eğitim

verileri kullanarak bulunan hiper düzlemler ile test verileri sınıflandırılır (Zan and Yıldız, 2018). Şekil 3.39’ de destek vektörleri ve sınır düzlemleri ile birlikte bir doğrusal SVM örneği gösterilmiştir.



Şekil 3.39. İki sınıflı birbirinden ayıran doğrusal SVM örneği (Kazan and Karakoca, 2019)


Verilerin doğrusal olarak birbirinden ayrılmaması durumunda verileri ayıracak, doğrusal olmayan bir çizgiye ihtiyaç duyulur. Böyle bir çizgi kullanmak yerine çekirdek fonksiyonlar kullanılarak SVM ayrı bir uzaya taşınır ve daha tutarlı sonuçlar elde edilmeye çalışılır (Aggarwal, 2015; Karakoyun and Hacıbeyoğlu, 2014). Bu tez çalışmasında kullanılan SVM algoritmaları için 3 farklı çekirdek fonksiyonu kullanılmıştır. Bunlardan ikisi ikinci dereceden polinom kullanan Q-SVM ile üçüncü dereceden polinom kullanan C-SVM’ dir. Üçüncüsü ise bir noktadan alınan mesafeye bağlı olan Gaussian çekirdeğidir (M-SVM) (Matworks®, 2020). Çekirdek fonksiyonu kullanarak verilerin ayrı bir uzaya taşınması Şekil 3.40’ da gösterilmiştir.



Şekil 3.40. Çekirdek fonksiyonu kullanarak verilerin ayrı bir uzaya taşınması (Karakoyun and Hacıbeyoğlu, 2014)

3.8.4. K-En Yakın Komşular (KNN)

KNN algoritması sınıflandırma problemlerinin çözümünde sıklıkla kullanılan basit bir yöntemdir (Zan and Yıldız, 2018). KNN' de karşılaşılan test verisi, eğitim kümesindeki örneklerle arasındaki benzerliğe göre sınıflandırılır. Eğitim kümesindeki örnekler n boyutlu örnek uzayda tutulur. Test verisi geldiğinde eğitim kümesindeki örneklerle arasındaki mesafe hesaplanır ve en yakın k tane örneğe bakılır. Çoğunluk hangi sınıfa aitse test verisi de o sınıfa atanır. Çoğunluğun sınıflar için eşit çıkmasının önüne geçilmesi için k değerinin tek sayı seçilmesi gerekmektedir (Okun and Skarlas, 2011; Taşcı and Onan, 2016). Şekil 3.41' de bir KNN örneği, farklı k değerleri için gösterilmiştir.




Şekil 3.41. (a) $k = 1$ (b) $k = 5$ değerleri için KNN örneği (Okun and Skarlas, 2011)

Bu tez çalışmasında 3 farklı KNN algoritması kullanılmıştır. F-KNN algoritmasında k değeri 1 seçilmiştir yani en yakın 1 komşuya bakılmıştır. W-KNN algoritmasında en yakın 10 komşuya bakılmıştır. Bunun yanında test verisine yakınlığa göre ağırlıklar hesaplanmış ve daha yakın olan verilerin ağırlığının daha yüksek olması sağlanmıştır. Ağırlıklar sayesinde k değerinin çift sayı seçilmesinden kaynaklı sorunun önüne geçilmektedir. S-KNN' de ise alt uzaylar kullanılmıştır. Tüm KNN algoritmalarında uzaklık hesabı yapılırken Öklid uzaklığı kullanılmıştır (Matworks®, 2020). Öklid uzaklığına ait eşitlik (3. 21)' de gösterilmiştir. (Hu et al., 2016). Burada $A=(x_1, x_2, \dots, x_m)$ ve $B=(y_1, y_2, \dots, y_m)$ uzaklığı hesaplanacak iki öznitelik vektörü ve m öznitelik vektörünün boyutudur.


$$Uzaklık(A, B) = \sqrt{\frac{\sum_{i=1}^m (x_i - y_i)^2}{m}} \quad (3. 21)$$

3.8.5. Gerçek Zamanlı Sınıflandırma

Bu tez çalışmasında gerçek zamanlı olmayan sınıflandırmanın ardından, veri setinin tamamı eğitim kümesinde kullanılarak sınıflandırma modeli elde edilmiştir. Bu sınıflandırma modeline test verileri gerçek zamanlı gönderilerek sınıflandırma doğrulukları kontrol edilmiştir. Gerçek zamanlı olarak elde edilen yüzey EMG işaretlerinin her 150 ms' lik pencereleri sırasıyla 10 Hz yüksek geçiren filtreden geçirilmiş, öznitelikleri çıkarılmış ve sınıflandırıcıya gönderilmiştir. Yüzey EMG işareti üzerindeki 150 ms uzunluğunda pencereler Şekil 3.42' de, gerçek zamanlı sınıflandırmaya ait akış şeması Şekil 3.43' de gösterilmiştir.



Şekil 3.42. Yüzey EMG işareti üzerinde 150 ms uzunluğundaki pencereler




Şekil 3.43. Gerçek zamanlı sınıflandırma süreci akış şeması

3.9. Ardışıl İleri Yönlü Öznitelik Seçimi

Tüm veri seti için öznitelikler hesaplanıp öznitelik matrisi oluşturulduğunda yüksek boyutlu bir öznitelik matrisi elde edilir. Bu durum hem işlem süresini artırmakta hem de doğruluğu düşürmektedir. Bunun önlenmesi için öznitelik matrisi içerisinde en yüksek doğruluğu veren öznitelikler seçilmelidir. Böylece daha düşük boyutta ve daha yüksek doğruluk veren bir öznitelik matrisi elde edilmiş olur (Phinyomark et al., 2012).

Öznitelik matrisi içerisinde yüksek doğruluk veren özniteliklerin seçilmesinde ardışıl ileri yönlü öznitelik seçimi kullanılmıştır. Bu yöntemin ilk adımında her bir öznitelik için ayrı ayrı sınıflandırılarak doğrulukları incelenir ve en yüksek doğruluğu veren öznitelik veya öznitelikler seçilerek ikinci adıma geçilir. İkinci adımda, seçilen özniteliklerin yanına diğer öznitelikler eklenerek iki öznitelikten oluşan öznitelik setlerinin doğrulukları incelenir. Bu adımda da en yüksek doğruluğu veren öznitelik seti seçilerek sonraki adıma geçilir ve adımlar tüm öznitelikleri içeren öznitelik setine ulaşılana kadar devam eder. Bu şekilde tüm öznitelikler incelenerek en yüksek doğruluğu veren öznitelik seti seçilir (Stańczyk and Jain, 2015). Şekil 3.44' de ardışıl ileri yönlü öznitelik seçimi sürecinde gerçekleştirilen işlemlere ait akış şeması gösterilmiştir.



Şekil 3.44. Ardışıl ileri yönlü öznitelik seçimi akış seması

3.10. Başarım Değerlendirme Ölçütlerinin Hesaplanması

Başarım değerlendirme ölçütleri hesaplanırken öncelikle her bir hareket için TP (Doğru Pozitif), TN (Doğru Negatif), FP (Yanlış Pozitif) ve FN (Yanlış Negatif) sayıları hesaplanmalıdır. Bu sayılar her bir hareket için ayrı ayrı hesaplanır. Bir hareket için hesaplama yapılırken tahmin edilen sınıflara “bu harekettir” önermesi sunulur. Örneğin yumruk hareketini ele aldığımızda tahmin edilen sınıflardan yumruk için “yumruktur”, diğer hareketler içinse “yumruk değildir” önermesi sunulur. Tahmin edilen sınıflar için olumlu önerme yani yumruktur önermesi sunulanlar “pozitif”, olumsuz önerme yani yumruk değildir önermesi sunulanlar ise “negatif” olur. Daha sonra bu önermelerin doğrulukları gerçek sınıflar üzerinden test edilir ve ifade edilen önerme doğruysa “doğru”, yanlışsa “yanlış” olur (Carvajal and Rowe, 2010).

3.10.1. Hassasiyet (Sensitivity)

Bir sınıfa ait verilerin doğru bir şekilde algılanma yeteneğini ifade eder. Doğru pozitif oranı, hatırlama veya algılama olasılığı olarak da adlandırılır. Doğru pozitiflerin, doğru pozitifler ve yanlış negatiflere oranıdır. Her bir sınıf için ayrı ayrı hesaplanır. Daha sonra her bir sınıfın hassasiyet değerlerinin ortalaması alınarak genel hassasiyet değeri elde edilir (Lalkhen and McCluskey, 2008).

$$Hassasiyet = \frac{TP}{TP + FN} \quad (3.22)$$

3.10.2. Özgünlük (Specificity)

Bir sınıfa ait olmayan verilerin doğru bir şekilde algılanma yeteneğini ifade eder. Seçicilik veya doğru negatif oranı olarak da adlandırılır. Doğru negatiflerin, doğru negatif ve yanlış pozitiflere oranıdır. Her bir sınıf için ayrı ayrı hesaplanır. Daha sonra bulunan özgünlük değerlerinin ortalaması alınarak genel özgünlük değeri elde edilir (Lalkhen and McCluskey, 2008).

$$\text{Özgünlük} = \frac{TN}{TN + FP} \quad (3.23)$$

3.10.3. Pozitif Tahmin Değeri (Positive Predictive Value)

Belli bir sınıfa atanan verilerin gerçekten o sınıfa ait olma ihtimalidir. Doğru pozitiflerin, doğru pozitifler ve yanlış pozitiflere oranıdır. Her bir sınıf için ayrı ayrı hesaplanır. Daha sonra bulunan pozitif tahmin değerlerinin ortalaması alınarak genel pozitif tahmin değeri elde edilir (Lalkhen and McCluskey, 2008).

$$PTD = \frac{TP}{TP + FP} \quad (3.24)$$

3.10.4. Negatif Tahmin Değeri (Negative Predictive Value)

Belli bir sınıfa atanmayan verilerin gerçekten de o sınıfa ait olmama ihtimalidir. Doğru negatiflerin, doğru negatifler ve yanlış negatiflere oranıdır. Her bir sınıf için ayrı ayrı hesaplanır. Daha sonra bulunan negatif tahmin değerlerinin ortalaması alınarak genel negatif tahmin değeri elde edilir (Lalkhen and McCluskey, 2008).

$$NTD = \frac{TN}{TN + FN} \quad (3.25)$$

3.10.5. Doğruluk (Accuracy – Correct Rate)

Diğerlerinin aksine her bir sınıf için ayrı ayrı hesaplanmaz, tüm veriler için hesaplanır. Tüm sınıflara ait doğru pozitiflerin toplamının, tüm verilere oranıdır. Ayrıca tüm sınıfların hassasiyet değerlerinin ortalamasına eşittir (Castro et al., 2015).

$$\text{Doğruluk} = \frac{\sum TP}{TP + TN + FP + FN} \quad (3.26)$$

4. BULGULAR 1 – GERÇEK ZAMANLI OLMAYAN UYGULAMA

4.1. Ardışıl İleri Yönlü Öznitelik Seçimi Sonuçları

Yüzey EMG işaretleri işlenirken hem kullanılacak özniteliklerin hem de kullanılacak sınıflandırıcının belirlenmesi amacıyla ardışıl ileri yönlü öznitelik seçimi yapılmıştır. En yüksek doğruluk üçüncü adımda F10+F7+F8 özniteliği ve C-SVM sınıflandırıcısıyla elde edilmiştir. Üçüncü adıma kadar olan doğruluklar Tablo 4.1, Tablo 4.2 ve Tablo 4.3’ de gösterilmiştir. Özniteliklerin gösteriminde kullanılan “+” işareti toplama işlemi değil, özniteliklerin yan yana eklenmesini ifade etmektedir.

Tablo 4.1. Ardışıl ileri yönlü öznitelik seçimi birinci adım

Öznitelikler	Sınıflandırma Doğrulukları (%)					
	Q-SVM	C-SVM	M-SVM	F-KNN	W-KNN	S-KNN
F1	95,90	96,38	95,14	95,62	95,24	95,33
F2	95,33	96,29	95,24	95,81	95,43	95,90
F3	46,29	42,10	48,76	37,52	41,90	41,05
F4	96,00	95,33	94,76	95,24	95,52	94,67
F5	41,14	37,62	42,67	33,05	36,10	35,52
F6	85,33	88,67	84,95	86,76	87,24	90,00
F7	72,67	69,05	73,24	67,81	70,29	65,33
F8	94,48	94,57	94,57	94,86	94,57	94,29
F9	93,14	94,86	92,19	94,00	93,62	94,38
F10	96,48	96,95	95,43	96,19	96,00	96,00
F11	95,81	96,38	95,52	96,10	95,62	95,71
F12	95,90	96,48	95,14	95,52	95,52	95,62
F13	95,33	95,43	95,05	95,24	95,52	95,43
F14	94,57	93,90	94,00	94,19	94,00	93,90
F15	91,90	93,52	91,14	92,48	92,76	93,62
F16	93,03	93,62	91,71	93,62	93,43	94,29
F17	92,86	94,19	91,62	93,90	93,33	94,29
F18	92,48	94,10	91,24	93,81	93,14	93,71
F19	92,57	93,52	90,95	93,33	92,57	93,42
F20	70,19	67,71	70,57	64,38	69,52	67,43


Tablo 4.2. Ardışıl ileri yönlü öznelik seçimi ikinci adım

Öznelikler	Sınıflandırma Doğrulukları (%)					
	Q-SVM	C-SVM	M-SVM	F-KNN	W-KNN	S-KNN
F10+F1	96,10	96,67	95,43	96,29	96,29	97,14
F10+F2	96,48	96,57	95,62	96,48	95,62	97,05
F10+F3	94,86	95,14	93,90	91,05	92,19	65,24
F10+F4	96,38	96,57	95,43	96,00	95,90	95,14
F10+F5	95,05	94,48	93,14	90,38	91,71	68,19
F10+F6	95,71	96,67	94,57	96,57	94,76	96,95
F10+F7	97,05	97,71	96,86	94,29	93,33	80,10
F10+F8	96,67	97,24	96,29	97,43	96,57	96,95
F10+F9	95,81	96,57	95,14	96,00	95,33	95,14
F10+F11	96,48	96,38	95,81	96,38	95,81	96,10
F10+F12	96,38	96,29	95,62	96,57	95,81	96,95
F10+F13	95,62	96,76	96,00	96,67	95,71	96,76
F10+F14	95,81	96,19	95,33	95,81	95,90	96,10
F10+F15	95,62	96,57	94,76	95,90	95,33	96,57
F10+F16	95,90	96,48	95,05	96,19	95,33	96,19
F10+F17	95,81	96,67	95,14	96,38	95,24	96,57
F10+F18	95,81	96,48	94,95	96,67	95,33	96,48
F10+F19	95,71	96,57	94,38	96,76	95,43	94,29
F10+F20	96,38	96,57	95,43	92,95	93,05	81,43

Tablo 4.3. Ardışıl ileri yönlü öznelik seçimi üçüncü adım

Öznelikler	Sınıflandırma Doğrulukları (%)					
	Q-SVM	C-SVM	M-SVM	F-KNN	W-KNN	S-KNN
F10+F7+F1	97,43	97,81	96,95	96,67	95,43	80,67
F10+F7+F2	97,71	97,90	97,14	96,29	95,43	80,95
F10+F7+F3	95,90	95,52	95,62	91,90	93,52	71,71
F10+F7+F4	97,24	97,90	97,14	96,10	95,43	83,24
F10+F7+F5	95,71	96,10	95,14	91,14	94,00	71,90
F10+F7+F6	96,48	96,76	96,19	94,86	93,62	79,33
F10+F7+F8	97,71	98,38	97,14	95,71	94,86	78,86
F10+F7+F9	96,95	97,14	96,19	94,67	94,19	81,24
F10+F7+F11	97,90	97,90	97,14	96,19	95,52	82,76
F10+F7+F12	97,71	97,62	97,05	96,48	95,62	81,33
F10+F7+F13	97,62	98,00	96,86	96,19	95,62	80,76
F10+F7+F14	97,62	97,62	97,71	93,33	96,29	81,24
F10+F7+F15	96,67	96,86	96,57	94,84	93,90	79,24
F10+F7+F16	96,95	97,14	96,57	97,76	94,19	90,19
F10+F7+F17	96,67	91,33	96,48	94,76	94,19	79,81
F10+F7+F18	96,95	97,76	96,48	95,05	93,33	80,57
F10+F7+F19	93,33	97,24	96,57	94,95	93,24	78,29
F10+F7+F20	96,57	96,19	95,52	91,81	91,90	73,43

Ardışıl ileri yönlü öznelik seçiminde tüm adımlar içerisinde elde edilen en yüksek doğrulukları C-SVM sınıflandırıcısı vermiştir. Şekil 4.1' deki grafikte her bir adımda elde edilen en yüksek doğruluklar gösterilmiştir ve değerler C-SVM sınıflandırıcısına aittir. Bu grafikte, bazı adımlarda yerel maksimumlarla karşılaşılrsa da mutlak maksimuma üçüncü adımla ulaşıldığı görülmektedir.



Şekil 4.1. Adımlara göre sınıflandırma doğruluklarının değişimi

4.2. Elde Edilen Başarımlar

Öznitelik seçimi sonucunda % 98,38' lik en yüksek doğrulukla seçilen, F10+F7+F8 özniteliği ve C-SVM sınıflandırıcısı ile elde edilen karmaşıklık matrisi Tablo 4.4' de gösterilmiştir. Karmaşıklık matrisi üzerinden tüm hareketlere ait başarımlar hesaplanmıştır. Ayrıca bu öznitelik kullanılarak veri setindeki tüm kişiler için ayrı ayrı sınıflandırma doğrulukları incelenmiştir. Elde edilen doğruluklar Tablo 4.5' de gösterilmiştir.

Tablo 4.4. Karmaşıklık matrisi

		Tahmin Edilen Sınıflar						
		YUM	PA	BİB	BDB	PRO	SPN	DN
Gerçek Sınıflar	YUM	148	0	2	0	0	0	0
	PA	0	150	0	0	0	0	0
	BİB	1	0	149	0	0	0	0
	BDB	0	0	0	149	0	1	0
	PRO	0	0	0	1	138	11	0
	SPN	0	0	0	0	1	149	0
	DN	0	0	0	0	0	0	150

Tablo 4.5. Her bir kişi için elde edilen doğruluk yüzdeleri

Kişi	Q-SVM	C-SVM	M-SVM	F-KNN	W-KNN	S-KNN
1. kişi	99,05	99,05	98,1	96,19	84,76	88,57
2. kişi	100	100	100	97,14	97,14	86,67
3. kişi	100	100	100	100	100	83,81
4. kişi	100	100	98,1	97,14	94,29	78,1
5. kişi	99,05	99,05	100	98,1	96,19	86,67
6. kişi	100	100	100	100	99,05	91,43
7. kişi	100	99,05	99,05	100	99,05	88,57
8. kişi	100	100	100	100	100	87,62
9. kişi	98,1	96,19	100	96,19	95,24	82,86
10. kişi	96,19	95,24	97,14	96,19	95,24	83,81
Ortalama	99,23	98,85	99,23	98,1	96,1	85,81
Tüm veri seti	97,71	98,38	97,14	95,71	94,86	78,86

4.2.1. Yumruk Başarımları

Tablo 4.6' da karmaşıklık matrisi üzerinden yumruk hareketine ait TP, TN, FP ve FN değerleri gösterilmiştir. Buradan TP = 148, TN= 899, FP = 1 ve FN = 2 bulunmuştur. Bu değerler üzerinden hassasiyet, özgünlük, pozitif tahmin değeri ve negatif tahmin değeri hesaplanmıştır.

Tablo 4.6. Yumruk hareketi TP, TN, FP, FN değerleri

		Tahmin Edilen Sınıflar						
		Yumruktur	Yumruk değildir					
		YUM	PA	BİB	BDB	PRO	SPN	DN
Gerçek Sınıflar	YUM	148 (TP)	0 (FN)	2 (FN)	0 (FN)	0 (FN)	0 (FN)	0 (FN)
	PA	0 (FP)	150 (TN)	0 (TN)	0 (TN)	0 (TN)	0 (TN)	0 (TN)
	BİB	1 (FP)	0 (TN)	149 (TN)	0 (TN)	0 (TN)	0 (TN)	0 (TN)
	BDB	0 (FP)	0 (TN)	0 (TN)	149 (TN)	0 (TN)	1 (TN)	0 (TN)
	PRO	0 (FP)	0 (TN)	0 (TN)	1 (TN)	138 (TN)	11 (TN)	0 (TN)
	SPN	0 (FP)	0 (TN)	0 (TN)	0 (TN)	1 (TN)	149 (TN)	0 (TN)
	DN	0 (FP)	0 (TN)	0 (TN)	0 (TN)	0 (TN)	0 (TN)	150 (TN)

$$\text{Hassasiyet} = 148 / (148 + 2) = 0,9867$$

$$\text{Özgünlük} = 899 / (899 + 1) = 0,9989$$

$$\text{Pozitif Tahmin Değeri} = 148 / (148 + 1) = 0,9933$$

$$\text{Negatif Tahmin Değeri} = 899 / (899 + 2) = 0,9978$$

4.2.2. Parmak Açma Başarımları

Tablo 4.7' de karmaşıklık matrisi üzerinden parmak açma hareketine ait TP, TN, FP ve FN değerleri gösterilmiştir. Buradan TP = 150, TN= 900, FP = 0 ve FN = 0 bulunmuştur. Bu değerler üzerinden hassasiyet, özgünlük, pozitif tahmin değeri ve negatif tahmin değeri hesaplanmıştır.

Tablo 4.7. Parmak açma hareketi TP, TN, FP, FN değerleri

		Tahmin Edilen Sınıflar						
		Parmak açma değildir	Parmak açmadır	Parmak açma değildir				
		YUM	PA	BİB	BDB	PRO	SPN	DN
Gerçek Sınıflar	YUM	148 (TN)	0 (FP)	2 (TN)	0 (TN)	0 (TN)	0 (TN)	0 (TN)
	PA	0 (FN)	150 (TP)	0 (FN)	0 (FN)	0 (FN)	0 (FN)	0 (FN)
	BİB	1 (TN)	0 (FP)	149 (TN)	0 (TN)	0 (TN)	0 (TN)	0 (TN)
	BDB	0 (TN)	0 (FP)	0 (TN)	149 (TN)	0 (TN)	1 (TN)	0 (TN)
	PRO	0 (TN)	0 (FP)	0 (TN)	1 (TN)	138 (TN)	11 (TN)	0 (TN)
	SPN	0 (TN)	0 (FP)	0 (TN)	0 (TN)	1 (TN)	149 (TN)	0 (TN)
	DN	0 (TN)	0 (FP)	0 (TN)	0 (TN)	0 (TN)	0 (TN)	150 (TN)

$$\text{Hassasiyet} = 150 / (150 + 0) = 1$$

$$\text{Özgünlük} = 900 / (900 + 0) = 1$$

$$\text{Pozitif Tahmin Değeri} = 150 / (150 + 0) = 1$$

$$\text{Negatif Tahmin Değeri} = 900 / (900 + 0) = 1$$

4.2.3. Bilek İçeri Bükme Başarımları

Tablo 4.8' de karmaşıklık matrisi üzerinden bilek içeri bükme hareketine ait TP, TN, FP ve FN değerleri gösterilmiştir. Buradan TP = 149, TN= 898, FP = 2 ve FN = 1 bulunmuştur. Bu değerler üzerinden hassasiyet, özgünlük, pozitif tahmin değeri ve negatif tahmin değeri hesaplanmıştır.

Tablo 4.8. Bilek içeri bükme hareketi TP, TN, FP, FN değerleri

		Tahmin Edilen Sınıflar						
		Bilek içeri bükme değildir		Bilek içeri bükmedir	Bilek içeri bükme değildir			
		YUM	PA	BİB	BDB	PRO	SPN	DN
Gerçek Sınıflar	YUM	148 (TN)	0 (TN)	2 (FP)	0 (TN)	0 (TN)	0 (TN)	0 (TN)
	PA	0 (TN)	150 (TN)	0 (FP)	0 (TN)	0 (TN)	0 (TN)	0 (TN)
	BİB	1 (FN)	0 (FN)	149 (TP)	0 (FN)	0 (FN)	0 (FN)	0 (FN)
	BDB	0 (TN)	0 (TN)	0 (FP)	149 (TN)	0 (TN)	1 (TN)	0 (TN)
	PRO	0 (TN)	0 (TN)	0 (FP)	1 (TN)	138 (TN)	11 (TN)	0 (TN)
	SPN	0 (TN)	0 (TN)	0 (FP)	0 (TN)	1 (TN)	149 (TN)	0 (TN)
	DN	0 (TN)	0 (TN)	0 (FP)	0 (TN)	0 (TN)	0 (TN)	150 (TN)

$$\text{Hassasiyet} = 149 / (149 + 1) = 0,9933$$

$$\text{Özgünlük} = 898 / (898 + 2) = 0,9978$$

$$\text{Pozitif Tahmin Değeri} = 149 / (149 + 2) = 0,9868$$

$$\text{Negatif Tahmin Değeri} = 898 / (898 + 1) = 0,9989$$

4.2.4. Bilek Dışarı Bükme Başarımları

Tablo 4.9’ da karmaşıklık matrisi üzerinden bilek dışarı bükme hareketine ait TP, TN, FP ve FN değerleri gösterilmiştir. Buradan TP = 149, TN = 899, FP = 1 ve FN = 1 bulunmuştur. Bu değerler üzerinden hassasiyet, özgünlük, pozitif tahmin değeri ve negatif tahmin değeri hesaplanmıştır.

Tablo 4.9. Bilek dışarı bükme hareketi TP, TN, FP, FN değerleri

		Tahmin Edilen Sınıflar						
		Bilek dışarı bükme değildir			Bilek dışarı bükmedir	Bilek dışarı bükme değildir		
		YUM	PA	BİB	BDB	PRO	SPN	DN
Gerçek Sınıflar	YUM	148 (TN)	0 (TN)	2 (TN)	0 (FP)	0 (TN)	0 (TN)	0 (TN)
	PA	0 (TN)	150 (TN)	0 (TN)	0 (FP)	0 (TN)	0 (TN)	0 (TN)
	BİB	1 (TN)	0 (TN)	149 (TN)	0 (FP)	0 (TN)	0 (TN)	0 (TN)
	BDB	0 (FN)	0 (FN)	0 (FN)	149 (TP)	0 (FN)	1 (FN)	0 (FN)
	PRO	0 (TN)	0 (TN)	0 (TN)	1 (FP)	138 (TN)	11 (TN)	0 (TN)
	SPN	0 (TN)	0 (TN)	0 (TN)	0 (FP)	1 (TN)	149 (TN)	0 (TN)
	DN	0 (TN)	0 (TN)	0 (TN)	0 (FP)	0 (TN)	0 (TN)	150 (TN)

$$\text{Hassasiyet} = 149 / (149 + 1) = 0,9933$$

$$\text{Özgünlük} = 899 / (899 + 1) = 0,9989$$

$$\text{Pozitif Tahmin Değeri} = 149 / (149 + 1) = 0,9933$$

$$\text{Negatif Tahmin Değeri} = 899 / (899 + 1) = 0,9989$$

4.2.5. Pronasyon Başarımları

Tablo 4.10’ da karmaşıklık matrisi üzerinden pronasyon hareketine ait TP, TN, FP ve FN değerleri gösterilmiştir. Buradan TP = 138, TN = 899, FP = 1 ve FN = 12 bulunmuştur. Bu değerler üzerinden hassasiyet, özgünlük, pozitif tahmin değeri ve negatif tahmin değeri hesaplanmıştır.

Tablo 4.10. Pronasyon hareketi TP, TN, FP, FN değerleri

		Tahmin Edilen Sınıflar						
		Pronasyon değildir				Pronasyondur	Pronasyon değildir	
		YUM	PA	BİB	BDB	PRO	SPN	DN
Gerçek Sınıflar	YUM	148 (TN)	0 (TN)	2 (TN)	0 (TN)	0 (FP)	0 (TN)	0 (TN)
	PA	0 (TN)	150 (TN)	0 (TN)	0 (TN)	0 (FP)	0 (TN)	0 (TN)
	BİB	1 (TN)	0 (TN)	149 (TN)	0 (TN)	0 (FP)	0 (TN)	0 (TN)
	BDB	0 (TN)	0 (TN)	0 (TN)	149 (TN)	0 (FP)	1 (TN)	0 (TN)
	PRO	0 (FN)	0 (FN)	0 (FN)	1 (FN)	138 (TP)	11 (FN)	0 (FN)
	SPN	0 (TN)	0 (TN)	0 (TN)	0 (TN)	1 (FP)	149 (TN)	0 (TN)
	DN	0 (TN)	0 (TN)	0 (TN)	0 (TN)	0 (FP)	0 (TN)	150 (TN)

$$\text{Hassasiyet} = 138 / (138 + 12) = 0,9200$$

$$\text{Özgünlük} = 899 / (899 + 1) = 0,9989$$

$$\text{Pozitif Tahmin Değeri} = 138 / (138 + 1) = 0,9928$$

$$\text{Negatif Tahmin Değeri} = 899 / (899 + 12) = 0,9868$$

4.2.6. Supinasyon Başarımları

Tablo 4.11’ de karmaşıklık matrisi üzerinden supinasyon hareketine ait TP, TN, FP ve FN değerleri gösterilmiştir. Buradan TP = 149, TN = 888, FP = 12 ve FN = 1 bulunmuştur. Bu değerler üzerinden hassasiyet, özgünlük, pozitif tahmin değeri ve negatif tahmin değeri hesaplanmıştır.

Tablo 4.11. Supinasyon hareketi TP, TN, FP, FN değerleri

		Tahmin Edilen Sınıflar						
		Supinasyon değildir					Supinasyondur	Supinasyon değildir
		YUM	PA	BİB	BDB	PRO	SPN	DN
Gerçek Sınıflar	YUM	148 (TN)	0 (TN)	2 (TN)	0 (TN)	0 (TN)	0 (FP)	0 (TN)
	PA	0 (TN)	150 (TN)	0 (TN)	0 (TN)	0 (TN)	0 (FP)	0 (TN)
	BİB	1 (TN)	0 (TN)	149 (TN)	0 (TN)	0 (TN)	0 (FP)	0 (TN)
	BDB	0 (TN)	0 (TN)	0 (TN)	149 (TN)	0 (TN)	1 (FP)	0 (TN)
	PRO	0 (TN)	0 (TN)	0 (TN)	1 (TN)	138 (TN)	11 (FP)	0 (TN)
	SPN	0 (FN)	0 (FN)	0 (FN)	0 (FN)	1 (FN)	149 (TP)	0 (FN)
	DN	0 (TN)	0 (TN)	0 (TN)	0 (TN)	0 (TN)	0 (FP)	150 (TN)

$$\text{Hassasiyet} = 149 / (149 + 1) = 0,9933$$

$$\text{Özgünlük} = 888 / (888 + 12) = 0,9867$$

$$\text{Pozitif Tahmin Değeri} = 149 / (149 + 12) = 0,9198$$

$$\text{Negatif Tahmin Değeri} = 888 / (888 + 1) = 0,9989$$

4.2.7. Dinlenme Başarımları

Tablo 4.12’ de karmaşıklık matrisi üzerinden dinlenme hareketine ait TP, TN, FP ve FN değerleri gösterilmiştir. Buradan TP = 150, TN = 900, FP = 0 ve FN = 0 bulunmuştur. Bu değerler üzerinden hassasiyet, özgünlük, pozitif tahmin değeri ve negatif tahmin değeri hesaplanmıştır.

Tablo 4.12. Dinlenme hareketi TP, TN, FP, FN değerleri

		Tahmin Edilen Sınıflar						
		Dinlenme değildir						Dinlenmedir
		YUM	PA	BİB	BDB	PRO	SPN	DN
Gerçek Sınıflar	YUM	148 (TN)	0 (TN)	2 (TN)	0 (TN)	0 (TN)	0 (TN)	0 (FP)
	PA	0 (TN)	150 (TN)	0 (TN)	0 (TN)	0 (TN)	0 (TN)	0 (FP)
	BİB	1 (TN)	0 (TN)	149 (TN)	0 (TN)	0 (TN)	0 (TN)	0 (FP)
	BDB	0 (TN)	0 (TN)	0 (TN)	149 (TN)	0 (TN)	1 (TN)	0 (FP)
	PRO	0 (TN)	0 (TN)	0 (TN)	1 (TN)	138 (TN)	11 (TN)	0 (FP)
	SPN	0 (TN)	0 (TN)	0 (TN)	0 (TN)	1 (TN)	149 (TN)	0 (FP)
	DN	0 (FN)	0 (FN)	0 (FN)	0 (FN)	0 (FN)	0 (FN)	150 (TP)

$$\text{Hassasiyet} = 150 / (150 + 0) = 1$$

$$\text{Özgünlük} = 900 / (900 + 0) = 1$$

$$\text{Pozitif Tahmin Değeri} = 150 / (150 + 0) = 1$$

$$\text{Negatif Tahmin Değeri} = 900 / (900 + 0) = 1$$

4.2.8. Ortalama Başarımlar

Her bir hareket için ayrı ayrı hesaplanan başarımlar ve en alt satırda bunların ortalamaları Tablo 4.13' de gösterilmiştir. Yapılan hesaplamalar sonucunda tüm hareketler için ortalama % 98,38 hassasiyet, % 99,73 özgünlük, % 98,37 pozitif tahmin değeri, % 99,73 negatif tahmin değeri elde edilmiştir. Burada tüm hareketlerin ortalama hassasiyetinin doğruluk değerine eşit olduğu görülmektedir.

Tablo 4.13. Ortalama başarımlar

	Hassasiyet (%)	Özgünlük (%)	Pozitif Tahmin Değeri (%)	Negatif Tahmin Değeri (%)
YUM	98,67	99,89	99,33	99,78
PA	100	100	100	100
BİB	99,33	99,78	98,68	99,89
BDB	99,33	99,89	99,33	99,89
PRO	92	99,89	99,28	98,68
SPN	99,33	98,67	91,98	99,89
DN	100	100	100	100
Ortalama	98,38	99,73	98,37	99,73

4.3. Kişi Başına Elde Edilen Başarımlar

Veri setindeki her bir kişi için tüm hareketlere ait başarımlar ayrı ayrı hesaplanmıştır. Elde edilen sonuçlar Tablo 4.14, Tablo 4.15, Tablo 4.16, Tablo 4.17, Tablo 4.18, Tablo 4.19, Tablo 4.20, Tablo 4.21, Tablo 4.22 ve Tablo 4.23' de gösterilmiştir.

Tablo 4.14. Birinci kiři için elde edilen bařarımlar

	Hassasiyet (%)	Özgünlük (%)	Pozitif Tahmin Deęeri (%)	Negatif Tahmin Deęeri (%)
YUM	100	100	100	100
PA	100	100	100	100
BİB	100	100	100	100
BDB	100	100	100	100
PRO	93,33	100	100	98,9
SPN	100	98,89	93,75	100
DN	100	100,00	100,00	100
Ortalama	99,05	99,84	99,11	99,84

Tablo 4.15. İkinci kiři için elde edilen bařarımlar

	Hassasiyet (%)	Özgünlük (%)	Pozitif Tahmin Deęeri (%)	Negatif Tahmin Deęeri (%)
YUM	100	100	100	100
PA	100	100	100	100
BİB	100	100	100	100
BDB	100	100	100	100
PRO	100	100	100	100
SPN	100	100	100	100
DN	100	100	100	100
Ortalama	100	100	100	100

Tablo 4.16. Üçüncü kiři için elde edilen bařarımlar

	Hassasiyet (%)	Özgünlük (%)	Pozitif Tahmin Deęeri (%)	Negatif Tahmin Deęeri (%)
YUM	100	100	100	100
PA	100	100	100	100
BİB	100	100	100	100
BDB	100	100	100	100
PRO	100	100	100	100
SPN	100	100	100	100
DN	100	100	100	100
Ortalama	100	100	100	100

Tablo 4.17. Dördüncü kiři için elde edilen bařarımlar

	Hassasiyet (%)	Özgünlük (%)	Pozitif Tahmin Deęeri (%)	Negatif Tahmin Deęeri (%)
YUM	100	100	100	100
PA	100	100	100	100
BİB	100	100	100	100
BDB	100	100	100	100
PRO	100	100	100	100
SPN	100	100	100	100
DN	100	100	100	100
Ortalama	100	100	100	100

Tablo 4.18. Beşinci kişi için elde edilen başarımlar

	Hassasiyet (%)	Özgünlük (%)	Pozitif Tahmin Değeri (%)	Negatif Tahmin Değeri (%)
YUM	100	100	100	100
PA	100	100	100	100
BİB	100	100	100	100
BDB	100	100	100	100
PRO	93,33	100	100	98,9
SPN	100	98,89	93,75	100
DN	100	100	100	100
Ortalama	99,05	99,84	99,11	99,84

Tablo 4.19. Altıncı kişi için elde edilen başarımlar

	Hassasiyet (%)	Özgünlük (%)	Pozitif Tahmin Değeri (%)	Negatif Tahmin Değeri (%)
YUM	100	100	100	100
PA	100	100	100	100
BİB	100	100	100	100
BDB	100	100	100	100
PRO	100	100	100	100
SPN	100	100	100	100
DN	100	100	100	100
Ortalama	100	100	100	100

Tablo 4.20. Yedinci kişi için elde edilen başarımlar

	Hassasiyet (%)	Özgünlük (%)	Pozitif Tahmin Değeri (%)	Negatif Tahmin Değeri (%)
YUM	100	100	100	100
PA	100	100	100	100
BİB	100	100	100	100
BDB	100	100	100	100
PRO	93,33	100	100	98,9
SPN	100	98,89	93,75	100
DN	100	100	100	100
Ortalama	99,05	99,84	99,11	99,84

Tablo 4.21. Sekizinci kişi için elde edilen başarımlar

	Hassasiyet (%)	Özgünlük (%)	Pozitif Tahmin Değeri (%)	Negatif Tahmin Değeri (%)
YUM	100	100	100	100
PA	100	100	100	100
BİB	100	100	100	100
BDB	100	100	100	100
PRO	100	100	100	100
SPN	100	100	100	100
DN	100	100	100	100
Ortalama	100	100	100	100

Tablo 4.22. Dokuzuncu kişi için elde edilen başarımlar

	Hassasiyet (%)	Özgünlük (%)	Pozitif Tahmin Değeri (%)	Negatif Tahmin Değeri (%)
YUM	73,33	100	100	95,74
PA	100	100	100	100
BİB	100	95,56	78,95	100
BDB	100	100	100	100
PRO	100	100	100	100
SPN	100	100	100	100
DN	100	100	100	100
Ortalama	96,19	99,37	96,99	99,39

Tablo 4.23. Onuncu kişi için elde edilen başarımlar

	Hassasiyet (%)	Özgünlük (%)	Pozitif Tahmin Değeri (%)	Negatif Tahmin Değeri (%)
YUM	93,33	100	100	98,9
PA	100	98,89	93,75	100
BİB	100	98,89	93,75	100
BDB	93,33	100	100	98,9
PRO	80	100	100	96,77
SPN	100	96,67	83,33	100
DN	100	100	100	100
Ortalama	95,24	99,21	95,83	99,22

4.4. Farklı Pencere Uzunluklarının, İstatiksel Parametrelerin ve Kas Aktivasyon Bölgesi Bulma Yöntemlerinin Karşılaştırılması

Bu çalışmada yüzey EMG verileri işlenirken 150 ms pencere uzunluğu seçilerek öznetelikler çıkarılmış ve öznetelik vektörlerinin skaler bir değere dönüştürülmesinde ortalama kullanılmıştır. Ancak diğer pencere uzunluklarının ve istatiksel parametrelerin etkileri de gözlemlenmiştir. Elde edilen sonuçlar Tablo 4.24 ve Tablo 4.25’ de gösterilmiştir. Ayrıca literatürdeki bazı çalışmalarda kullanılan kas aktivasyon bölgesi bulma yöntemleri de bu çalışmadaki veri setinde denenmiş ve elde edilen sonuçlar Tablo 4.26’ da gösterilmiştir.

Tablo 4.24. Farklı pencere uzunluklarının karşılaştırılması

Öznetelik	50 ms	100 ms	150 ms	200 ms	250 ms
F10+F7+F8	97,71	97,62	98,38	97,43	96,95

Tablo 4.25. Farklı istatiksel parametrelerin karşılaştırılması

Öznetelik	min	max	ortanca değer	\bar{x}	σ	σ^2	S	K	RMS
F10+F7+F8	96,86	98	98	98,38	96,19	93,9	14	14,29	98,1

Tablo 4.26. Farklı kas aktivasyon bölgesi bulma yöntemleri ile elde edilen bulgular


Çalışma	Doğruluk (%)
(Wahid et al., 2018)	89,05
(Yang et al., 2017)	40,1

4.5. Jiroskop Verilerinin Eklenmesi ve Özniteliklerinin Karşılaştırılması

Yüzey EMG verilerinin sınıflandırılmasında jiroskop verilerinin sınıflandırma performansına etkisi hem F10 hem de F10+F7+F8 öznitelik seti için kontrol edilmiştir. Jiroskop verileri işlenerek yüzey EMG öznitelik matrisinin son sütununa eklenmiştir. Jiroskop verilerinde hangi özniteliklerin kullanılacağına karar vermek için tüm öznitelikler denenmiştir. Elde edilen sonuçlar F10 özniteliği (bir yüzey EMG özniteliği) için Tablo 4.27 ve Şekil 4.2' de, F10+F7+F8 özniteliği (üç yüzey EMG özniteliği) için Tablo 4.28 ve Şekil 4.3' de gösterilmiştir. Jiroskop verileri bir yüzey EMG özniteliği için kullanıldığında zaman düzleminden G9, frekans düzleminden G15 en yüksek doğruluğu vermiştir. Üç öznitelikte ise zaman düzleminde G6, frekans düzleminde G19 en yüksek doğruluğu vermiştir. Şekil 4.4, Şekil 4.5, Şekil 4.6, Şekil 4.7' de en yüksek doğruluk veren jiroskop özniteliklerinin grafiksel çizimleri gösterilmiştir.

Tablo 4.27. Bir yüzey EMG özniteliği için jiroskop özniteliklerinin sınıflandırma doğrulukları


Öznitelik	Sınıflandırma Doğruluğu (%)
F10	96,95
F10+G1	97,71
F10+G2	97,71
F10+G3	96,29
F10+G4	97,52
F10+G5	96,57
F10+G6	97,43
F10+G7	96,38
F10+G8	96,95
F10+G9	98,00
F10+G10	96,86
F10+G11	97,62
F10+G12	97,52
F10+G13	97,62
F10+G14	96,67
F10+G15	98,00
F10+G16	97,81
F10+G17	97,81
F10+G18	97,90
F10+G19	97,62
F10+G20	96,10
F10+G21	96,85




Şekil 4.2. Bir yüzey EMG özniteliği için jirosop özniteliklerinin sınıflandırma doğruluk değişimleri

Tablo 4.28. Üç yüzey EMG özniteliği için jiroskop özniteliklerinin sınıflandırma doğrulukları


Öznitelik	Sınıflandırma Doğruluğu (%)
F10+F7+F8	98,38
F10+F7+F8+G1	97,71
F10+F7+F8+G2	97,71
F10+F7+F8+G3	97,43
F10+F7+F8+G4	97,81
F10+F7+F8+G5	97,90
F10+F7+F8+G6	98,10
F10+F7+F8+G7	97,81
F10+F7+F8+G8	98,00
F10+F7+F8+G9	97,90
F10+F7+F8+G10	98,00
F10+F7+F8+G11	97,71
F10+F7+F8+G12	97,62
F10+F7+F8+G13	97,71
F10+F7+F8+G14	98,00
F10+F7+F8+G15	97,71
F10+F7+F8+G16	97,90
F10+F7+F8+G17	97,90
F10+F7+F8+G18	97,90
F10+F7+F8+G19	98,19
F10+F7+F8+G20	97,24
F10+F7+F8+G21	98,10




Şekil 4.3. Üç yüzey EMG özneteliği için jirosop özneteliklerinin sınıflandırma doğruluk değişimleri




Şekil 4.4. G9 özneteliği grafiksel gösterimi



Şekil 4.5. G15 özneteliği grafiksel gösterimi



Şekil 4.6. G6 özniteliği grafiksel gösterimi



Şekil 4.7. G19 özniteliği grafiksel gösterimi

4.6. Kullanılan Kanal Sayısının Azaltılması

Sekiz kanal olarak elde edilen yüzey EMG işaretlerinde, daha az sayıda kanal kullanıldığında elde edilen sınıflandırma doğrulukları incelenmiştir. En az iki kanaldan başlayarak yedi kanala kadar kullanılacak tüm kombinasyonlar kontrol edilmiştir. Kanal azaltımı hem tek öznitelikte en yüksek doğruluğu veren F10 için hem de ardışıl ileri yönlü öznitelik seçimi sonucunda en yüksek doğruluğu veren F10+F7+F8 özniteliği için yapılmıştır. Ayrıca tüm kanal kombinasyonları için jiroskop özniteliklerinin eklenmesiyle elde edilen doğruluklar da incelenmiştir. F10 özniteliği için elde edilen sonuçlar Tablo 4.29, Tablo 4.30, Tablo 4.31, Tablo 4.32, Tablo 4.33 ve Tablo 4.34' de gösterilmiştir. Bu tablolarda % Fark 1 F10+G9 öznitelisinin doğruluğu ile F10 öznitelisinin doğruluğu arasındaki yüzdelik farktır. %

Fark 2 ise F10+G15 özniteliğinin doğruluğu ile F10 özniteliğinin doğruluğu arasındaki yüzdellik farktır. F10+F7+F8 özniteliği için elde edilen doğruluklar Tablo 4.35, Tablo 4.36, Tablo 4.37, Tablo 4.38, Tablo 4.39 ve Tablo 4.40’ da gösterilmiştir. Bu tablolarda % Fark 1 F10+F7+F8+G6 özniteliğinin doğruluğu ile F10+F7+F8 özniteliğinin doğruluğu arasındaki yüzdellik farktır. % Fark 2 ise F10+F7+F8+G19 özniteliğinin doğruluğu ile F10+F7+F8 özniteliğinin doğruluğu arasındaki yüzdellik farktır. Tüm bu işlemler sonucunda elde edilen en yüksek doğruluklar F10 için Tablo 4.41 ve Şekil 4.8’ de gösterilmiştir. F10+F7+F8 içinse Tablo 4.42 ve Şekil 4.9’ da gösterilmiştir.

Tablo 4.29. Bir yüzey EMG özniteliği ve iki kanal ile elde edilen sınıflandırma doğruluk yüzdeleri

Kanallar	F10	F10+G9	% Fark 1	F10+G15	% Fark 2
1,2	43,90	72,57	28,67	72,67	28,77
1,3	68,38	79,52	11,14	75,71	7,33
1,4	72,67	81,33	8,67	81,43	8,76
1,5	69,81	76,86	7,05	76,95	7,14
1,6	63,52	79,71	16,19	79,33	15,81
1,7	67,43	77,90	10,48	78,76	11,33
1,8	55,43	76,10	20,67	76,76	21,33
2,3	46,95	69,52	22,57	68,19	21,24
2,4	48,76	67,90	19,14	68,48	19,72
2,5	48,19	64,95	16,76	65,43	17,24
2,6	49,33	68,67	19,33	69,43	20,10
2,7	63,05	71,90	8,86	73,71	10,66
2,8	54,29	71,52	17,24	72,10	17,81
3,4	50,86	70,95	20,10	71,33	20,47
3,5	50,48	72,19	21,71	73,05	22,57
3,6	59,24	77,05	17,81	75,90	16,66
3,7	66,57	76,76	10,19	77,24	10,67
3,8	69,33	80,67	11,33	80,95	11,62
4,5	43,33	70,19	26,86	64,57	21,24
4,6	56,95	74,95	18,00	73,43	16,48
4,7	75,90	82,86	6,95	83,05	7,15
4,8	61,90	78,86	16,95	79,24	17,34
5,6	58,57	72,76	14,19	70,29	11,72
5,7	66,95	77,90	10,95	77,81	10,86
5,8	62,67	74,67	12,00	74,57	11,90
6,7	59,14	76,95	17,81	76,57	17,43
6,8	47,52	79,71	32,19	80,19	32,67
7,8	65,62	80,86	15,24	80,38	14,76

Tablo 4.30. Bir yüzey EMG özniteliği ve üç kanal ile elde edilen sınıflandırma doğruluk yüzdeleri

Kanallar	F10	F10+G9	% Fark 1	F10+G15	% Fark 2
1,2,3	79,33	82,95	3,62	83,62	4,29
1,2,4	79,81	83,14	3,33	83,71	3,90
1,2,5	78,19	82,48	4,29	82,76	4,57
1,2,6	76,19	83,90	7,71	84,48	8,29
1,2,7	78,48	83,52	5,05	84,38	5,90

Tablo 4.30. (devam)

1,2,8	75,81	80,76	4,95	81,05	5,24
1,3,4	82,95	85,90	2,95	86,00	3,05
1,3,5	82,76	86,10	3,33	86,10	3,34
1,3,6	85,90	89,33	3,43	89,24	3,34
1,3,7	85,24	87,90	2,67	87,71	2,47
1,3,8	82,19	85,81	3,62	86,86	4,67
1,4,5	82,10	86,76	4,67	86,10	4,00
1,4,6	87,05	89,24	2,19	89,43	2,38
1,4,7	88,76	91,52	2,76	91,14	2,38
1,4,8	81,14	86,76	5,62	87,14	6,00
1,5,6	85,24	87,81	2,57	87,33	2,09
1,5,7	84,10	86,19	2,10	85,43	1,33
1,5,8	78,86	82,86	4,00	83,05	4,19
1,6,7	80,38	85,71	5,33	85,33	4,95
1,6,8	79,62	83,62	4,00	84,29	4,67
1,7,8	81,24	85,90	4,67	85,52	4,28
2,3,4	70,29	78,67	8,38	79,71	9,42
2,3,5	69,24	78,67	9,43	79,33	10,09
2,3,6	72,57	81,05	8,48	82,00	9,43
2,3,7	79,81	82,48	2,67	83,43	3,62
2,3,8	81,24	85,14	3,90	85,14	3,90
2,4,5	67,43	76,19	8,76	76,86	9,43
2,4,6	74,57	78,67	4,10	78,76	4,19
2,4,7	83,62	86,29	2,67	86,19	2,57
2,4,8	77,81	82,48	4,67	82,67	4,86
2,5,6	75,24	80,57	5,33	81,24	6,00
2,5,7	80,48	84,19	3,71	83,90	3,42
2,5,8	75,71	80,67	4,95	80,38	4,67
2,6,7	77,62	83,43	5,81	83,52	5,90
2,6,8	76,38	83,14	6,76	83,24	6,86
2,7,8	80,86	85,33	4,48	85,43	4,57
3,7,8	87,90	90,29	2,38	90,76	2,86
3,6,8	85,43	89,52	4,10	89,14	3,71
3,6,7	82,48	85,62	3,14	86,29	3,81
3,5,8	82,19	85,24	3,05	85,52	3,33
3,5,7	80,48	85,33	4,86	85,33	4,85
3,5,6	76,38	83,05	6,67	84,57	8,19
3,4,8	82,29	86,76	4,48	87,52	5,23
3,4,7	81,62	85,71	4,10	85,62	4,00
3,4,6	76,29	82,10	5,81	82,38	6,09
3,4,5	67,14	77,43	10,29	77,24	10,10
4,7,8	88,76	91,14	2,38	90,67	1,91
4,6,8	85,43	88,76	3,33	88,19	2,76
4,6,7	83,62	85,52	1,90	86,10	2,48
4,5,8	81,62	86,76	5,14	85,52	3,90
4,5,7	82,95	86,57	3,62	86,86	3,91
3,5,6	75,90	80,57	4,67	81,05	5,15
5,6,7	82,48	86,57	4,10	86,48	4,00
5,6,8	84,57	87,14	2,57	87,52	2,95
5,7,8	84,00	87,24	3,24	86,67	2,67
6,7,8	83,24	85,62	2,38	86,38	3,14

Tablo 4.31. Bir yüzey EMG özneteliği ve dört kanal ile elde edilen sınıflandırma doğruluk yüzdeleri

Kanallar	F10	F10+G9	% Fark 1	F10+G15	% Fark 2
1,2,3,4	85,14	88,48	3,33	88,38	3,24
1,2,3,5	86,10	89,43	3,33	88,76	2,66
1,2,3,6	89,71	92,00	2,29	91,81	2,10
1,2,3,7	89,05	91,14	2,10	91,71	2,66
1,2,3,8	86,76	89,43	2,67	89,81	3,05
1,2,4,5	86,76	87,71	0,95	88,10	1,34
1,2,4,6	89,81	90,86	1,05	91,62	1,81
1,2,4,7	90,67	91,62	0,95	91,81	1,14
1,2,4,8	84,76	88,10	3,33	88,29	3,53
1,2,5,6	89,14	90,67	1,52	91,14	2,00
1,2,5,7	89,24	91,14	1,90	91,33	2,09
1,2,5,8	84,95	88,00	3,05	88,57	3,62
1,2,6,7	84,29	89,62	5,33	89,52	5,23
1,2,6,8	85,05	88,19	3,14	88,38	3,33
1,2,7,8	85,90	89,24	3,33	89,33	3,43
1,3,4,5	86,95	89,33	2,38	89,14	2,19
1,3,4,6	90,76	92,48	1,71	92,19	1,43
1,3,4,7	90,67	92,76	2,10	92,67	2,00
1,3,4,8	87,52	89,33	1,81	89,62	2,10
1,3,5,6	91,71	93,81	2,10	93,33	1,62
1,3,5,7	90,00	92,10	2,10	91,71	1,71
1,3,5,8	88,48	91,05	2,57	91,05	2,57
1,3,6,7	90,67	92,38	1,71	92,76	2,09
1,3,6,8	90,00	92,19	2,19	92,10	2,10
1,3,7,8	88,76	91,62	2,86	91,90	3,14
1,4,5,6	88,48	90,38	1,90	89,81	1,33
1,4,5,7	89,43	92,57	3,14	92,19	2,76
1,4,5,8	89,05	90,76	1,71	90,67	1,62
1,4,6,7	91,24	91,14	-0,10	91,81	0,57
1,4,6,8	90,67	92,00	1,33	92,38	1,71
1,4,7,8	91,33	94,00	2,67	93,90	2,57
1,5,6,7	89,33	90,00	0,67	89,81	0,48
1,5,6,8	90,57	91,14	0,57	91,14	0,57
1,5,7,8	88,76	90,57	1,81	90,76	2,00
1,6,7,8	86,19	89,52	3,33	89,71	3,52
2,3,4,5	77,14	82,76	5,62	82,48	5,34
2,3,4,6	84,29	86,10	1,81	86,86	2,57
2,3,4,7	87,24	89,14	1,90	89,43	2,19
2,3,4,8	88,29	90,76	2,48	90,57	2,28
2,3,5,6	83,71	88,86	5,14	88,76	5,05
2,3,5,7	86,57	89,43	2,86	89,33	2,76
2,3,5,8	87,62	89,62	2,00	89,62	2,00
2,3,6,7	89,62	90,19	0,57	89,52	-0,10
2,3,6,8	90,57	93,33	2,76	93,14	2,57
2,3,7,8	89,33	92,10	2,76	92,19	2,86
2,4,5,6	80,19	82,86	2,67	83,62	3,43
2,4,5,7	88,29	90,76	2,48	90,95	2,66
2,4,5,8	85,90	88,48	2,57	88,76	2,86
2,4,6,7	87,52	89,24	1,71	89,05	1,53
2,4,6,8	89,71	90,95	1,24	91,52	1,81
2,4,7,8	89,14	91,24	2,10	90,76	1,62
2,5,6,7	88,29	89,52	1,24	90,29	2,00
2,5,6,8	88,38	89,33	0,95	88,95	0,57

Tablo 4.31. (devam)

2,5,7,8	87,90	90,86	2,95	90,95	3,05
2,6,7,8	85,90	89,90	4,00	88,95	3,05
3,4,5,6	82,86	86,95	4,10	86,67	3,81
3,4,5,7	86,76	90,19	3,43	90,48	3,72
3,4,5,8	87,62	90,48	2,86	90,48	2,86
3,4,6,7	86,67	88,00	1,33	89,14	2,47
3,4,6,8	90,86	93,62	2,76	93,71	2,85
3,4,7,8	91,90	93,71	1,81	93,43	1,53
3,5,6,7	89,71	91,33	1,62	92,19	2,48
3,5,6,8	92,29	94,38	2,10	94,67	2,38
3,5,7,8	90,29	92,29	2,00	92,38	2,09
3,6,7,8	92,38	93,71	1,33	93,81	1,43
4,5,6,7	87,71	89,71	2,00	89,71	2,00
4,5,6,8	88,67	90,48	1,81	90,19	1,52
4,5,7,8	91,52	93,24	1,71	93,71	2,19
4,6,7,8	91,24	92,29	1,05	91,81	0,57
5,6,7,8	91,14	92,67	1,52	92,48	1,34

Tablo 4.32. Bir yüzey EMG özneteliği ve beş kanal ile elde edilen sınıflandırma doğruluk yüzdeleri

Kanallar	F10	F10+G9	% Fark 1	F10+G15	% Fark 2
1,2,3,4,5	88,29	91,43	3,14	91,81	3,52
1,2,3,4,6	92,86	93,71	0,86	93,90	1,04
1,2,3,4,7	91,62	93,71	2,10	93,43	1,81
1,2,3,4,8	89,90	91,90	2,00	91,14	1,24
1,2,3,5,6	93,52	94,38	0,86	94,48	0,96
1,2,3,5,7	92,00	93,52	1,52	93,90	1,90
1,2,3,5,8	90,76	92,76	2,00	93,05	2,29
1,2,3,6,7	93,33	94,19	0,86	94,00	0,67
1,2,3,6,8	93,62	94,95	1,33	95,14	1,52
1,2,3,7,8	91,71	94,00	2,29	94,29	2,58
1,2,4,5,6	92,19	91,90	-0,29	91,81	-0,38
1,2,4,5,7	92,29	94,29	2,00	94,19	1,90
1,2,4,5,8	90,38	91,62	1,24	91,81	1,43
1,2,4,6,7	92,86	93,71	0,86	93,52	0,66
1,2,4,6,8	94,10	93,81	-0,29	94,29	0,19
1,2,4,7,8	92,67	94,67	2,00	95,05	2,38
1,2,5,6,7	92,76	94,10	1,33	94,48	1,72
1,2,5,6,8	92,95	93,05	0,10	93,05	0,10
1,2,5,7,8	91,62	93,43	1,81	93,71	2,09
1,2,6,7,8	89,43	91,71	2,29	92,38	2,95
1,3,4,5,6	92,29	93,81	1,52	93,43	1,14
1,3,4,5,7	92,57	94,48	1,90	94,48	1,91
1,3,4,5,8	90,95	93,33	2,38	93,43	2,48
1,3,4,6,7	93,71	95,24	1,52	94,76	1,05
1,3,4,6,8	94,48	95,43	0,95	95,52	1,04
1,3,4,7,8	92,86	95,71	2,86	95,43	2,57
1,3,5,6,7	94,10	94,48	0,38	94,67	0,57
1,3,5,6,8	94,29	95,81	1,52	95,52	1,23
1,3,5,7,8	92,29	93,71	1,43	94,48	2,19
1,3,6,7,8	93,62	95,43	1,81	95,52	1,90
1,4,5,6,7	93,05	94,48	1,43	94,00	0,95
1,4,5,6,8	93,05	94,19	1,14	93,81	0,76

Tablo 4.32. (devam)

1,4,5,7,8	93,14	94,38	1,24	94,57	1,43
1,4,6,7,8	94,57	94,95	0,38	94,76	0,19
1,5,6,7,8	92,86	93,81	0,95	94,00	1,14
2,3,4,5,6	86,86	89,24	2,38	89,43	2,57
2,3,4,5,7	90,29	92,57	2,29	92,19	1,90
2,3,4,5,8	90,67	92,67	2,00	92,67	2,00
2,3,4,6,7	91,43	91,71	0,29	92,10	0,67
2,3,4,6,8	93,05	95,33	2,29	95,24	2,19
2,3,4,7,8	92,95	95,14	2,19	95,14	2,19
2,3,5,6,7	92,86	93,33	0,48	93,90	1,04
2,3,5,6,8	94,10	95,05	0,95	94,95	0,85
2,3,5,7,8	92,67	93,81	1,14	94,10	1,43
2,3,6,7,8	93,52	95,05	1,52	95,14	1,62
2,4,5,6,7	91,90	93,05	1,14	92,95	1,05
2,4,5,6,8	90,76	92,57	1,81	92,48	1,72
2,4,5,7,8	92,48	93,52	1,05	93,05	0,57
2,4,6,7,8	92,10	92,86	0,76	92,67	0,57
2,5,6,7,8	92,00	94,19	2,19	93,90	1,90
3,4,5,6,7	91,14	92,86	1,71	92,57	1,43
3,4,5,6,8	92,76	94,38	1,62	94,48	1,72
3,4,5,7,8	93,52	94,76	1,24	94,86	1,34
3,4,6,7,8	93,43	96,29	2,86	96,29	2,86
3,5,6,7,8	95,43	96,19	0,76	96,19	0,76
4,5,6,7,8	94,29	94,57	0,29	94,29	0,00

Tablo 4.33. Bir yüzey EMG özneteliği ve altı kanal ile elde edilen sınıflandırma doğruluk yüzdeleri

Kanallar	F10	F10+G9	% Fark 1	F10+G15	% Fark 2
1,2,3,4,5,6	93,71	94,57	0,86	94,76	1,05
1,2,3,4,5,7	93,05	94,95	1,90	94,67	1,62
1,2,3,4,5,8	93,05	93,81	0,76	94,29	1,24
1,2,3,4,6,7	94,57	95,05	0,48	94,86	0,29
1,2,3,4,6,8	95,14	96,95	1,81	96,86	1,72
1,2,3,4,7,8	94,29	95,90	1,62	95,81	1,52
1,2,3,5,6,7	95,24	96,19	0,95	95,81	0,57
1,2,3,5,6,8	94,95	96,48	1,52	96,76	1,81
1,2,3,5,7,8	95,05	95,81	0,76	96,19	1,14
1,2,3,6,7,8	95,05	96,48	1,43	96,48	1,43
1,2,4,5,6,7	94,48	95,43	0,95	95,52	1,04
1,2,4,5,6,8	95,33	94,48	-0,86	94,19	-1,14
1,2,4,5,7,8	94,57	94,95	0,38	95,43	0,86
1,2,4,6,7,8	95,24	95,62	0,38	95,71	0,47
1,2,5,6,7,8	95,33	95,43	0,10	95,52	0,19
1,3,4,5,6,7	94,00	96,00	2,00	95,81	1,81
1,3,4,5,6,8	94,86	96,19	1,33	96,38	1,52
1,3,4,5,7,8	94,67	95,71	1,05	96,19	1,52
1,3,4,6,7,8	95,24	97,71	2,48	98,00	2,76
1,3,5,6,7,8	96,29	97,81	1,52	97,81	1,52
1,4,5,6,7,8	95,43	95,81	0,38	95,62	0,19
2,3,4,5,6,7	93,43	94,19	0,76	93,90	0,47
2,3,4,5,6,8	95,05	95,71	0,67	95,81	0,76
2,3,4,5,7,8	95,33	95,33	0,00	95,24	-0,09
2,3,4,6,7,8	94,67	95,90	1,24	95,90	1,23

Tablo 4.33. (devam)

2,3,5,6,7,8	<u>96,38</u>	96,95	0,57	97,05	0,67
2,4,5,6,7,8	94,86	95,24	0,38	95,05	0,19
3,4,5,6,7,8	95,90	96,00	0,10	96,48	0,58

Tablo 4.34. Bir yüzey EMG özneteliği ve yedi kanal ile elde edilen sınıflandırma doğruluk yüzdeleri

Kanallar	F10	F10+G9	% Fark 1	F10+G15	% Fark 2
1,2,3,4,5,6,7	95,05	96,38	1,33	96,29	1,24
1,2,3,4,5,6,8	95,71	96,57	0,86	96,38	0,67
1,2,3,4,5,7,8	95,71	96,29	0,57	96,67	0,96
1,2,3,4,6,7,8	96,48	97,24	0,76	97,33	0,85
1,2,3,5,6,7,8	<u>96,67</u>	<u>97,90</u>	1,24	97,81	1,14
1,2,4,5,6,7,8	96,57	96,00	-0,57	96,48	-0,09
1,3,4,5,6,7,8	96,38	97,43	1,05	<u>97,90</u>	1,52
2,3,4,5,6,7,8	96,48	96,86	0,38	96,67	0,19

Tablo 4.35. Üç yüzey EMG özneteliği ve iki kanal ile elde edilen sınıflandırma doğruluk yüzdeleri

Kanallar	F10+F7+F8	F10+F7+F8+G6	% Fark 1	F10+F7+F8+G19	% Fark 2
1,2	68,48	74,10	5,62	72,48	4,00
1,3	78,48	79,14	0,67	77,43	-1,05
1,4	79,14	82,10	2,95	80,95	1,81
1,5	73,24	77,71	4,48	76,76	3,52
1,6	74,48	78,00	3,52	77,81	3,33
1,7	74,86	78,95	4,10	79,24	4,38
1,8	73,43	77,05	3,62	76,57	3,14
2,3	62,38	68,76	6,38	68,48	6,10
2,4	65,52	70,67	5,14	71,43	5,91
2,5	63,24	66,86	3,62	68,10	4,86
2,6	59,24	68,38	9,14	65,52	6,28
2,7	70,00	74,86	4,86	75,52	5,52
2,8	70,57	76,29	5,71	74,95	4,38
3,4	67,24	72,10	4,86	73,52	6,28
3,5	65,90	72,67	6,76	70,76	4,86
3,6	68,76	75,43	6,67	75,14	6,38
3,7	78,19	79,05	0,86	79,33	1,14
3,8	<u>82,95</u>	84,29	1,33	<u>86,48</u>	3,53
4,5	65,62	70,29	4,67	71,33	5,71
4,6	71,62	75,90	4,29	74,67	3,05
4,7	81,62	<u>84,67</u>	3,05	84,29	2,67
4,8	80,19	82,57	2,38	84,00	3,81
5,6	70,57	75,52	4,95	74,10	3,53
5,7	75,05	77,52	2,48	77,43	2,38
5,8	73,33	77,33	4,00	76,76	3,43
6,7	71,05	77,14	6,10	76,48	5,43
6,8	74,48	80,67	6,19	80,29	5,81
7,8	79,14	81,62	2,48	81,71	2,57

Tablo 4.36. Üç yüzey EMG özneliği ve üç kanal ile elde edilen sınıflandırma doğruluk yüzdeleri

Kanallar	F10+F7+F8	F10+F7+F8+G6	% Fark 1	F10+F7+F8+G19	% Fark 2
1,2,3	82,48	84,29	1,81	83,62	1,14
1,2,4	85,90	86,95	1,05	85,81	-0,09
1,2,5	82,38	84,29	1,90	84,19	1,81
1,2,6	81,33	83,81	2,48	84,67	3,34
1,2,7	82,57	84,95	2,38	85,81	3,24
1,2,8	78,57	84,29	5,71	82,57	4,00
1,3,4	87,24	88,48	1,24	87,71	0,47
1,3,5	85,71	87,14	1,43	87,14	1,43
1,3,6	87,62	87,90	0,29	88,19	0,57
1,3,7	88,29	88,10	-0,19	89,05	0,76
1,3,8	87,24	88,19	0,95	88,19	0,95
1,4,5	84,76	86,00	1,24	86,57	1,81
1,4,6	87,71	88,29	0,57	89,62	1,91
1,4,7	90,57	91,43	0,86	90,76	0,19
1,4,8	87,52	89,24	1,71	89,14	1,62
1,5,6	85,90	87,05	1,14	88,57	2,67
1,5,7	86,10	86,86	0,76	88,67	2,57
1,5,8	81,62	84,67	3,05	86,10	4,48
1,6,7	84,76	86,86	2,10	86,67	1,91
1,6,8	81,52	84,95	3,43	83,90	2,38
1,7,8	84,67	86,48	1,81	86,29	1,62
2,3,4	75,52	79,81	4,29	80,10	4,58
2,3,5	77,14	78,38	1,24	79,05	1,91
2,3,6	75,14	80,19	5,05	81,05	5,91
2,3,7	80,29	80,00	-0,29	82,29	2,00
2,3,8	88,19	89,14	0,95	88,19	0,00
2,4,5	73,14	77,52	4,38	77,71	4,57
2,4,6	78,76	81,62	2,86	82,38	3,62
2,4,7	87,71	87,62	-0,10	88,19	0,48
2,4,8	86,10	88,00	1,90	89,71	3,61
2,5,6	78,10	80,38	2,29	79,43	1,33
2,5,7	82,48	86,48	4,00	85,14	2,66
2,5,8	84,38	85,62	1,24	86,48	2,10
2,6,7	80,19	83,14	2,95	84,00	3,81
2,6,8	81,24	84,00	2,76	84,38	3,14
2,7,8	84,00	86,57	2,57	86,57	2,57
3,7,8	90,19	90,95	0,76	91,90	1,71
3,6,8	90,67	91,81	1,14	92,95	2,28
3,6,7	86,67	87,71	1,05	87,43	0,76
3,5,8	87,05	87,90	0,86	89,14	2,09
3,5,7	85,62	87,14	1,52	87,14	1,52
3,5,6	80,00	83,43	3,43	83,14	3,14
3,4,8	88,76	88,95	0,19	89,90	1,14
3,4,7	85,90	87,05	1,14	87,90	2,00
3,4,6	79,43	81,90	2,48	82,10	2,67
3,4,5	75,05	76,76	1,71	78,29	3,24
4,7,8	91,14	91,33	0,19	90,67	-0,47
4,6,8	88,76	89,24	0,48	91,33	2,57
4,6,7	87,71	87,81	0,10	87,52	-0,19
4,5,8	84,57	86,29	1,71	87,14	2,57

Tablo 4.36. (devam)

4,5,7	84,95	87,24	2,29	86,86	1,91
4,5,6	79,43	81,05	1,62	81,24	1,81
5,6,7	84,00	87,33	3,33	85,05	1,05
5,6,8	85,52	87,71	2,19	87,52	2,00
5,7,8	85,90	87,33	1,43	86,67	0,77
6,7,8	83,81	88,48	4,67	87,52	3,71

Tablo 4.37. Üç yüzey EMG özneteliği ve dört kanal ile elde edilen sınıflandırma doğruluk yüzdeleri

Kanallar	F10+F7+F8	F10+F7+F8+G6	% Fark 1	F10+F7+F8+G19	% Fark 2
1,2,3,4	89,52	90,57	1,05	90,29	0,77
1,2,3,5	89,62	91,05	1,43	90,67	1,05
1,2,3,6	92,48	92,76	0,29	93,05	0,57
1,2,3,7	90,67	91,52	0,86	92,29	1,62
1,2,3,8	91,14	91,71	0,57	91,62	0,48
1,2,4,5	88,76	90,57	1,81	90,86	2,10
1,2,4,6	92,86	92,00	-0,86	92,48	-0,38
1,2,4,7	93,14	94,19	1,05	94,19	1,05
1,2,4,8	89,90	90,95	1,05	91,14	1,24
1,2,5,6	90,67	91,14	0,48	91,14	0,47
1,2,5,7	90,00	92,10	2,10	92,67	2,67
1,2,5,8	89,71	90,95	1,24	91,05	1,34
1,2,6,7	87,52	91,14	3,62	91,43	3,91
1,2,6,8	85,81	87,81	2,00	88,19	2,38
1,2,7,8	87,14	90,19	3,05	89,52	2,38
1,3,4,5	90,10	90,48	0,38	90,57	0,47
1,3,4,6	91,90	92,95	1,05	93,52	1,62
1,3,4,7	93,14	93,90	0,76	93,81	0,67
1,3,4,8	90,57	92,19	1,62	92,95	2,38
1,3,5,6	92,29	92,48	0,19	92,95	0,66
1,3,5,7	91,90	92,10	0,19	92,29	0,39
1,3,5,8	90,57	91,43	0,86	91,81	1,24
1,3,6,7	92,86	91,62	-1,24	92,86	0,00
1,3,6,8	93,05	93,81	0,76	94,19	1,14
1,3,7,8	92,29	93,52	1,24	94,38	2,09
1,4,5,6	89,90	90,48	0,57	90,95	1,05
1,4,5,7	92,10	92,29	0,19	92,57	0,47
1,4,5,8	90,38	91,52	1,14	91,14	0,76
1,4,6,7	92,86	93,24	0,38	93,33	0,47
1,4,6,8	92,00	92,95	0,95	93,33	1,33
1,4,7,8	93,24	94,00	0,76	94,29	1,05
1,5,6,7	90,38	91,05	0,67	90,38	0,00
1,5,6,8	90,67	92,48	1,81	91,62	0,95
1,5,7,8	89,52	89,62	0,10	89,43	-0,09
1,6,7,8	88,86	90,38	1,52	89,81	0,95
2,3,4,5	81,05	83,62	2,57	84,38	3,33
2,3,4,6	83,81	85,05	1,24	86,38	2,57
2,3,4,7	89,14	89,62	0,48	90,19	1,05
2,3,4,8	91,05	92,86	1,81	93,52	2,47
2,3,5,6	84,00	86,95	2,95	87,71	3,71
2,3,5,7	89,90	89,05	-0,86	90,48	0,58
2,3,5,8	91,43	92,00	0,57	92,19	0,76
2,3,6,7	89,71	89,71	0,00	89,52	-0,19

Tablo 4.37. (devam)

2,3,6,8	92,38	93,05	0,67	93,05	0,67
2,3,7,8	91,81	92,95	1,14	93,43	1,62
2,4,5,6	85,24	85,52	0,29	86,48	1,24
2,4,5,7	90,00	90,10	0,10	89,81	-0,19
2,4,5,8	89,52	90,10	0,57	90,76	1,24
2,4,6,7	91,52	90,76	-0,76	91,14	-0,38
2,4,6,8	91,33	92,19	0,86	92,95	1,62
2,4,7,8	93,81	94,57	0,76	93,71	-0,10
2,5,6,7	88,76	89,71	0,95	89,81	1,05
2,5,6,8	89,71	90,29	0,57	90,29	0,58
2,5,7,8	89,81	91,24	1,43	90,86	1,05
2,6,7,8	88,67	90,48	1,81	91,05	2,38
3,4,5,6	85,62	86,00	0,38	87,33	1,71
3,4,5,7	89,90	90,86	0,95	91,24	1,34
3,4,5,8	90,38	90,95	0,57	92,19	1,81
3,4,6,7	89,81	90,57	0,76	90,48	0,67
3,4,6,8	94,00	93,81	-0,19	94,86	0,86
3,4,7,8	93,33	94,48	1,14	95,43	2,10
3,5,6,7	91,05	91,05	0,00	91,24	0,19
3,5,6,8	93,90	92,48	-1,43	94,10	0,20
3,5,7,8	93,71	94,19	0,48	94,86	1,15
3,6,7,8	94,67	95,05	0,38	95,24	0,57
4,5,6,7	89,81	90,19	0,38	89,90	0,09
4,5,6,8	89,52	90,48	0,95	92,10	2,58
4,5,7,8	93,24	93,33	0,10	93,24	0,00
4,6,7,8	93,81	93,33	-0,48	93,81	0,00
5,6,7,8	91,62	92,29	0,67	92,38	0,76

Tablo 4.38. Üç yüzey EMG özneteliği ve beş kanal ile elde edilen sınıflandırma doğruluk yüzdeleri

Kanallar	F10+F7+F8	F10+F7+F8+G6	% Fark 1	F10+F7+F8+G19	% Fark 2
1,2,3,4,5	92,10	92,86	0,76	93,33	1,23
1,2,3,4,6	93,14	93,33	0,19	93,33	0,19
1,2,3,4,7	94,19	94,95	0,76	95,05	0,86
1,2,3,4,8	93,81	93,90	0,10	94,19	0,38
1,2,3,5,6	94,48	95,05	0,57	95,05	0,57
1,2,3,5,7	93,81	94,38	0,57	93,81	0,00
1,2,3,5,8	93,81	94,19	0,38	93,90	0,09
1,2,3,6,7	94,10	94,29	0,19	94,10	0,00
1,2,3,6,8	94,48	95,14	0,67	95,33	0,85
1,2,3,7,8	93,52	94,76	1,24	94,29	0,77
1,2,4,5,6	94,00	92,57	-1,43	93,90	-0,10
1,2,4,5,7	93,90	94,76	0,86	94,38	0,48
1,2,4,5,8	92,48	93,33	0,86	93,52	1,04
1,2,4,6,7	94,67	94,95	0,29	94,67	0,00
1,2,4,6,8	94,67	94,29	-0,38	94,48	-0,19
1,2,4,7,8	94,95	95,81	0,86	95,52	0,57
1,2,5,6,7	93,05	94,19	1,14	93,62	0,57
1,2,5,6,8	92,86	93,52	0,67	94,29	1,43
1,2,5,7,8	93,14	93,71	0,57	93,90	0,76
1,2,6,7,8	91,52	93,14	1,62	92,95	1,43
1,3,4,5,6	93,81	92,95	-0,86	93,81	0,00
1,3,4,5,7	94,29	94,00	-0,29	94,67	0,38

Tablo 4.38. (devam)

1,3,4,5,8	92,95	93,43	0,48	93,52	0,57
1,3,4,6,7	95,71	94,48	-1,24	95,05	-0,66
1,3,4,6,8	94,86	95,71	0,86	95,71	0,85
1,3,4,7,8	95,81	96,10	0,29	96,10	0,29
1,3,5,6,7	94,95	94,57	-0,38	94,57	-0,38
1,3,5,6,8	95,62	94,76	-0,86	95,52	-0,10
1,3,5,7,8	95,33	94,86	-0,48	95,14	-0,19
1,3,6,7,8	95,14	95,71	0,57	95,43	0,29
1,4,5,6,7	94,00	94,29	0,29	94,38	0,38
1,4,5,6,8	93,24	92,67	-0,57	93,81	0,57
1,4,5,7,8	94,57	94,19	-0,38	94,95	0,38
1,4,6,7,8	95,43	95,43	0,00	95,05	-0,38
1,5,6,7,8	93,43	94,00	0,57	93,71	0,28
2,3,4,5,6	89,33	89,24	-0,10	90,57	1,24
2,3,4,5,7	92,38	92,29	-0,10	92,67	0,29
2,3,4,5,8	93,33	93,62	0,29	94,00	0,67
2,3,4,6,7	92,67	92,86	0,19	92,57	-0,10
2,3,4,6,8	94,29	95,24	0,95	95,24	0,95
2,3,4,7,8	94,38	95,71	1,33	95,52	1,14
2,3,5,6,7	92,57	91,90	-0,67	92,57	0,00
2,3,5,6,8	95,05	95,81	0,76	96,10	1,05
2,3,5,7,8	94,67	94,76	0,10	95,33	0,66
2,3,6,7,8	94,86	95,81	0,95	95,62	0,76
2,4,5,6,7	92,57	91,33	-1,24	91,62	-0,95
2,4,5,6,8	93,14	92,86	-0,29	93,81	0,67
2,4,5,7,8	94,10	95,43	1,33	95,33	1,23
2,4,6,7,8	94,57	94,76	0,19	94,00	-0,57
2,5,6,7,8	92,67	94,10	1,43	93,81	1,14
3,4,5,6,7	92,00	91,81	-0,19	92,00	0,00
3,4,5,6,8	94,95	94,76	-0,19	95,71	0,76
3,4,5,7,8	94,86	95,24	0,38	95,71	0,85
3,4,6,7,8	96,19	96,76	0,57	96,57	0,38
3,5,6,7,8	96,00	96,10	0,10	96,00	0,00
4,5,6,7,8	95,24	95,14	-0,10	94,86	-0,38

Tablo 4.39. Üç yüzey EMG özneteliği ve altı kanal ile elde edilen sınıflandırma doğruluk yüzdeleri

Kanallar	F10+F7+F8	F10+F7+F8+G6	% Fark 1	F10+F7+F8+G6	% Fark 2
1,2,3,4,5,6	94,76	95,14	0,38	95,05	0,29
1,2,3,4,5,7	94,86	95,43	0,57	95,43	0,57
1,2,3,4,5,8	95,24	95,52	0,29	95,90	0,66
1,2,3,4,6,7	96,00	95,81	-0,19	96,38	0,38
1,2,3,4,6,8	95,81	96,10	0,29	96,29	0,48
1,2,3,4,7,8	96,00	96,48	0,48	96,48	0,48
1,2,3,5,6,7	94,95	95,43	0,48	95,24	0,29
1,2,3,5,6,8	96,48	97,14	0,67	96,95	0,47
1,2,3,5,7,8	95,90	96,38	0,48	96,57	0,67
1,2,3,6,7,8	95,90	96,48	0,57	96,76	0,86
1,2,4,5,6,7	96,00	95,52	-0,48	95,81	-0,19
1,2,4,5,6,8	95,24	94,57	-0,67	95,14	-0,10
1,2,4,5,7,8	96,10	96,76	0,67	96,57	0,47
1,2,4,6,7,8	96,19	96,38	0,19	95,62	-0,57
1,2,5,6,7,8	94,76	95,33	0,57	95,90	1,14

Tablo 4.39. (devam)


1,3,4,5,6,7	95,52	95,62	0,10	95,62	0,10
1,3,4,5,6,8	95,71	96,10	0,38	96,00	0,29
1,3,4,5,7,8	95,71	96,19	0,48	96,38	0,67
1,3,4,6,7,8	96,48	96,86	0,38	96,48	0,00
1,3,5,6,7,8	96,86	97,05	0,19	96,95	0,09
1,4,5,6,7,8	95,81	95,90	0,10	95,33	-0,48
2,3,4,5,6,7	94,57	93,90	-0,67	94,00	-0,57
2,3,4,5,6,8	96,10	95,81	-0,29	96,67	0,57
2,3,4,5,7,8	95,71	96,19	0,48	96,29	0,58
2,3,4,6,7,8	96,29	97,14	0,86	96,76	0,47
2,3,5,6,7,8	96,76	96,48	-0,29	96,57	-0,19
2,4,5,6,7,8	96,67	95,71	-0,95	95,62	-1,05
3,4,5,6,7,8	96,86	96,67	-0,19	96,76	0,29

Tablo 4.40. Üç yüzey EMG özneteliği ve yedi kanal ile elde edilen sınıflandırma doğruluk yüzdeleri

Kanallar	F10+F7+F8	F10+F7+F8+G6	% Fark 1	F10+F7+F8+G6	% Fark 2
1,2,3,4,5,6,7	96,57	96,67	0,10	96,48	-0,09
1,2,3,4,5,6,8	96,95	97,52	0,57	97,71	0,76
1,2,3,4,5,7,8	96,57	97,14	0,57	97,33	0,76
1,2,3,4,6,7,8	97,14	96,76	-0,38	96,67	-0,47
1,2,3,5,6,7,8	97,33	97,62	0,29	97,33	0,00
1,2,4,5,6,7,8	96,95	96,48	-0,48	96,57	-0,38
1,3,4,5,6,7,8	97,71	97,14	-0,57	97,43	-0,28
2,3,4,5,6,7,8	97,52	97,24	-0,29	97,05	-0,47

Tablo 4.41. Bir yüzey EMG özneteliği ile elde edilen en yüksek doğruluklar


En yüksek doğruluk veren kanallar	F10 doğruluğu (%)	F10+G9 doğruluğu (%)	F10+G15 doğruluğu (%)
4,7	75,90	82,86	83,05
1,4,7	88,76	91,52	91,14
3,5,6,8	92,29	94,38	94,67
3,6,7,8	92,38	93,71	93,81
3,4,6,7,8	93,43	96,29	96,29
3,5,6,7,8	95,43	96,19	96,19
1,3,4,6,7,8	95,24	97,71	98,00
1,3,5,6,7,8	96,29	97,81	97,81
2,3,5,6,7,8	96,38	96,95	97,05
1,2,3,5,6,7,8	96,67	97,90	97,81
1,3,4,5,6,7,8	96,38	97,43	97,90
Tüm Kanallar	96,95	98,00	98,00



Şekil 4.8. Bir yüzey EMG özneteliği ile elde edilen en yüksek doğrulukların grafiksel gösterimi

Tablo 4.42. Üç yüzey EMG özneteliği ile elde edilen en yüksek doğruluklar

En yüksek doğruluk veren kanallar	F10+F7+F8 doğruluğu (%)	F10+F7+F8+G6 doğruluğu (%)	F10+F7+F8+G19 doğruluğu (%)
3,8	82,95	84,29	86,48
4,7	81,62	84,67	84,29
3,6,8	90,67	91,81	92,95
4,7,8	91,14	91,33	90,67
3,4,7,8	93,33	94,48	95,43
3,6,7,8	94,67	95,05	95,24
3,4,6,7,8	96,19	96,76	96,57
1,2,3,5,6,8	96,48	97,14	96,95
1,3,5,6,7,8	96,86	97,05	96,95
2,3,4,6,7,8	96,29	97,14	96,76
3,4,5,6,7,8	96,86	96,67	96,76
1,2,3,4,5,6,8	96,95	97,52	97,71
1,2,3,5,6,7,8	97,33	97,62	97,33
1,3,4,5,6,7,8	97,71	97,14	97,43
Tüm Kanallar	98,38	98,10	98,19



Şekil 4.9. Üç yüzey EMG özneteliği ile elde edilen en yüksek doğrulukların grafiksel gösterimi

5. BULGULAR 2 – GERÇEK ZAMANLI UYGULAMA

Gerçek zamanlı olmayan uygulamada % 98,38 ile en yüksek doğruluğu veren F10+F7+F8 özniteliği kullanılarak gerçek zamanlı sınıflandırma uygulaması denenmiştir. Ancak bu öznelik setinin gerçek zamanlı sınıflandırmada iyi sonuç vermediği görülmüştür. Bunun nedeni araştırıldığında bu öznelik setinin işlem süresinin 300 ms' lik gerçek zamanlı sınıflandırma süre kısıtlamasının üzerinde olduğu görülmüştür. Sınıflandırmayı yapacak algoritmada tüm işlemlerin 300 ms' den önce bitirilmesi gerekliliği tanımlandığı için özneliklerde veri kaybı olmaktadır. Bu nedenle sınıflandırma performansı önemli ölçüde düşmektedir. Bu sorunun aşılması için en yüksek doğruluğu veren C-SVM sınıflandırıcısı ile zaman düzlemi özneliklerinin gerçek zamanlı sınıflandırma doğrulukları hesaplanmıştır. Sadece zaman düzlemi özneliklerinin hesaplanmasının nedeni, frekans düzlemi özneliklerinin çıkarılmasının daha uzun sürmesidir. Böylece gerçek zamanlı uygulama tek bir zaman düzlemi özniteliği kullanılarak gerçekleştirilmiştir.


Özneliklerin doğrulukları hesaplanırken bir kişi kendi verileri ile eğitilmiş C-SVM sınıflandırıcısını kullanarak tüm el hareketlerini 30' ar kez tekrarlamıştır. Elde edilen sonuçlar Tablo 5.1' de gösterilmiştir. Bu tabloda F2 özniteliğinin diğer özneliklerden daha yüksek sonuç verdiği görülmektedir. Bu nedenle gerçek zamanlı uygulamada F2 özniteliği kullanılmıştır.

Tablo 5.1. Zaman düzlemi özneliklerinin gerçek zamanlı sınıflandırma sonuçları


Öznelik	Doğruluk (%)
F1	98,57
F2	99,05
F4	38,1
F7	14,29
F8	23,33
F9	91,43
F10	28,57
F11	96,67
F12	40,48
F13	32,21
F14	14,29

Gerçek zamanlı uygulamada elde edilen doğrulukların günlere göre değişiminin incelenebilmesi için veri setindeki beşinci ve yedinci kişiler 10 gün boyunca sınıflandırma doğruluklarını hesaplamışlardır. Bu işlem için iki farklı sınıflandırma modeli kullanılmıştır. Bunlardan bir tanesi yalnızca hareketi yapan kişiden alınan veriler ile eğitilmiş modeldir. Diğeri ise tüm veri seti kullanılarak eğitilen modeldir.

Ölçüm işlemi her gün için her iki modelde de tüm hareketlerin 30' ar kez tekrarlanması şeklinde yapılmıştır. Elde edilen sonuçlar Şekil 5.1 ve Şekil 5.2' de gösterilmiştir.



Şekil 5.1. Beşinci kişi gerçek zamanlı sınıflandırma doğrulukları



Şekil 5.2. Yedinci kişi gerçek zamanlı sınıflandırma doğrulukları

Gerçek zamanlı sınıflandırma doğruluklarının kişilere göre değişiminin incelenmesi için veri setindeki sekiz kişi her iki sınıflandırıcı için, tüm hareketleri 30' ar kez tekrarlamışlardır. Her hareket yapılmadan önce kişiler kendilerini bir süre eğitmişlerdir. Elde edilen sonuçlar Tablo 5.2' de gösterilmiştir. Bu uygulamada işlem

süresi yaklaşık 200-220 ms civarındadır. Bu süre 300 ms'lik gerçek zaman kısıtlamalarının altındadır. Ayrıca çalışmanın gerçekleştirildiği bilgisayarın özellikleri: Intel(R) Core(TM) i7-6700HQ CPU @ 2,60 GHz 2,59 GHz 16 GB-RAM 64 bit işletim sistemidir.

Tablo 5.2. Veri setindeki kişiler için elde edilen gerçek zamanlı sınıflandırma doğrulukları

Kişi	Kişinin kendi verileri ile eğitilmiş sınıflandırıcı için doğruluk (%)	Tüm veri seti ile eğitilmiş sınıflandırıcı için doğruluk (%)
1. kişi	93,33	91,43
2. kişi	90,48	89,05
3. kişi	99,05	88,57
4. kişi	90,95	88,1
5. kişi	99,05	90,48
6. kişi	95,24	91,43
7. kişi	99,05	97,62
8. kişi	99,52	97,62
Ortalama	95,83	91,79

6. TARTIŞMA

6.1. Öznitelik Seçimi ve Sınıflandırma Performanslarının İncelenmesi

Yüzey EMG özniteliklerinin her birinin sınıflandırma doğrulukları (Tablo 4.1) incelendiğinde birçok özniteliğin % 90' ın üzerinde doğruluk verdiği görülmektedir. Ancak F3 ve F5' in doğruluklarının, diğer özniteliklere kıyasla oldukça düşük olduğu dikkat çekmiştir. Bunun nedeni Myo kol bandı yüzey EMG verilerini 200 Hz ile örneklemediğinden en yüksek frekans bileşeninin 100 Hz olmasıdır. Bunun sonucunda Myo kol bandı ile alınan yüzey EMG işaretlerinde yüksek frekanslı bileşenler kaybolmaktadır. Bu kayıplar bu iki özniteliğin doğruluğunun düşmesine neden olmaktadır. Ancak farklı öznitelik setleri seçilerek bu kayıpların önüne geçilmiştir (Phinyomark and Scheme, 2018).

Sınıflandırma yapılırken her bir hareket için ayrı ayrı başarımlar hesaplanmıştır (Tablo 4.13). Başarımlar incelendiğinde parmak açma ve dinlenme hareketlerinin diğer hareketlerden tamamen ayrıldığı görülmüştür. Ancak pronasyon hareketinin hassasiyetinin diğer hareketlerle kıyaslandığında daha düşük olduğu ve supinasyonla karıştırıldığı dikkat çekmiştir. Bu durum pronasyon hareketinin doğru bir şekilde algılanmasının diğer hareketlere oranla daha düşük olduğu anlamına gelir (Lalkhen and McCluskey, 2008). Bunun nedeni önkol pronasyonu ve supinasyonunun kemiklere yakın iki pronator kasını ve iki supinator kasını aktive etmesidir (Kanoga et al., 2020). Bunun sonucunda bu hareketlerin yüzey EMG işaretleriyle sınıflandırılması zorlaşmaktadır.

6.2. Jiroskop Özniteliklerinin Sınıflandırma Performansına Etkilerinin İncelenmesi

Bir yüzey EMG özniteliği için yapılan sınıflandırmada, jiroskop kullanılmayan sınıflandırmaya göre doğruluğun arttığı görülmüştür (Tablo 4.27 ve Şekil 4.2). Ancak burada jiroskop verilerinin hangi öznitelik ile işlendiği önemlidir. G9 ile işlenmiş jiroskop verileri kullanıldığında % 98 doğruluğa ulaşılmıştır. Bu doğruluk jiroskop özniteliğinin kullanılmadığı sınıflandırmaya göre % 1,05 daha yüksektir. Ayrıca jiroskop verileri frekans düzleminde de işlenmiş ve G15 özniteliği kullanılarak yapılan sınıflandırmada da % 98 doğruluk elde edilmiştir.

Üç yüzey EMG özniteliği kullanılarak yapılan sınıflandırmalarda ise aynı sonuçlar elde edilememiştir (Tablo 4.28 ve Şekil 4.3). Jiroskop verilerinin G6 kullanılarak işlenmesiyle % 98,1 doğruluk elde edilmiştir. Bu doğruluk jiroskop

özniteliğinin kullanılmadığı doğruluğa göre % 0,28 daha düşüktür. Frekans düzleminde işlenen jiroskop verilerinde ise G19 özniteliğiyle % 98,19 doğruluk elde edilmiştir. Bu doğruluk jiroskop özniteliğinin kullanılmadığı doğruluğa göre % 0,19 daha düşüktür. Sonuç olarak üçlü yüzey EMG öznitelik setine jiroskop özniteliği eklendiğinde doğruluklarda önemli bir değişime rastlanılmamıştır.

6.3. Kullanılan Kanal Sayısının Azaltılması ile Elde Edilen Bulguların İncelenmesi

Myo kol bandı ile 8 kanallı olarak elde edilen yüzey EMG verilerinde hem F10 hem de F10+F7+F8 öznitelikleri için farklı kanal sayılarının etkileri incelenmiştir. Bu incelemeler hem jiroskop özniteliklerinin kullanıldığı hem de kullanılmadığı durumlar için yapılmıştır. 3-7 kanal arasında incelenen sınıflandırma doğrulukları F10 için % 86,76 - % 96,67; F10+G9 için % 91,52 - % 97,9; F10+G15 için % 91,14 - % 98 arasındadır (Tablo 4.41). 3-7 kanal arasında incelenen sınıflandırma doğrulukları F10+F7+F8 için % 90,67 - % 97,71; F10+F7+F8+G6 için % 91,33 - % 97,62; F10+F7+F8+G19 için % 90,67 - % 97,71 arasındadır (Tablo 4.42). Kanal azaltımında elde edilen sonuçlar incelendiğinde 3-7 kanal için güvenilir sınıflandırma sonuçları elde edilmiştir (Hussain et al., 2020; Kanoga et al., 2020; Oskoei and Hu, 2007). Farklı kanal sayılarında jiroskop öznitelikleri sınıflandırma performansını artırmıştır. Protez kol denetiminde çok fazla sayıda kanala ihtiyaç olmadığı görülmüştür. 8 kanal yerine 3 kanallı yüzey EMG işaretleri protez kol denetiminde kullanılabilir. Ayrıca öznitelik matrisinin boyutu da önemli ölçüde azaldığı için işlem süresi de kısalmıştır.

6.4. Gerçek Zamanlı Sınıflandırma Sonuçlarının İncelenmesi

Gerçek zamanlı uygulamada sınıflandırma yapacak kişinin dikkati, duygusal durumu, yorgunluğu, o anki hareket kabiliyeti vb. durumların sınıflandırma doğruluğu üzerindeki etkilerinin anlaşılabilmesi için veri setindeki beşinci ve yedinci kişiler 10 gün boyunca sınıflandırma doğruluklarını hesaplamıştır. Yedinci kişinin doğruluklarının günlere göre değişimi çok azken, beşinci kişinin doğruluklarının değişimi, özellikle tüm veri seti ile eğitilen sınıflandırıcı için daha fazladır. Şekil 5.1' de beşinci kişi için doğruluklar incelendiğinde, tüm veri seti ile eğitilen sınıflandırıcı kullanılarak yapılan sınıflandırmada ilk 4 gün için doğrulukların daha düşük olduğu ancak daha sonraki günlerde doğruluğun arttığı görülmektedir. Beşinci kişinin, dördüncü günden itibaren kendini daha iyi eğiterek hareketleri daha iyi yaptığı ve daha fazla doğru sonuç elde ettiği söylenebilir.

Gerçek zamanlı sınıflandırmadan elde edilen doğrulukların kişilere göre değişiminin incelenmesi amacıyla veri setindeki sekiz kişi için doğruluklar hesaplanmıştır. Hem kişinin kendi verileri ile eğitilmiş sınıflandırıcıda hem de tüm veri seti ile eğitilen sınıflandırıcıda elde edilen doğrulukların kişiden kişiye farklılık gösterdiği görülmüştür. Ancak tüm uygulamalar için kişinin kendi verileri ile eğitilen sınıflandırıcının daha yüksek doğruluk verdiği görülmektedir. Buradan da görüleceği üzere yüzey EMG işaretleri kişiye özeldir ve kişinin kendi yüzey EMG işaretleri işlenerek elde edilen sınıflandırıcılar daha yüksek sonuçlar vermektedir.

6.5. Gerçek Zamanlı Olmayan Sınıflandırma Doğruluklarının Literatürdeki Çalışmalar ile Karşılaştırılması

Literatüre bakıldığında çalışmaların büyük çoğunluğunda tüm veri seti kullanılarak sınıflandırma yapılmış ve buradan elde edilen sonuç gösterilmiştir. Bazı çalışmalarda ise veri setindeki her bir kişi için sınıflandırma yapılmış ve elde edilen sonuçların ortalaması alınmıştır (Akhmadeev et al., 2017; Hassan et al., 2019; Mendez et al., 2017). Literatürdeki çalışmalar ile karşılaştırmalar bu iki durum için ayrı ayrı yapılmıştır.

Tablo 6.1' de gösterilen çalışmaların birinde % 99 doğruluk elde edilmiştir (Yang et al., 2017). Bunun nedeni çalışmanın yalnızca bir kişiden alınan veriler ile yapılmasıdır. Tablo 4.5' de gösterilen kişilerin bireysel sınıflandırma doğrulukları incelendiğinde 5 kişide % 100, 3 kişide % 99,05 doğruluk elde edildiği görülmektedir.

Kanal azaltımı ile ilgili sonuçlar incelendiğinde 7 kanal (% 97,90 doğruluk) ve 6 kanal (% 98 doğruluk) kullanılarak yapılan sınıflandırmada literatürdeki 9 adet çalışmadan daha yüksek doğruluk elde edilmiştir (Benalcázar et al., 2017; Chen and Zhang, 2019; Cote-Allard et al., 2017; Hussain et al., 2020; Kanoga et al., 2020; Kurniawan and Pamungkas, 2018; Morales and Cepeda, 2017; Said et al., 2020; Wahid et al., 2018). 5 kanal (% 96,76 doğruluk) kullanılarak yapılan sınıflandırmada 8 (Benalcázar et al., 2017; Chen and Zhang, 2019; Hussain et al., 2020; Kanoga et al., 2020; Kurniawan and Pamungkas, 2018; Morales and Cepeda, 2017; Said et al., 2020; Wahid et al., 2018), 4 kanal (% 95,43 doğruluk) kullanılarak yapılan sınıflandırmada 7 (Benalcázar et al., 2017; Chen and Zhang, 2019; Hussain et al., 2020; Kanoga et al., 2020; Kurniawan and Pamungkas, 2018; Morales and Cepeda, 2017; Said et al., 2020), 3 kanal (% 92,95 doğruluk) kullanılarak yapılan sınıflandırmada 5 adet (Benalcázar et al., 2017; Chen and Zhang, 2019; Hussain et al., 2020; Kurniawan and Pamungkas, 2018; Said et al., 2020) çalışmadan daha yüksek doğruluklar elde edilmiştir.

Tablo 6.1. Tüm veri seti kullanılarak yapılan çalışmaların karşılaştırılması

Çalışma	Kanal Sayısı	Denek Sayısı	El Hareketi Sayısı	El Hareketi Tekrar Sayısı	Öznitelik	Sınıflandırıcı	En Yüksek Doğruluk (%)
(Wahid et al., 2018)	8	10	3	10-12	MAV, ZC, WL, SSC	Random Forest	96,4
(Kanoga et al., 2020)	8	5	22	4	RMS, MAV, ZC, WL, SSC, AR	LDA	95
(Cote-Allard et al., 2017)	8	18+17	7	1+3	CNN	CNN	97,81
(Côté-Allard et al., 2019)	8	19+17	7	1+3	CWT	CNN	98,31
(Said et al., 2020)	8	23	4	10	MAV, STD, AR	SVM	89,93
(Yang et al., 2017)	8	1	6	100	RMS	GMM-HMM	99
(Benalcázar et al., 2017)	8	10	5	10	Envelope	KNN-DTW	89,5
(Chen and Zhang, 2019)	8	9	5	5	MAV, SSC, WL, RMS, Hjort	SVM	89
(Kurniawan and Pamungkas, 2018)	8	1	2	5	RMS	YSA	92,68
(Hussain et al., 2020)	8	3	14	2	RMS, STD, MIN, MAX	MLP	90,05
(Morales and Cepeda, 2017)	8	15	5	X	MAV, RMS, VAR, STD	SVM	92
Bu Çalışma	8	10	7	30	DASDV, WAMP, AAC	SVM	98,38
Bu Çalışma	7	10	7	30	DASDV, Gyro SSI	SVM	97,90
Bu Çalışma	6	10	7	30	DASDV, Gyro PKF	SVM	98,00
Bu Çalışma	5	10	7	30	DASDV, WAMP, AAC, Gyro VAR	SVM	96,76
Bu Çalışma	4	10	7	30	DASDV, WAMP, AAC, Gyro SM2	SVM	95,43
Bu Çalışma	3	10	7	30	DASDV, WAMP, AAC, Gyro SM2	SVM	92,95

Bu çalışmadaki bireysel sınıflandırma doğruluklarının ortalamaları Q-SVM ve M-SVM sınıflandırıcıları için % 99,23' tür (Tablo 4.5). Tablo 6.2 incelendiğinde elde edilen ortalama doğruluğun diğer çalışmalardan yüksek olduğu görülmektedir.

Tablo 6.2. Veri setindeki kişilere ait doğrulukların ortalamasının verildiği çalışmalar ile karşılaştırma

Çalışma	Kanal Sayısı	Denek Sayısı	El Hareketi Sayısı	El Hareketi Tekrar Sayısı	Öznitelik	Sınıflandırıcı	Ortalama Doğruluk (%)
(Hassan et al., 2019)	8	6	7	8	RMS, MAV, SSC, WL, AR	SVM	95,26
(Mendez et al., 2017)	8	8	9	5	WL, MAV, WAMP, CARD, SSC, ZC	LDA	91,67
(Mendez et al., 2017)	6	8	9	5	WL, MAV, WAMP, CARD, SSC, ZC	LDA	90,14
(Akhmadeev et al., 2017)	8	9	6	X	MAV, ZC, SSC, WL, AR	SVM	99,023
Bu Çalışma	8	10	7	30	DASDV, WAMP, AAC	SVM	99,23

6.6. Gerçek Zamanlı Sınıflandırma Doğruluklarının Literatürdeki Çalışmalar ile Karşılaştırılması

Bu çalışmada elde edilen gerçek zamanlı sınıflandırma doğruluklarının literatürdeki çalışmalar ile karşılaştırılması Tablo 6.3' de gösterilmiştir. Gerçek zamanlı sınıflandırma modelinde kişinin kendi verisinin mi yoksa tüm veri setinin mi kullanıldığı bilgisi yalnızca bir çalışmada verilmiştir ve kişilerin kendi verileri ile eğitilen sınıflandırıcıların kullanıldığı söylenmiştir (Motoche and Benalcázar, 2018). Literatürdeki çalışmalar incelendiğinde bir çalışmada % 99 doğruluk elde edilmiştir (Pinzón-Arenas et al., 2019). Bu çalışma incelendiğinde gerçek zamanlı testin bir kişi tarafından gerçekleştirildiği görülmüştür. Bu çalışmada kişi başına elde edilen gerçek zamanlı doğruluklar incelendiğinde 4 kişi için % 99' un üzerinde doğruluk elde edildiği görülmektedir (Tablo 5.2).

Tablo 6.3. Gerçek zamanlı uygulamalar ile karşılaştırma

Çalışma	Kanal Sayısı	El Hareketi Sayısı	Testi Yapan Kişi Sayısı	Bir Kişinin Tekrar Sayısı	Öznitelik	Sınıflandırıcı	Ortalama Doğruluk (%)
(Côté-Allard et al., 2019)	8	7	8	10-16	CTW	CNN	95,42
(Hassan et al., 2019)	7	7	6	X	RMS, MAV, WL, AR	SVM	94
(Said et al., 2020)	8	4	1	20	MAV, STD, AR	SVM	95
(Motoche and Benalcázar, 2018)	8	5	10	30	MAV, SSC, WL, RMS, Hjort	YSA	90,7
(Chung and Benalcázar, 2019)	8	5	60	25	Autoencoder	YSA	85,08
(Pinzón-Arenas et al., 2019)	8	6	1	160	PSD	CNN	99
Bu Çalışma	8	7	8	30	MAV	SVM	95,83

7. SONUÇ

Bu tez çalışmasında 8 kanallı Myo kol bandından alınan yüzey EMG işaretlerinde kanal sayısının sınıflandırma doğruluğuna etkisi incelenmiştir. Ayrıca kaynak taramasında kullanımına rastlanılmayan, Myo kol bandı üzerinden elde edilebilen, jiroskop özniteliklerinin de sınıflandırma performansına etkisi ilk kez bu çalışmada gözlemlenmiştir. Bu yönüyle çalışmanın literatüre yeni bir öznitelik kazandırdığı söylenebilir. F10+F7+F8 özniteliği ve C-SVM sınıflandırıcısı ile % 98,38 doğruluk elde edilmiştir. Jiroskop ile F10 özniteliği kullanıldığında sınıflandırma performansı artmıştır. En yüksek doğruluğu veren F10+F7+F8 öznitelik seti içinse doğruluğun değişmediği görülmüştür. Daha sonra farklı kanal sayılarında hem F10 hem de F10+F7+F8 özniteliği için sınıflandırma doğrulukları incelenmiştir. Özellikle daha az kanal kullanılarak yapılan sınıflandırmalarda jiroskop özniteliğinin doğruluğu daha fazla artırdığı görülmüştür. Yapılan incelemeler sonucunda kanal sayısı 3' e kadar düşürülerek ve jiroskop öznitelikleri kullanılarak güvenilir sonuçlar elde edilebileceği sonucuna varılmıştır. Sonuç olarak sınırlı sayıda kaslara sahip olan ampüte bireyler için daha az sayıda kanal kullanarak protez kol denetimi yapılabilir.

Gerçek zamanlı olmayan uygulamalar tamamlandıktan sonra model gerçek zamanlı olarak test edilmiştir. F10+F7+F8 özniteliğinin gerçek zamanlı uygulamada güvenilir sınıflandırma sonuçları vermediği görülmüştür. Bu nedenle gerçek zamanlı uygulama için diğer öznitelikler denenmiş ve F2 özniteliği ile en yüksek doğruluk elde edilmiştir. Veri setindeki iki kişi için 10 gün boyunca gerçek zamanlı doğruluklar hesaplanmıştır. Bu kişilerden biri için kendi verileri ile eğitilen sınıflandırıcıda % 98,67, tüm veri seti ile eğitilen sınıflandırıcıda % 93,95 ortalama doğruluk elde edilmiştir. Diğer kişi içinse kendi verileri ile eğitilen sınıflandırıcıda % 98,91, tüm veri seti ile eğitilen sınıflandırıcıda % 97,76 ortalama doğruluk elde edilmiştir. Bu hesaplamaların ardından veri setindeki sekiz kişi için doğruluklar hesaplanmıştır. Doğrulukların kişiden kişiye değiştiği, ancak sekiz kişi için de kendi verileri ile eğitilen sınıflandırıcıların doğruluklarının, tüm veri seti ile eğitilen sınıflandırıcıların doğruluklarından yüksek olduğu görülmüştür. Bu hesaplamalar sonucunda % 95,83 ortalama doğruluk elde edilmiştir.

Bu çalışma uzuv kaybı olan bireylerden yüzey EMG verisi alınarak tekrarlanabilir. Ayrıca gerçek zamanlı olarak bir mikrodenetleyici üzerinden gerçekleştirilebilir.

KAYNAKLAR

- Abduo, M., & Galster, M. (2015). Myo gesture control armband for medical applications.
- Aggarwal, C. C. (2015). *Data Classification Algorithms and Applications*: Taylor & Francis Group.
- 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.
- Ayhan, S., & Erdoğan, Ş. (2014). Destek vektör makineleriyle sınıflandırma problemlerinin çözümü için çekirdek fonksiyonu seçimi. *Eskişehir Osmangazi Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 9(1), 175-201.
- Barioul, R., Fakhfakh, S., Derbel, H., & Kanoun, O. (2019). *Evaluation of EMG Signal Time Domain Features for Hand Gesture Distinction*. Paper presented at the 2019 16th International Multi-Conference on Systems, Signals & Devices (SSD).
- Benalcázar, M. E., Motoche, C., Zea, J. A., Jaramillo, A. G., Anchundia, C. E., Zambrano, P., . . . Pérez, M. (2017). *Real-time hand gesture recognition using the myo armband and muscle activity detection*. Paper presented at the 2017 IEEE Second Ecuador Technical Chapters Meeting (ETCM).
- Boyalı, A., Hashimoto, N., & Matsumoto, O. (2015). *Hand posture and gesture recognition using MYO armband and spectral collaborative representation based classification*. Paper presented at the 2015 IEEE 4th Global Conference on Consumer Electronics (GCCE).
- Carvajal, D. N., & Rowe, P. C. (2010). Sensitivity, specificity, predictive values, and likelihood ratios. *Pediatr Rev*, 31(12), 511-513.
- 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.
- Chen, W., & Zhang, Z. (2019). *Hand Gesture Recognition using sEMG Signals Based on Support Vector Machine*. Paper presented at the 2019 IEEE 8th Joint International Information Technology and Artificial Intelligence Conference (ITAIC).
- Chu, J.-U., Moon, I., Lee, Y.-J., Kim, S.-K., & Mun, M.-S. (2007). A supervised feature-projection-based real-time EMG pattern recognition for multifunction myoelectric hand control. *IEEE/ASME Transactions on Mechatronics*, 12(3), 282-290.
- Chu, J.-U., Moon, I., & Mun, M.-S. (2006). A real-time EMG pattern recognition system based on linear-nonlinear feature projection for a multifunction myoelectric hand. *IEEE Transactions on biomedical engineering*, 53(11), 2232-2239.
- Chung, E. A., & Benalcázar, M. E. (2019). *Real-Time Hand Gesture Recognition Model Using Deep Learning Techniques and EMG Signals*. Paper presented at the 2019 27th European Signal Processing Conference (EUSIPCO).
- Cagnolato, M., Atzori, M., Faccio, D., Tiengo, C., Bassette, F., Gassert, R., & Müller, H. (2018). *Hand Gesture Classification in Transradial Amputees Using the Myo Armband Classifier*. Paper presented at the 2018 7th IEEE International Conference on Biomedical Robotics and Biomechanics (Biorob).
- Cote-Allard, U., Fall, C. L., Campeau-Lecours, A., Gosselin, C., Laviolette, F., & Gosselin, B. (2017). *Transfer learning for sEMG hand gestures recognition*

- using convolutional neural networks. Paper presented at the 2017 IEEE International Conference on Systems, Man, and Cybernetics (SMC).
- 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. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 27(4), 760-771.
- De Luca, C. J., Gilmore, L. D., Kuznetsov, M., & Roy, S. H. (2010). Filtering the surface EMG signal: Movement artifact and baseline noise contamination. *Journal of biomechanics*, 43(8), 1573-1579.
- Englehart, K., & Hudgins, B. (2003). A robust, real-time control scheme for multifunction myoelectric control. *IEEE Transactions on biomedical engineering*, 50(7), 848-854.
- Fraiwan, L., Awwad, M., Mahdawi, M. e., & Jamous, S. (2011). *Real time virtual prosthetic hand controlled using EMG signals*. Paper presented at the 2011 1st Middle East Conference on Biomedical Engineering.
- Ghapanchizadeh, H., Ahmad, S. A., Ishak, A. J., & Al-quraishi, M. S. (2017). Review of surface electrode placement for recording electromyography signals.
- Hassan, H. F., Abou-Loukh, S. J., & Ibraheem, I. K. (2019). Teleoperated robotic arm movement using electromyography signal with wearable Myo armband. *Journal of King Saud University-Engineering Sciences*.
- Hu, L.-Y., Huang, M.-W., Ke, S.-W., & Tsai, C.-F. (2016). The distance function effect on k-nearest neighbor classification for medical datasets. *SpringerPlus*, 5(1), 1-9.
- Hussain, J. S., Al-Khazzar, A., & Raheema, M. N. (2020). Recognition of new gestures using myo armband for myoelectric prosthetic applications. *International Journal of Electrical & Computer Engineering (2088-8708)*, 10(6).
- İşcan, M., Emeç, C., & Yeşildirek, A. (2018). *Hand gesture movement classification based on dynamically structured neural network*. Paper presented at the 2018 Electric Electronics, Computer Science, Biomedical Engineerings' Meeting (EBBT).
- Kanoga, S., Kanemura, A., & Asoh, H. (2020). Are armband sEMG devices dense enough for long-term use?—Sensor placement shifts cause significant reduction in recognition accuracy. *Biomedical Signal Processing and Control*, 60, 101981.
- Karakoyun, M., & Hacıbeyoğlu, M. (2014). Biyomedikal Veri Kümeleri İle Makine Öğrenmesi Sınıflandırma Algoritmalarının İstatistiksel Olarak Karşılaştırılması. *Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen ve Mühendislik Dergisi*, 16(48), 30-42.
- Kaya, T., & İnce, M. C. (2010). Pencere Fonksiyonu Aileleri ve Uygulama Alanları. *Erciyes Üniversitesi Fen Bilimleri Enstitüsü Fen Bilimleri Dergisi*, 26(3), 291-306.
- Kazan, S., & Karakoca, H. (2019). Makine Öğrenmesi ile Ürün Kategorisi Sınıflandırma. *Sakarya University Journal of Computer and Information Sciences*, 2(1), 18-27.
- Kocyyigit, Y., & Kilic, I. (2008). *Using LBG algorithm for extracting the features of EMG signals*. Paper presented at the 2008 IEEE 16th Signal Processing, Communication and Applications Conference.
- Kunapipat, M., Phukpattaranont, P., Neranon, P., & Thongpull, K. (2018). *Sensor-assisted EMG data recording system*. Paper presented at the 2018 15th

- International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology (ECTI-CON).
- Kurniawan, S. R., & Pamungkas, D. (2018). *MYO Armband sensors and Neural Network Algorithm for Controlling Hand Robot*. Paper presented at the 2018 International Conference on Applied Engineering (ICAE).
- Lalkhen, A. G., & McCluskey, A. (2008). Clinical tests: sensitivity and specificity. *Continuing Education in Anaesthesia Critical Care & Pain*, 8(6), 221-223.
- Matworks®. (2020). Choose Classifier Options. Retrieved from https://www.mathworks.com/help/stats/choose-a-classifier.html?searchHighlight=classifier&s_tid=srchtitle
- Mendez, I., Hansen, B. W., Grabow, C. M., Smedegaard, E. J. L., Skogberg, N. B., Uth, X. J., . . . Kamavuako, E. N. (2017). *Evaluation of the Myo armband for the classification of hand motions*. Paper presented at the 2017 International Conference on Rehabilitation Robotics (ICORR).
- Mokhlesabadifarahani, B., & Gunjan, V. K. (2015). *EMG signals characterization in three states of contraction by fuzzy network and feature extraction*: Springer.
- Moore, K. L., Agur, A. M., & Dalley, A. F. (1995). *Essential clinical anatomy* (5th Edition ed.): Williams & Wilkins.
- Morales, L., & Cepeda, J. (2017). *Feature Extraction from sEMG of Forearm Muscles, Performance Analysis of Neural Networks and Support Vector Machines for Movement Classification*. Paper presented at the ICINCO (1).
- Moreno-Torres, J. G., Sáez, J. A., & Herrera, F. (2012). Study on the impact of partition-induced dataset shift on k -fold cross-validation. *IEEE Transactions on Neural Networks and Learning Systems*, 23(8), 1304-1312.
- Motoche, C., & Benalcázar, M. E. (2018). *Real-time hand gesture recognition based on electromyographic signals and artificial neural networks*. Paper presented at the International Conference on Artificial Neural Networks.
- Okun, O., & Skarlas, L. (2011). *Feature selection and ensemble methods for bioinformatics: algorithmic classification and implementations* (Vol. 445): Medical Information Science Reference.
- Oskoei, M. A., & Hu, H. (2007). Myoelectric control systems—A survey. *Biomedical Signal Processing and Control*, 2(4), 275-294.
- Phinyomark, A., Phukpattaranont, P., & Limsakul, C. (2012). Feature reduction and selection for EMG signal classification. *Expert systems with applications*, 39(8), 7420-7431.
- Phinyomark, A., & Scheme, E. (2018). *A feature extraction issue for myoelectric control based on wearable EMG sensors*. Paper presented at the 2018 IEEE Sensors Applications Symposium (SAS).
- Pinzón-Arenas, J. O., Jiménez-Moreno, R., & Herrera-Benavides, J. E. (2019). *Convolutional neural network for hand gesture recognition using 8 different emg signals*. Paper presented at the 2019 XXII Symposium on Image, Signal Processing and Artificial Vision (STSIVA).
- 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).
- Ploengpit, Y., & Phienthrakul, T. (2016). *Rock-paper-scissors with Myo Armband pose detection*. Paper presented at the 2016 International Computer Science and Engineering Conference (ICSEC).

- Rafiee, J., Rafiee, M., Yavari, F., & Schoen, M. (2011). Feature extraction of forearm EMG signals for prosthetics. *Expert systems with applications*, 38(4), 4058-4067.
- Robertson, G. E., Caldwell, G. E., Hamill, J., Kamen, G., & Whittlesey, S. (2013). *Research methods in biomechanics: Human kinetics*.
- Said, S., Boulkaibet, I., Sheikh, M., Karar, A. S., Alkork, S., & Nait-ali, A. (2020). Machine-Learning-Based Muscle Control of a 3D-Printed Bionic Arm. *Sensors*, 20(11), 3144.
- Smith, L. H., Hargrove, L. J., Lock, B. A., & Kuiken, T. A. (2011). Determining the optimal window length for pattern recognition-based myoelectric control: balancing the competing effects of classification error and controller delay. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 19(2), 186-192.
- Stańczyk, U., & Jain, L. C. (2015). *Feature selection for data and pattern recognition*: Springer.
- Taşcı, E., & Onan, A. (2016). K-en yakın komşu algoritması parametrelerinin sınıflandırma performansı üzerine etkisinin incelenmesi. *Akademik Bilişim*.
- Tepe, C., & Demir, M. C. (2020). Detection and Classification of Muscle Activation in EMG Data Acquired by Myo Armband. *Avrupa Bilim ve Teknoloji Dergisi*, 178-183.
- 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.
- Wibawa, A. D., & Sumpeno, S. (2017). *Gesture Recognition for Indonesian Sign Language Systems (ISLS) Using Multimodal Sensor Leap Motion and Myo Armband Controllers Based-on Naïve Bayes Classifier*. Paper presented at the 2017 International Conference on Soft Computing, Intelligent System and Information Technology (ICSIIT).
- Wong, T.-T. (2015). Performance evaluation of classification algorithms by k-fold and leave-one-out cross validation. *Pattern Recognition*, 48(9), 2839-2846.
- 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).
- Zan, H., & Yıldız, A. (2018). SUPPORT VECTOR MACHINES, K NEAREST NEIGHBORS AND ENSEMBLE METHODS OF CLASSIFICATION TRAINED ON TIME, FREQUENCY AND PLP FEATURES FOR CLASSIFYING HEART SOUNDS.

ÖZ GEÇMİŞ



Mehmet Can DEMİR, 02.06.1994 tarihinde Bafra/Samsun’ da doğdu. Bafra Anadolu Lisesi’ni bitirdikten sonra Ondokuz Mayıs Üniversitesi Mühendislik Fakültesi Elektrik-Elektronik Mühendisliği Bölümü’ nden 2017 yılında mezun oldu. OMÜ Lisansüstü Eğitim Enstitüsü Elektrik-Elektronik Mühendisliği Ana Bilim Dalı Yüksek Lisans programına 2018 yılında girdi.

İletişim Bilgileri

E-mail: mehmetcandemir994@gmail.com

Telefon: 543 943 84 77

ORCID ID: 0000-0002-2372-4242

Yayınlanmış Çalışmalar

Tepe, C. and Demir, M. C. 2020. Detection and Classification of Muscle Activation in EMG Data Acquired by Myo Armband. *Avrupa Bilim ve Teknoloji Dergisi*, 178-183.