

**BURSA TEKNİK ÜNİVERSİTESİ ❖ FEN BİLİMLERİ ENSTİTÜSÜ**

**AKILLI EL PROTEZ KONTROLÜ KARAR VERME PERFORMANSINA  
ELEKTROMİYOGRAFİ SİNYALLERİNİN ÇOK DEĞİŞKENLİ GÖRGÜL KİP  
AYRIŞIMI İLE ANALİZİNİN ETKİLERİ**

**YÜKSEK LİSANS TEZİ**

**Fatih ONAY**

**Mekatronik Mühendisliği Anabilim Dalı**

**HAZİRAN 2019**

**BURSA TEKNİK ÜNİVERSİTESİ ❖ FEN BİLİMLERİ ENSTİTÜSÜ**

**AKILLI EL PROTEZ KONTROLÜ KARAR VERME PERFORMANSINA  
ELEKTROMİYOGRAFİ SİNYALLERİNİN ÇOK DEĞİŞKENLİ GÖRGÜL KİP  
AYRIŞIMI İLE ANALİZİNİN ETKİLERİ**

**YÜKSEK LİSANS TEZİ**

**FATİH ONAY  
(171081519)**

**Mekatronik Mühendisliği Anabilim Dalı**

**Tez Danışmanı: Doç. Dr. Ahmet MERT**

**HAZİRAN 2019**

BTÜ, Fen Bilimleri Enstitüsü'nün 171081519 numaralı Yüksek Lisans Öğrencisi Fatih Onay, ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı "Akıllı El Protez Kontrolü Karar Verme Performansına Elektromiyografi Sinyallerinin Çok Değişkenli Görgül Kip Ayrışımı İle Analizinin Etkileri" başlıklı tezini aşağıda imzaları olan jüri önünde başarı ile sunmuştur.

**Tez Danışmanı :** **Doç. Dr. Ahmet MERT** .....  
Bursa Teknik Üniversitesi

**Jüri Üyeleri :** **Doç. Dr. Gökhan GELEN** .....  
Bursa Teknik Üniversitesi

**Dr. Öğr. Üyesi Ömer KASIM** .....  
Kütahya Dumlupınar Üniversitesi

**Savunma Tarihi :** 20 Haziran 2019

**FBE Müdürü :** **Doç. Dr. Murat ERTAŞ** .....  
Bursa Teknik Üniversitesi

...../...../.....





*Beni seven herkese,*

## ÖNSÖZ

Öncelikle, tez çalışmam süresince bana her konuda destek olan ve yol gösteren değerli danışmanım Doç. Dr. Ahmet Mert'e en içten teşekkürlerimi sunarım. Bana olan inancını hiç bir zaman kaybetmeyen anneme ve babama, bana verdikleri desteklerden dolayı minnettarım. Onların ellerinden öpmeyi kendime borç bilirim. Bu tez çalışmasına maddi katkı sağlayan Bursa Teknik Üniversitesi Bilimsel Araştırma Projeleri Birimine de teşekkürü bir borç bilirim.

Haziran 2019

Fatih Onay



## İÇİNDEKİLER

### Sayfa

ÖNSÖZ .....	v
İÇİNDEKİLER .....	vi
KISALTMALAR .....	viii
SEMBOLLER .....	ix
ÇİZELGE LİSTESİ.....	x
ŞEKİL LİSTESİ.....	xi
ÖZET .....	xiii
SUMMARY .....	xiv
<b>1. GİRİŞ .....</b>	<b>1</b>
1.1 Literatür Araştırması .....	4
1.2 Elektromiyografi Sinyali Yapısı.....	5
1.3 sEMG Sinyalinin Ölçülmesi.....	11
1.3.1 Elektrod Yapısı .....	13
1.3.2 Derinin Temizlenmesi .....	15
1.3.3 Elektrodların Yerleşimi .....	15
1.4 3B Yazıcı ve Protez Eller .....	16
<b>2. MATERYAL METOD .....</b>	<b>18</b>
2.1 Veri Seti.....	18
2.2 EMG Sinyal İşleme .....	19
2.2.1 Filtreleme .....	20
2.2.2 Doğrultma ve Yumuşatma .....	20
2.3 Görgül Kip Ayrışımı .....	21
2.4 Çok Değişkenli Görgül Kip Ayrışımı .....	28
2.5 Öznitelik Çıkarma .....	32
2.6 Sınıflandırma.....	33
2.6.1 <i>k</i> -Yakın Komşu Sınıflandırıcı .....	34
2.6.2 Doğrusal Ayrım Analizi.....	35
2.6.3 Destek Vektör Makinesi.....	37
2.7 Deney Süreci .....	40
2.7.1 Öznitelik Çıkarma Süreci.....	41
2.7.2 Sınıflandırma Süreci .....	43
<b>3. BULGULAR .....</b>	<b>45</b>
3.1 ÇDGKA Yöntemi ile ÖKF Bileşenlerinin Bulunması.....	46
3.2 ÖKF Tabanlı Özniteliklerin Sınıflandırılması ve ÖKF'lerin Eliminasyonu ....	49
3.3 sEMG Sinyallerinin Protez Kontrolü için Kısa Zamanlı Analizi.....	53
3.3.1 ÇDGKA ile ÖKF'lerin bulunması .....	55
3.3.2 Kullanıcı Bağımlı Sınıflandırma .....	56
3.3.3 Kullanıcı Bağımsız Sınıflandırma.....	57
3.4 Protez El Kontrolü ve Uygulaması.....	61
<b>4. SONUÇLAR .....</b>	<b>63</b>

<b>KAYNAKLAR</b> .....	<b>65</b>
<b>EKLER</b> .....	<b>69</b>
<b>ÖZGEÇMİŞ</b> .....	<b>71</b>





## KISALTMALAR

<b>ÇDGKA</b>	: Çok Değişkenli Görgül Kip Ayrışımı
<b>EEG</b>	: Elektroensefalografi
<b>EMG</b>	: Elektromiyografi
<b>EOG</b>	: Elektrokofiyografi
<b>GKA</b>	: Görgül Kip Ayrışımı
<b>k-NN</b>	: k- Yakın komşu
<b>LDA</b>	: Doğrusal Ayrım Analizi
<b>ÖKF</b>	: Özgül Kip Fonksiyonu
<b>RMS</b>	: Etkin Değer
<b>sEMG</b>	: Yüzey elektromiyografi
<b>SVM</b>	: Destek Vektör Makinesi
<b>WL</b>	: Dalga Formu
<b>ZC</b>	: Sıfır Geçiş Sayısı

## SEMBOLLER

<b>Cl</b>	: Klor
<b>K</b>	: Potasyum
<b>Na</b>	: Sodyum
<b><math>\sigma^2</math></b>	: Varyans



## ÇİZELGE LİSTESİ

	<u>Sayfa</u>
<b>Tablo 2.1 :</b> Çalışmada yer alan katılımcıların bilgisi. ....	<b>19</b>
<b>Tablo 3.1 :</b> Bütün kuvvet seviyelerinden elde edilen ÖKF'lerin ortalama frekans değerleri. ....	<b>49</b>
<b>Tablo 3.2 :</b> Tüm kuvvet seviyeleri için ÖKF sayısına göre elde edilen doğruluk oranları. ....	<b>53</b>
<b>Tablo 3.3 :</b> ÖKF'lerin ortalama frekans değerleri. ....	<b>55</b>
<b>Tablo 3.4 :</b> Kullanıcı-Bağımlı sınıflandırma sonuçları. ....	<b>56</b>
<b>Tablo 3.5 :</b> Kullanıcı içi kuvvetten bağımsız sınıflandırma sonuçları. ....	<b>56</b>
<b>Tablo 3.6 :</b> Tüm kuvvet seviyeleri bir arada ve ayrı ayrı olarak kullanıcı-bağımsız sınıflandırma sonuçları. ....	<b>58</b>

## ŞEKİL LİSTESİ

### Sayfa

Şekil 1.1 : Hücre zarı içindeki potansiyel değişimleri [28].	7
Şekil 1.2 : Aksiyon potansiyeli ve fazları	7
Şekil 1.3 : Hücre zarı potansiyel dağılımı (a,b) ve zardaki konuma göre aksiyon potansiyeli genliği (c) [27].	8
Şekil 1.4 : Voltaj kapılı sodyum kanalı [29].	9
Şekil 1.5 : Motor birimi yapısı [30].	9
Şekil 1.6 : Motor birimi aksiyon potansiyelinin ( $h(t)$ ) oluşumu [32].	10
Şekil 1.7 : Motor birimi X ve Y (üstte) Motor birimi fiber sayısına göre oluşturulan uyarı (altta) [34].	11
Şekil 1.8 : Motor ünitelerinin aksiyon potansiyellerinin analizinde karşılaşılan problemler [32].	12
Şekil 1.9 : Düşük, orta ve yüksek güç seviyelerine ait sEMG işaretleri genlikleri ...	13
Şekil 1.10 : Elektrod-elektrolit arayüzü (Elektrotan elektrolite doğru olan akım akışının gösterilişi [27].	14
Şekil 1.11 : Pratik uygulamalar için kullanılabilir bir EMG sensörünün tipik yapısı [38].	15
Şekil 1.12 : Elektrod için uygun konum (motor birimi ve tendon arasında) [38].	16
Şekil 1.13 : Open Bionic Ada Hand protez eli [42].	17
Şekil 2.1 : Altı sınıflı veri seti el hareketleri (1: BP, 2: İP, 3: ÇK, 4:TK, 5: KK, 6:KÜK).	18
Şekil 2.2 : Doğrultma (üstte) ve yumuşatma (altta) işlemi.	21
Şekil 2.3 : Örnek $x(t)$ sinyali.	22
Şekil 2.4 : $x(t)$ (mavi) sinyalinin yerel ekstremum noktaları ile bulunan alt ve üst zarfları (yeşil) ve zarfların ortalaması (kırmızı) [48].	23
Şekil 2.5 : $x(t)$ verisi (kırmızı) and $h_1(t)$ (mavi) [48].	23
Şekil 2.6 : $h_1$ ve $m_2$ ile devam eden eleme süreci [48].	24
Şekil 2.7 : $h_2$ ve $m_3$ ile devam eden eleme süreci [48].	24
Şekil 2.8 : Eleme sürecinde 12. adım ve İlk ÖKF bileşeni $c_1$ [48].	25
Şekil 2.9 : Orijinal veri $x(t)$ (mavi) ve artık $r_1(t)$ .	26
Şekil 2.10 : GKA Algoritması Akış Diyagramı.	27
Şekil 2.11 : (a) Üç boyutlu düzlemde O merkezli küre (b) Örnek dönme eksenine $u$ .	29
Şekil 2.12 : Yön vektörlerini oluşturacak nokta dağılımları (a) Unifrom açısal örnekleme yöntemi (b) düşük tutarsızlıklı Hammersley yöntemi.	30
Şekil 2.13 : Örnek sEMG Sinyali.	31
Şekil 2.14 : Amputenin 4. Kanalından alınan sEMG sinyalinin ilk 10 ÖKF'sine ait veriler.	31
Şekil 2.15 : $k$ -NN sınıflandırma aşaması	35

<b>Şekil 2.16</b> : SVM algoritması için verileri sınıflandırma işleminin gerçekleştirilmesi (a) Olası hiperdüzlemler (b) Maksimum marjini sağlayan hiperdüzlem. ....	<b>37</b>
<b>Şekil 2.17</b> : Karar sınırları ve marjin. ....	<b>39</b>
<b>Şekil 2.18</b> : Analiz edilecek uygun sinyal uzunluğunun belirlenmesi. ....	<b>41</b>
<b>Şekil 2.19</b> : Sinyale uygulana pencereleme işlemi. ....	<b>41</b>
<b>Şekil 2.20</b> : Tek bir kanal için öznitelik vektörünün elde edilmesi. ....	<b>42</b>
<b>Şekil 2.21</b> : Sınıflandırma için tüm verilerin elde edilme süreci. ....	<b>42</b>
<b>Şekil 2.22</b> : Verilerin sınıflandırılmasında izlenen süreç.....	<b>43</b>
<b>Şekil 2.23</b> : Sınıflandırma sürecinde 5- katlamalı çapraz doğrulama yönteminin uygulanması .....	<b>44</b>
<b>Şekil 2.24</b> : ÇDGKA tabanlı öznitelik çıkarma süreci genel akış diyagramı .....	<b>44</b>
<b>Şekil 3.1</b> : İlk amputeden alınan orta kuvvet seviyesindeki BP hareketine ait EMG sinyali. ....	<b>45</b>
<b>Şekil 3.2</b> : İlk amputeden alınan orta kuvvet seviyesindeki BP hareketinin, birinci kanal sEMG sinyaline ait ilk 7 ÖKF bileşeni. ....	<b>46</b>
<b>Şekil 3.3</b> : İlk amputeden alınan orta kuvvet seviyesindeki BP hareketinin, ilk kanal sEMG sinyaline ait son 6 ÖKF bileşeni ve artık.....	<b>47</b>
<b>Şekil 3.4</b> : Orta kuvvet seviyesindeki BP hareketine ait 8 kanallı sEMG sinyalinin ÇDGKA kullanılarak elde edilen ÖKF'lerinin ortalama frekans değerleri. ....	<b>48</b>
<b>Şekil 3.5</b> : Sinyallerden elde edilen ÖKF sayılarının dağılımı. ....	<b>48</b>
<b>Şekil 3.6</b> : Üçüncü amputenin düşük kuvvet seviyesindeki tüm kanallara ait 10 ÖKF'sinin WL- $\sigma^2$ -Rms öznitelikleri dağılımı. ....	<b>50</b>
<b>Şekil 3.7</b> : Tüm amputelerden alınan düşük kuvvet seviyesindeki KÜK hareketinin tüm kanallarına ait 10 ÖKF'sinin WL- $\sigma^2$ -rms öznitelikleri dağılımı.....	<b>50</b>
<b>Şekil 3.8</b> : Kullanıcı-Bağımlı düşük kuvvet seviyesi sınıflandırma sonuçları. ....	<b>51</b>
<b>Şekil 3.9</b> : Kullanıcı-Bağımlı orta kuvvet seviyesi sınıflandırma sonuçları.....	<b>51</b>
<b>Şekil 3.10</b> : Kullanıcı-Bağımlı yüksek kuvvet seviyesi sınıflandırma sonuçları.....	<b>52</b>
<b>Şekil 3.11</b> : KNN, LDA ve SVM için sınıflandırma sonuçları.....	<b>52</b>
<b>Şekil 3.12</b> : Yüksek kuvvet sEMG işaretine uygulanan pencereleme işlemi. ....	<b>54</b>
<b>Şekil 3.13</b> : Sinyalden elde edilen ilk üç pencere .....	<b>54</b>
<b>Şekil 3.14</b> : Tek bir pencereden elde edilen ÖKF bileşenleri. ....	<b>55</b>
<b>Şekil 3.15</b> : Tüm kuvvet seviyeleri için altı farklı parmak hareketinin 1. kanal 6 ÖKF'sine ait özniteliklerin dağılımı. ....	<b>57</b>
<b>Şekil 3.16</b> : Tüm kuvvet seviyeleri için altı farklı parmak hareketinin 1. kanalına ait ham sinyallerden çıkarılan özniteliklerin dağılımı.....	<b>57</b>
<b>Şekil 3.17</b> : KNN, LDA ve SVM sınıflandırıcıları ile her bir kuvvet seviyesi kullanıcı-bağımsız olarak. ....	<b>58</b>
<b>Şekil 3.18</b> : $k$ -NN ile ÇDGKA tabanlı özniteliklerin kullanıcı-bağımsız düşük kuvvet seviyesi sınıflandırma sonuçlarına ait karışıklık matrisi.....	<b>59</b>
<b>Şekil 3.19</b> : $k$ -NN ile ÇDGKA tabanlı kullanıcı-bağımsız orta kuvvet seviyesi sınıflandırma sonuçlarına ait karışıklık matrisi.....	<b>59</b>
<b>Şekil 3.20</b> : $k$ -NN ile ÇDGKA tabanlı kullanıcı bağımsız yüksek kuvvet seviyesi sınıflandırma sonuçlarına ait karışıklık matrisi.....	<b>60</b>
<b>Şekil 3.21</b> : $k$ -NN ile ÇDGKA tabanlı kullanıcı bağımsız tüm kuvvet seviyeleri bir arada sınıflandırma sonuçlarına ait karışıklık matrisi. ....	<b>60</b>
<b>Şekil 3.22</b> : Üretilen prototip protez el (a) KÜK hareketi (b) ÇK Hareketi .....	<b>61</b>
<b>Şekil 3.23</b> : Prototip protez el kontrolü için Matlab arayüzü.....	<b>62</b>
<b>Şekil 3.24</b> : Protez Elin Kontrol Süreci .....	<b>62</b>

# AKILLI EL PROTEZ KONTROLÜ KARAR VERME PERFORMANSINA ELEKTROMİYOGRAFİ SİNYALLERİNİN ÇOK DEĞİŞKENLİ GÖRGÜL KİP AYRIŞIMI İLE ANALİZİNİN ETKİLERİ

## ÖZET

Elektromiyografi (EMG) sinyalleri, insan-makine etkileşimli çok fonksiyonlu akıllı el protezlerinin kontrolünde önemli bir rol oynamaktadır. Kas aktivesinin bir sonucu olarak ortaya çıkan EMG sinyalleri, yapılan aktiviteye dair özel bilgileri kendi içerisinde ihtiva etmektedir. Dolayısıyla akıllı el protezlerinin işlevselliğinin artırılması, kas bölgesinden toplanan EMG sinyalinin doğru bir şekilde analiz edilip yorumlanmasına önemli ölçüde bağlıdır. Bu konseptte uygun olarak, akıllı el protezi hareketlerinin karar verme sürecinde, EMG sinyallerinin güvenilir bir şekilde kullanılabilmesi için, var olan yöntemlerin geliştirilmesi ya da bu yöntemlere üstünlük sağlayacak yeni yöntemler önerilmesi gerekmektedir. Bu tez çalışması kapsamında, çok kanallı EMG sinyallerinin analizinin geliştirilmesi amacıyla, çok değişkenli görgül kip ayrışımı (ÇDGKA) tabanlı öznitelik çıkarma yöntemi, geleneksel metotlara alternatif olarak sunulmuştur. Sinyali adaptif olarak salınım modlarına ayıran ÇDGKA yöntemi kullanılarak, EMG sinyalinden daha anlamlı bilgi edinilmesi amaçlanmıştır. ÇDGKA tabanlı özniteliklerin farklı el ve parmak hareketlerini ayırt etme performansı ve farklı kuvvet seviyelerine karşı gösterdiği performans incelenmiştir. Bu amaçla ampute katılımcıların artık uzuvlarından toplanan düşük, orta ve yüksek kuvvet seviyelerine ait sekiz kanallı yüzey elektromiyografi (sEMG) sinyalleri üzerinde ÇDGKA yöntemi uygulanarak özgül kip fonksiyonları (ÖKF) elde edilmiştir. Elde edilen ÖKF'lerden çıkarılan öznitelikler kullanılarak altı farklı el ve parmak hareketi, en yakın komşu ( $k$ -NN), doğrusal ayırım analizi (LDA) ve destek vektör makinesi (SVM) sınıflandırıcıları kullanılarak sınıflandırılmıştır. Kullanıcı-bağımlı, kullanıcı-bağımsız ve hem kullanıcı hem de kuvvetten bağımsız sınıflandırmalar neticesinde, önerilen ÇDGKA tabanlı özniteliklerin ham sinyal tabanlı özniteliklere göre kullanıcı-bağımlı için %1, kullanıcı-bağımsız için %15 - %20, kullanıcı ve kuvvet bağımsız için %15'e kadar üstünlük sağladığı belirlenmiştir. Uygun el protezi üretilerek, kayıtlı EMG sinyallerinden hangi el hareketinin yapılmak istendiği tespit edilerek, protezin bilgisayar destekli kontrolü gerçekleştirilmiştir.

**Anahtar kelimeler:** Elektromiyografi, Çok değişkenli görgül kip ayrışımı, İnsan-Makine Etkileşimi, El protezi, Kontrol.

# **THE EFFECTS OF MULTIVARIATE EMPIRICAL MODE DECOMPOSITION ANALYSIS OF ELECTROMYOGRAPHY SIGNALS ON INTELLIGENT HAND PROTHESIS CONTROL DECISION MAKING PERFORMANCE**

## **SUMMARY**

Electromyography (EMG) signals play an important role in the control of human-machine interfaced multifunctional smart hand prostheses. The EMG signals emerged as a result of muscle activity contain specific information about the activity. Therefore, enhancing the functionality of intelligent hand prostheses significantly depends on the precise analysis and interpretation of the EMG signals that are collected from the muscle region. In accordance with this concept, in order to use EMG signals reliably in the decision-making process of smart hand prosthesis movements, it is necessary to improve present methods or to propose new methods to be superior to these methods. In this thesis, multivariate empirical decomposition (MEMD) based feature extraction method is presented as an alternative to traditional methods to improve the analysis of multichannel EMG signals. It is aimed to obtain more meaningful information from EMG signals by using the MEMD method which separates the signal into adaptive oscillation modes. The performance of discriminating hand and finger movements at different force levels of the MEMD based features was investigated. For this purpose, intrinsic mode functions (IMF) were obtained by using the MEMD method on eight-channel surface electromyography signals of low, medium and high force levels collected from the amputated participants. The features which are extracted from IMFs, classified by  $k$  nearest neighbours (k-NN), linear discriminant analysis (LDA) and support vector machines (SVM) to discriminate six hand and finger movements. User-dependent, user-independent, both user and force-independent classification operations were performed. The proposed MEMD based features have provided 1% for user-dependent classification, 15% -20% for user-independent and 15% for both user and force-independent more accuracy than raw signal-based features. A suitable prosthetic hand has been produced in order to control and simulate the computer-aided prosthetic hand by using EMG signals.

**Anahtar kelimeler:** Electromyography, Multivariate Empirical Mode Decomposition, Human-Machine Interface, Hand Prosthesis, Control.

## 1. GİRİŞ

İnsan vücudunda meydana gelen uzuv kayıpları; doğuştan, sonradan yaşanan kazalar ve hastalıklar sebebiyle meydana gelebilmektedir. Bunun sonucu olarak da engelli insan sayısı her geçen gün artmaktadır. Dolayısıyla, engelli insanların yaşam kalitesini arttırmak için araştırmacılar, basit ve doğal insan-makine kontrol ara yüzünün gerekliliğini düşünmektedir. İnsan-makine arayüzü için özel bir dokudan, organdan veya sinir sisteminden elde edilen elektroensefalografi (EEG) [1], elektrookülografi (EOG) [2] veya elektromiyografi (EMG) gibi çeşitli biyolojik sinyaller kullanılabilir. Ses komutları [3] ve kuvvet sensörleri [4] gibi başka yöntemler kullanılarak da bu ara yüzleri oluşturmak için çalışmalar yapılmaktadır. Biyolojik sinyaller ise insan-makine etkileşiminde akıllı protezlerin, robotların [5] ve yardımcı araçların [6] kullanımını mümkün kılmakta ve bu alanda yapılan çalışmalara yeni kapılar açmaktadır.

Üst ekstremité amputasyona sahip ve günlük hayatta basit el hareketlerini gerçekleştiremeyen bireyler için geliştirilen çok fonksiyonlu akıllı el protezleri, insan-makine etkileşimli cihazlardır. Bu protezler kullanıcının ihtiyaçlarına hızlı bir şekilde cevap verebilmeli ve hassas olarak çalışmalıdır. Bu kriterleri temin edebilecek unsurlardan biri ise protez kontrolünün geliştirilmesidir. Ampute bireylerin kalan uzuvlarından alınan biyolojik sinyaller ile protez kontrolü gerçekleştirmek mümkündür. Biyolojik sinyaller, kontrol edilen akıllı protezlerin kullanıcıya sağladığı sezgisel kontrol imkânıyla beraber karmaşık görevlerin gerçekleştirilmesine olanak sağlar. Ampute bireylerin günlük ihtiyaçlarını karşılayabilecek çok fonksiyonlu akıllı protezlerin kontrol karmaşıklığı, biyolojik sinyaller ve makine öğrenmesi tabanlı algoritmalar yardımıyla çözüme kavuşturulabilir. İnsan-makine etkileşimli güçlendirilmiş akıllı protezlerin kontrolü için EMG sinyali tercih edilir çünkü EMG sinyalleri diğer biyolojik sinyallere göre daha yüksek sinyal-gürültü oranına sahiptir. Ayrıca EEG ve EOG tabanlı kontrol yöntemlerine göre kullanıcının daha az efor sarf etmesini gerektirdiğinden, EMG sinyali güçlendirilmiş akıllı protezlerin kontrolünde giriş sinyali olarak yaygın bir kullanıma sahiptir [7]. Miyoelektrik kontrol yöntemi



yıllardır kullanılmakta ve laboratuvar ortamlarında başarılı sonuçlar vermektedir. Elde edilen bu başarılı sonuçlara rağmen, ampute bireylerin gündelik hayatta fonksiyonlu hareketleri gerçekleştirebilmelerini sağlayacak pratik protezlerin geliştirilmesi için halen çalışmalara ihtiyaç vardır [8].

Elektromiyografi sinyali, insan kasları içerisinde bulunan bireysel motor ünitelerinin aktivitesi sonucu ortaya çıkan bir işarettir. Bu işaret kas bölgelerinde deri üzerine yerleştirilen yüzey elektrotları ya da kas dokusuna batırılan iğne benzeri elektrodlar yardımıyla toplanabilir [9]. Yapılan çalışmalar invaziv yöntemlerle invaziv olmayan yöntemlerin benzer doğrulukta sonuçlar verdiğini göstermiştir [10]. Yüzey EMG (sEMG) yönteminin invaziv olmaması ve invaziv yöntemlere göre daha kolay kullanıma sahip olması nedeniyle güçlendirilmiş protezlerin kontrolünde yer alması tercih edilir.

Çok fonksiyonlu bir protez elin kontrolünde kullanılan EMG sinyalinin tek bir kanaldan alınması sinyalin sınıflandırılmasını zorlaştırır. Englehart ve arkadaşları [11] çok kanallı EMG sinyali kullanarak çok fonksiyonlu bir protezin hareketlerinin daha kolay sınıflandırılabileceğini göstermişlerdir. Yüzey elektrotları yardımı ile elde edilen çok kanallı EMG sinyalini kullanmak için gelişmiş sinyal ayrıştırma ve sınıflandırma algoritmaları kullanılmalıdır. EMG sinyallerini ham olarak kullanılmasından ziyade, ayrıştırılıp matematiksel modellere dayanan öznelik vektörleriyle kullanılması tercih edilir. Böylece sinyalin bilgi içeriği, rastgele ve karmaşık olan ham sinyale göre daha doğru bir şekilde tanımlanır. Bu sebeple EMG sinyalinin matematiksel olarak minimum hata ile tespit edilmesi ve sinyalin barındırdığı bilginin verimli bir şekilde kullanılabilmesi için hesaplama yöntemlerinin geliştirilmesi gerekmektedir. Ayrıca ortaya çıkacak verinin kullanışlı bir analizini yapmak ise oldukça önemlidir [12].

Sinir sistemi tarafından kontrol edilen kaslarda meydana gelen kasılma ve gevşeme hareketleri sonucunda zamanın bir fonksiyonu olarak ortaya çıkan EMG sinyali, genliği, frekansı ve fazı açısından tanımlanabilir [13]. Yüzey elektrotları yardımıyla toplanan EMG sinyalinin içinde barındırdığı genlik ve frekans bileşenlerini doğru bir şekilde tespit etmek gerekmektedir. Fakat bu işlemi gerçekleştirmek EMG sinyalinin doğrusal olmayan ve lineer olmayan karakteristiği yüzünden kolay değildir. Bu yüzden yapılan uygulamanın niteliğine göre bir EMG sinyalinin zaman, frekans ve zaman-frekans tabanında analizinin yapılması, doğru çıkarımlar yapabilmek için önemlidir.

Yüzey EMG sinyalinin analizi çoklukla zaman tabanında gerçekleştirilir. Zaman tabanlı analiz işlemi herhangi bir matematiksel dönüşüm gerektirmez, bundan dolayı da hesaplanması hızlıdır. Bununla birlikte, bu işlemleri etkin bir şekilde gerçekleştirebilmek için, doğru bir EMG sinyal edinimi şarttır. Bir EMG sinyali kaydedilirken, elektronik ekipman ve fizyolojik faktörlerin varlığından kaynaklanan çeşitli arka plan gürültüleri de sinyalle beraber kaydedilir. Bu yüzden EMG sinyaline ön-işleme uygulandıktan sonra sinyalin işleme süreci başlatılmalıdır.

Deri yüzeyine elektrotlar bağlanarak alınan EMG sinyalleri belirtmek için kullanılan sEMG ve çok kanallı sEMG sinyallerinin analizinde zaman düzleminde genlik ve enerji gibi temel sinyal analiz yöntemleri kullanılırken, frekans düzlemi yöntemleri arasında Fourier dönüşümü (FD) ve dalgacık dönüşümü (DD) gibi sinyal işleme yöntemleri kullanılmaktadır. Gerçekleştirilen farklı kas hareketlerinden elde edilen işaretlerin arasındaki farkları tespit etmek için gelişmiş sinyal işleme teknikleri kullanılmalıdır. Ayrıca, birden fazla kas grubunun aynı anda çalıştığı hareketler için de ayırt edici özelliklerin bulunması gerekmektedir. Bu özelliklerin kullanılarak, kas aktivitesini makine öğrenmesi algoritmaları yardımı ile tespit etmek, akıllı protezlerin kontrolünün geliştirilmesi için gereken bir unsurdur [14].

Bu tez kapsamında, doğrusal olmayan ve durağan olmayan sinyallerin işlenmesinde taban fonksiyonuna ihtiyaç duyan analitik sinyal işleme yöntemlerine alternatif olarak geliştirilen çok değişkenli görgül kip ayrışımı yöntemi (ÇDGKA) kullanılacaktır. EMG sinyali gibi doğrusal olmayan ve durağan olmayan sinyaller, önceden belirlenen bir taban fonksiyonunun karakteristiğinden farklı bir yapıya sahip olabilir bu da analizin doğru olarak yapılamamasına sebep olabilmektedir. ÇDGKA yöntemi klasik sinyal işleme metodlarından farklı olarak, herhangi bir taban fonksiyonunu kullanmamaktadır. Ayrıca ÇDGKA algoritma tabanlı ve sinyal uyarlamalı bir yöntemdir. Bu çalışmanın amacı ise, güncel ve gelişmiş sinyal işleme yöntemi olan ÇDGKA ile farklı kas gruplarının eş zamanlı çalışması neticesinde oluşan çok kanallı sEMG sinyallerinin ayırt edici analizini gerçekleştirmek, bunun neticesinde de altı farklı parmak hareketinin kombinasyonunu yansıtan sEMG sinyallerini doğru bir şekilde ayırt edebilmektir.

## 1.1 Literatür Araştırması

Ham EMG sinyali, içerisinde kas hareketlerine ait bilgiler barındırmaktadır. Bu bilgi, sayısal olarak ölçülebilirse yararlı hale getirilebilir. Doğru ve geçerli bilgiyi elde etmek için ham EMG'ye çeşitli sinyal işleme yöntemleri uygulanmaktadır. Bu bölümde literatürde bu konu hakkında yapılan çalışmalar incelenerek EMG sinyal işleme yöntemleri hakkında bilgi verilecektir.

Walsh 1773 yılında yılan balığının kıvılcım ürettiğini görmüş ve canlıların dokularında bir çeşit enerjinin varlığını tespit etmiştir. 1792 yılında ise Luigi Galvani bir kurbağanın bacağındaki elektriksel aktiviteyi yaptığı deneylerle gözlemlemiş ve elektriksel işaretlerin kaslarda kasılma meydana getirebileceğini göstermiştir. Biyolojik sistemlerin yapısında keşfedilen elektriksel sinyallerin yorumlanması, ayrıştırılması ve uygulamalarda kullanılabilmesine yönelik çalışmalar, 1970 ve 1980'li yıllardan itibaren teknolojik gelişmelerle beraber araştırmacıların daha çok ilgisini çekmeye başlamıştır. EMG sinyalinin durağan olmayan ve doğrusal olmayan karakteristiğinden dolayı araştırmacılar yeni yöntemler geliştirmek için çalışmalar yürütmüşlerdir. Bu çalışmalarla beraber EMG sinyali protez kontrolünde kendine yer bulmuştur [15].

Tenore F. ve ark.[16] sağlıklı katılımcıların ön kol kaslarından aldıkları sEMG sinyalleri ile 12 farklı parmak hareketini zaman tabanına dayanan öznelikleri kullanarak yapay sinir ağları ile sınıflandırmışlardır. Başarılı sonuçlar elde etmelerine rağmen ampute bireylerden alınan sinyaller ile yapılan çalışmaların aynı derecede başarılı olmadığını belirtmişler ve bu alanda daha fazla araştırma yapılması gerektiğine işaret etmişlerdir. M. Jiang ve ark. [17] çok-çözünürlüklü dalgacık dönüşümü ile 2 kanallı ve 4 kanallı sEMG sinyalleri ile altı farklı parmak hareketini sınıflandırmışlardır. Yaptıkları çalışma neticesinde kanal sayısının artmasıyla elde edilen sonuçların daha başarılı olduğunu göstermişlerdir. Lucas ve ark. [18] ayrık dalgacık dönüşümünü kullanarak 8 kanallı sEMG sinyali için altı sınıflı el hareketlerinin destek vektör makineleri ile sınıflandırmasını yapmışlardır. Yapılan çalışmada, dalgacık dönüşümünde kullanılan taban fonksiyonlarının, elde edilen sonuçlar üzerindeki etkisinin yüksek olduğu belirlenmiştir. Bu sebeple taban fonksiyonunun belirlenmesi için hesaplama yükü ağır olan optimizasyon yöntemi

geliştirmişlerdir. Buna rağmen seçilen taban fonksiyonuna göre elde edilen sınıflandırma başarısı kişiden kişiye farklılık göstermiştir.

Geethanjali[19] tarafından yapılan çalışmada altı sınıflı el hareketlerinin sınıflandırılması için çok kanallı sEMG sinyalleri kullanılmıştır. Sağlıklı bireyler için dört kanallı bir edinim sistemi kullanılırken, benzer şekilde bir transradial amputeler içinse kas sisteminin tanımlanmasındaki zorluklar nedeniyle sekiz kanallı bir EMG edinim sistemi kullanılmıştır. Ampute bireyler için daha fazla kanal kullanılarak, toplanan bilginin artırılması amaçlanmıştır. Hem sağlıklı bireyler hem de ampute bireyler için aynı öznelik ve sınıflandırıcılar kullanılarak yapılan çalışma neticesinde ampute bireylere ait öznelikler kullanılarak elde edilen sınıflandırma başarısı sağlıklı bireylere göre daha düşük seviyede kalmıştır. El hareketlerini sEMG sinyalleri kullanarak ayırt etmeye çalışan Sapsanis ve ark. [20] görgül kip ayrışımı tabanlı öznelikler kullanarak özneliklerin performansını arttırmayı amaçlamışlardır. Fakat yaptıkları çalışma sonucunda görgül kip ayrışımı tabanlı öznelikler ham sinyallerden elde edilen özneliklerin performansından düşük kalmıştır.

Geçmişte yapılan bu çalışmalar, EMG sinyali için halen farklı analiz yöntemlerinin geliştirilip denenmesi gerekliliğini ortaya koymaktadır. Sinyalin doğrusal-durağan olmayan yapısı sebebiyle önceden belirlenmiş bir taban fonksiyonuna bağlı olmaksızın adaptif olarak analiz edilmesini sağlayan GKA yöntemi, EMG sinyal analizinde kullanılmaya başlanmıştır [21]. GKA tek kanallı sinyallerin analizine uygun olarak sinyalin doğal salınım modlarını bulurken, çok kanallı sinyallerin salınım modlarının frekans bantlarını hassas olarak ayıramamaktadır [22]. Çok kanallı sinyallerin analizinde GKA'nın etkili bir şekilde kullanılabilmesi için araştırmacılar, iki değişkenli GKA [23], üç değişkenli GKA [24] ve sonunda çok değişkenli görgül kip ayrışımı (ÇDGKA) [25] yöntemlerini önermişlerdir. Bu tez kapsamında çok kanallı sEMG sinyali ÇDGKA yöntemi ile salınım modlarına ayrıştırılacaktır. Salınım modları kullanılarak sinyalin analizi ve öznelik çıkarma işlemi yapılacaktır.

## **1.2 Elektromiyografi Sinyali Yapısı**


İnsan vücudunda yer alan sistemler, çeşitli eylemleri gerçekleştirirken bazı işaretler üretirler. Bu işaretler vücudun içerisindeki biyolojik yapıların ortaya çıkardığı çalışmalara dair bilgiler taşır. Bu yüzden gerçek bir elin hareketlerini taklit edecek protez el tasarlayabilmek için, öncelikle el hareketlerinin

gerçekleştirilmesini sağlayan yapı ve EMG sinyalinin oluşumu hakkında bilgi sahibi olmak faydalı olacaktır. Bu bölümde, kasların kasılması ile ortaya çıkan EMG sinyalinin fizyolojik incelemesi yapılarak, bu sinyalin doğası hakkında bilgiler sunulacaktır.

İnsan vücudunda iskelet kası, kalp kası ve düz kas olmak üzere üç temel kas tipi vardır. Bu kaslar, merkezi sinir sisteminden gelen elektriksel uyarıların kas hücrelerini uyarmasıyla kasılırlar. Elektriksel uyarılar iskelet kaslarında istemli kasılmanın ortaya çıkmasını sağlarken kalp ve düz kaslarda oluşan kasılmalar istemsiz olarak gerçekleşir. İnsan tarafından gerçekleştirilen istemli hareketler merkezi sinir sistemi aracılığıyla kontrol edilir. Sinir sisteminde bulunan ve nöron olarak adlandırılan özelleşmiş sinir hücreleri, elektriksel sinyaller aracılığıyla vücudun farklı kısımları arasında bilgi iletimini sağlar. Aksiyon potansiyeli olarak bilinen bu elektriksel sinyal hem nöronların kendi aralarında haberleşmesini sağlar hem de motor hücrelerine bağlanarak hücre içi aktiviteyi başlatır. Bir kasın kasılmasını sağlayan süreç, aksiyon potansiyelinin kas liflerindeki hücrelere ulaşmasıyla başlamış olur [26]. EMG sinyalinin ortaya çıkması ise iskelet kaslarının kasılmasını sağlayan aksiyon potansiyelinden kaynaklanmaktadır.

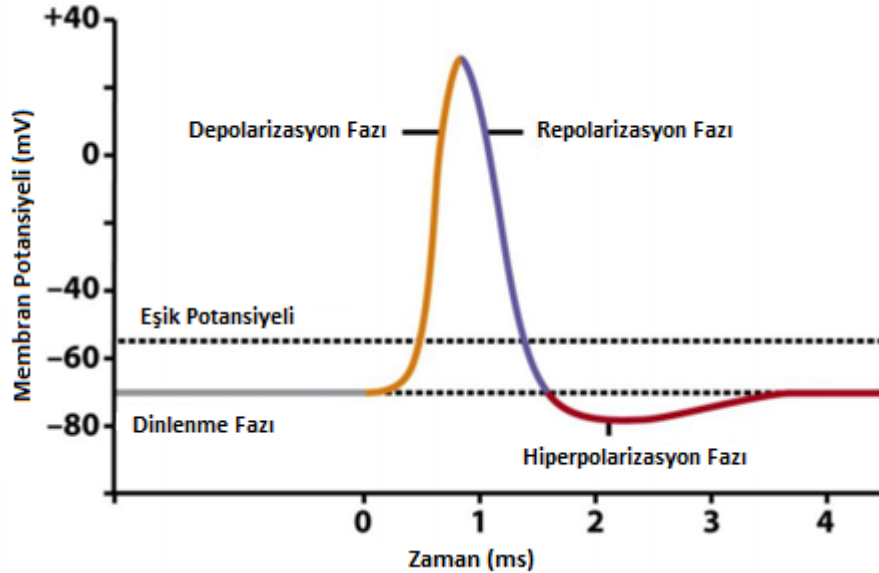
İnsan vücudunda yer alan sinir ve kas hücreleri dışarıdan yapılan bir etki ile uyarılma özelliğine sahiptir. Bu hücrelerin uyarılmasıyla zarlarında potansiyel değişim meydana gelir ve elektriksel aktivite ortaya çıkar. Bu aktivite ise hücre içindeki ve dışındaki sıvı bileşimlerinin içerisindeki, potasyum ( $K^+$ ), sodyum ( $Na^+$ ) ve klor ( $Cl^-$ ) iyonlarının yoğunluğunun farkından kaynaklanmaktadır. Sinir ve kas hücrelerinin zarları  $K^+$  ve  $Cl^-$  iyonlarını kolaylıkla hücre içine geçirirken  $Na^+$  iyonlarının geçişine engel olmaktadır. Böylelikle hücre dışında daha fazla pozitif yüklü  $Na^+$  iyonu bulunmakta ve hücrenin dışı içine göre daha pozitif olmaktadır. Ortaya çıkan elektriksel yük dengesizliğinin düzelmesi için pozitif yüklü  $K^+$  iyonları hücre zarından içeriye doğru akarlar ve iyon akışı elektriksel denge durumu sağlanıncaya kadar devam eder. Denge durumunda hücre içindeki  $K^+$  iyonunun yoğunluğu hücre dışındaki  $K^+$  iyonuna göre daha fazladır. Böylelikle elektriksel kuvvet ile difüzyon kuvveti birbirinin dengeler ve  $K^+$  iyonunun akışı durmuş olur. Hücrenin bu durumunda var olan potansiyeline ise dinlenme potansiyeli denilir. Dışarıdan herhangi bir uyarı gelmedikçe denge hali değişmez ve hücre zarının iç kısmı zarın dış kısmına göre daha negatif halde bulunur. Bu potansiyel fark ise 100 mV seviyesine kadar çıkabilir [27]. Hücre zarının dışarıdan uyarılması hücre zarının  $Na^+$  iyonlarına karşı geçirgenliği artar. Böylece hücre zarı dışındaki  $Na^+$

iyonları hücre içine doğru sodyum kanalları vasıtasıyla akarken  $K^+$  iyonları ise dışarıya doğru akar. Şekil 1.1'de hücre içindeki iyon değişimlere göre hücrenin farklı durumdaki halleri gösterilmiştir.



Şekil 1.1 Hücre zarı içindeki potansiyel değişimleri [28].


Bu olay nöronun iç kısmı dış kısmına göre pozitif elektrikle yüklenmesine sebep olur. Bu geçici potansiyel değişimi aksiyon potansiyelini meydana getirir ve depolarizasyon durumu olarak adlandırılır. Şekil 1.2'de aksiyon potansiyeli grafiği yer almaktadır.



Şekil 1.2 Aksiyon potansiyeli ve fazları

Şekil 1.3'te uyarılan bir sinir hücresinin zarındaki potansiyel dağılımı ve uyarının zarda meydana getirdiği değişiklik yer almaktadır. Sinir hücresinin uyarılmasıyla

birlikte zarın içinde bir potansiyel değişim meydana gelmektedir. Hücre zarının iç kısmındaki potansiyel, negatif durumdan pozitif duruma geçer ve depolarize olur. Depolarize olan kısım, yanında yer alan ve depolarize olmayan komşusunu nötrlemeye çalışır. Böylece zarın iç yüzeyinde uyarı yönünde bir akım oluşur. Zarın dış yüzeyindeki potansiyel değişim sonucunda da, zarın iç yüzeyinde meydana gelen akıma zıt yönde başka bir akım ortaya çıkar. Sonuç olarak zarın uyarılan kısmında bir dipol meydana gelir.




**Şekil 1.3** Hücre zarı potansiyel dağılımı (a,b) ve zardaki konuma göre aksiyon potansiyeli genliği (c) [27].

Dipolun oluşturduğu kuvvet komşu kısımları depolarize edebilecek eşik değerinin üstünde olduğundan aksiyon potansiyeli zar boyunca ilerlemeye devam eder. Aksiyon potansiyeli sinir hücresinin aksonu boyunca ilerleyerek bir başka sinir hücresini ya da motor hücresini uyararak vücut içerisindeki fonksiyonların yerine getirilmesine aracılık eder.

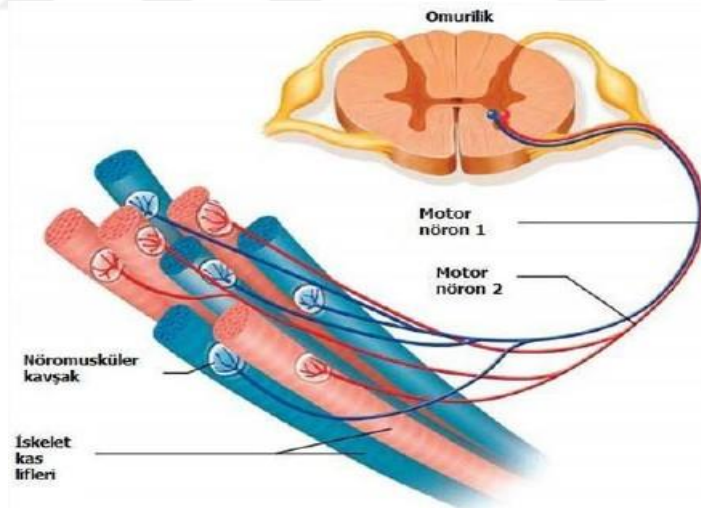
Sinir hücresinin zarında voltaj kapılı iyon kanalları bulunmaktadır. Bu kanallar açılıp kapanabilen kapılara sahip moleküler gözeneklerdir. Dinlenme ve aksiyon potansiyeli, bu özel protein kanallarının, nöron zarındaki iyon geçişini kontrol etmesiyle sağlanır. Proteinin bileşenleri kanalın da özelliğini belirler ve her iyon, her iyon kanalından geçemez. Birçok iyon kanalında, kanala bağlanan iyonlara yanıt olarak kapılar açılır. Aksiyon potansiyelinin ortaya çıkmasında önemli bir rol oynayan voltaj kapılı sodyum kanalında kapı, membran potansiyelinin seviyesine tepki veren bir voltaj sensörü tarafından kontrol edilir. Sinir hücresine dışarıdan bir uyarı gelmesiyle, depolarizasyon gerçekleşir, yani hücre zarının iç kısmı daha pozitif olur. Sodyum kanalındaki voltaj sensörleri, depolarizasyon sonucunda iyon yoğunluğuna ve

elektriksel deęişimlere baęlı olarak, kanalın kapısını açarlar ve sodyumun hücre zarı içine akmasını sağlarlar.



Şekil 1.4 Voltaj kapılı sodyum kanalı [29].

Merkezi sinir sisteminin bir parçası olan omurilięin, ön boynuzunda ve beyin sapında motor nöronlar yer almaktadır. Motor nöronlar sinir sisteminin farklı kesimlerinden gelen duysal verileri, girişleri alırlar ve aksonları ile ventral kök üzerinden kas liflerine innerve ederler. Böylelikle motor nöronlar tarafından üretilen aksiyon potansiyeli motor biriminde yer alan tüm kas liflerine iletilmiş olur [26].



Şekil 1.5 Motor birimi yapısı [30].

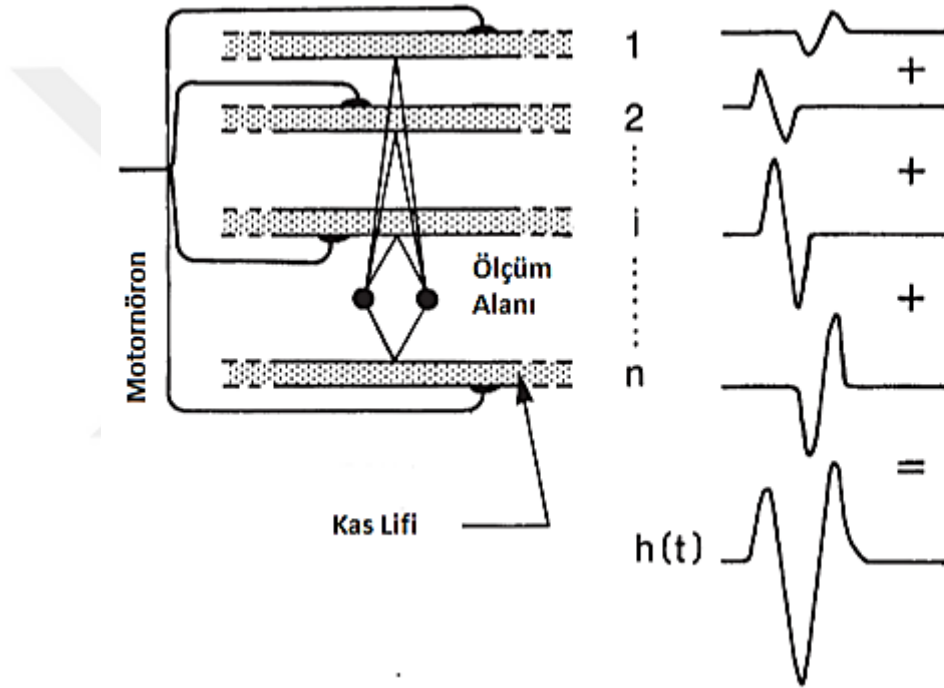
Motor nöron tarafından gönderilen aksiyon potansiyeli, motor nöronun innerve ettiği kas liflerinin yaptığı aktiviteye dair içerisinde bilgiler barındırmaktadır [31]. Tek bir motor birimi içerisinde yer alan kas liflerinin aksiyon potansiyellerinin toplamı, motor birimi aksiyon potansiyelini oluşturmaktadır. Motor birimi aksiyon potansiyelinin oluşumu gösteren Şekil 1.6 bu süreci ifade etmektedir.



Bir motor nöronda yer alan her bir kas lifinin potansiyelinin katkısının toplamıyla ortaya çıkan motor ünitesi aksiyon potansiyeli şu şekilde ifade edilebilir.

$$h(t) = \sum_{i=1}^N x_i(t - \tau) s_i \quad (1.1)$$

Denklem (1.1)'de yer alan  $N$  motor biriminde bulunan kas lifi sayısını temsil etmektedir. Ayrıca  $x_i$   $i$ . kas lifine ait potansiyeli,  $\tau$  ise  $x(t)$ 'nin geçici ofset değerini ifade eder. Son olarak  $s_i$  ise kas lifinin o an aktif olup olmadığını gösteren ve bir ya da sıfır değeri alan bir katsayıdır.





Şekil 1.6 Motor birimi aksiyon potansiyelinin ( $h(t)$ ) oluşumu [32].

Kas birimi, tek bir motor nöron tarafından innerve edilen kas lifleri ve motor biriminin çevresel elemanlarından oluşur [26]. Kas tarafından uygulanan kuvvet ise innerve edilen kas sayısı ile doğru orantılı olarak değişmektedir. Ayrıca kasılma hızı ve kuvveti kas liflerinin türüne bağlı olarak da değişim göstermektedir [33].

Sinir sistemi, farklı motor ünitelerini ve ona karşılık gelen kas liflerini değişken ateşleme hızında aktive ederek kas kasılmasını kontrol eder. Her motor biriminde bulunan kas liflerinin sayısı değişebilir. Bir motor ünitesinin aktif olması tüm kas liflerinin aktivasyonu anlamına gelir. Kas dokusu hücreleri, sinir hücreleri ile aynı şekilde elektriksel potansiyelleri iletir. Tek bir motor ünitesinin tüm kas liflerinde

oluşan kas lifleri aksiyon potansiyellerinin toplamı, motor ünite aksiyon potansiyelini (MUAP) verir. Şekil 1.7 motor ünitelerinin yapısını ve üretilen gerginliğini ve karşılık gelen kas lifleri sayısını göstermektedir.

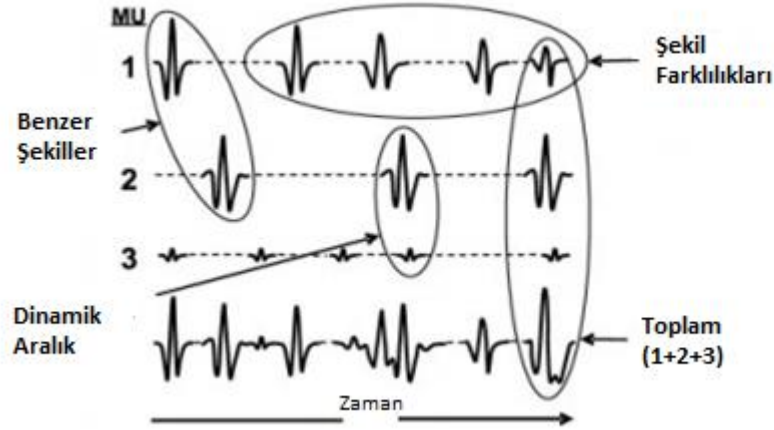


Şekil 1.7 Motor birimi X ve Y (üstte) Motor birimi fiber sayısına göre oluşturulan uyarı (altta) [34].

### 1.3 sEMG Sinyalinin Ölçülmesi

El hareketlerinin biyolojik sinyaller kullanılarak ayırt edilmesi karmaşık bir işlemdir. Basit bir hareketin yapılabilmesi için bile birden fazla kas kullanılmaktadır [35]. Bu kas aktivitelerinin ortaya çıkması neticesinde görüntülenen sEMG işaretleri, motor ünitelerinin aksiyon potansiyelleri toplanarak elde edilmektedir. Kastaki kasılma seviyesinin düşük seviyede olduğu hallerde EMG işaretleri daha kolay gözlemlenebilirken, kasılma miktarının değişimiyle beraber işaretin yapısı karmaşıklaşabilir. Kasılma miktarının artışıyla orantılı olarak ateşleme yapan motor ünite sayısı da artar ve böylelikle EMG girişim modeli değişir [4]. Buna ilaveten, her bir motor ünitenin ateşleme frekansı, kasılma miktarıyla beraber artmakta ve yeni bir motor ünite ateşleme yapıncaya kadar bu davranışını korumaktadır. Ayrıca yapılan harekete ve kişinin fizyolojik yapısına göre ortaya çıkan potansiyelin genliği ve frekansı değişiklik göstermektedir. Tüm bunlarla beraber EMG sinyalinin ayrıştırılmasını zorlaştıran dört ana etken bulunmaktadır.

- i. Farklı motor üniteleri aracılığıyla ortaya çıkan aksiyon potansiyellerinin toplanması
- ii. Kas grubunun farklı motor ünitelerine ait aksiyon potansiyelleri arasındaki büyük genlik farkı
- iii. Her bir motor ünitesinin kendisine ait aksiyon potansiyelleri arasındaki şekil farkı
- iv. Farklı motor ünitelerine ait aksiyon potansiyelleri arasındaki şekil benzerliği




**Şekil 1.8** Motor ünitelerinin aksiyon potansiyellerinin analizinde karşılaşılan problemler [32].

Motor üniteleri kapsamında ortaya çıkan aksiyon potansiyellerinin doğasından kaynaklı zorlukların haricinde, ölçümden kaynaklanan zorluklar da vardır. Yüzeysel elektrod olarak deri yüzeyinden ölçüm yapılması, sadece istenilen kas grubuna ait aksiyon potansiyellerinin değil, farklı motor ünitelerinden kaynaklanan aksiyon potansiyellerinin de ölçümünü hesaba katar. Bu da ayrıştırılması gereken sinyal bileşenini artırır. Ayrıca ölçüm yüzeyine yeterince yakın olmayan bazı aksiyon potansiyeli kaynaklarından elde edilen düşük enerjili işaretler gürültü ile karışabilmektedir. Sensörlerin deri yüzeyinden ölçüm yapması sonucu ortaya çıkan bir başka problem ise ölçülen aksiyon potansiyellerinin arasındaki şekil ve genlik farklılıklarının düşük bir aralıkta kalmasıdır. Bunun sonucu olarak aksiyon potansiyellerinin ölçümüyle elde edilen şekil ve genlik bilgileri birbirine daha fazla benzeme eğilimi gösterir [32].

Dolayısıyla motor ünite potansiyellerinin ve bunun sonucu olarak EMG sinyalinin ölçülebilmesi için özel tekniklere ve cihazlara ihtiyaç vardır. Şekil 1.9'da ampute bireyden alınmış sEMG sinyali örnekleri gösterilmiştir. Aynı harekete ait olan işaretler üç farklı güç seviyesini temsil etmektedir.

Kasların uyguladığı güç seviyesinin değişmesiyle beraber sEMG sinyali genliğinin de uygulanan güçle orantılı olarak değiştiği görülmektedir.



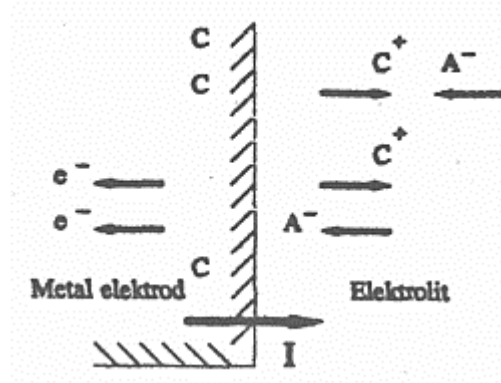
**Şekil 1.9** Düşük, orta ve yüksek güç seviyelerine ait sEMG işaretleri genlikleri

sEMG işaretinin ölçümü elektrotun özelliğine, elektrotun deri yüzeyi ile olan temasına, elektrotların kas bölgesine olan uzaklığına, yükseltici özelliklerine, analog dijital dönüştürücünün yapısına göre değişim gösterebilmektedir. sEMG işaretinin kalitesi genellikle işaretin gürültüye olan oranının büyüklüğüyle belirlenmektedir.

### 1.3.1 Elektrod Yapısı

EMG elektrodları kasların elektriksel aktivitesini ölçen ve kas dokusu boyunca ortaya çıkan iyonik akımları EMG edinim sistemine aktaran sensörler olarak tanımlanabilir. Diğer biyopotansiyel elektrotlar gibi, EMG elektrodlarının çalışma prensibi de elektrolit çözeltilerin ve dokuların içerdiği iyonların etkileşimine dayanır [19]. EMG elektrotları tarafından tespit edilen biyolojik sinyal, vücuttan akan iyonik akımın transdüksiyonu ile üretilir. Ölçüm esnasında EMG edinim sistemine aktarılan akımlar çok küçüktür, dolayısıyla bu akımların hassas ve doğru bir şekilde ölçülmesi sEMG işaretinin verimli bir şekilde kullanılabilmesi bakımından oldukça önemlidir. Elektrodlar, kimyasal sıvı bir ortam olan elektrolid içerisinde, iyon akımını elektrik akımına dönüştürürler. Bu işlem, elektrod atomlarının elektron kaybetmesiyle elektrolit

sıvısına katyon vererek ya da elektrod atomlarının elektrolid sıvısından elektron çekerek ortaya çıkan potansiyel farktan yararlanılarak yapılır.



**Şekil 1.10** Elektrod-elektrolit arayüzü (Elektrottan elektrolite doğru olan akım akışının gösterilişi [27]).

Şekil 1.10'da elektrod-elektrolid ara yüzünde katot ve anot arasındaki ilişki yer almaktadır. Meydana gelen bu işlem şu şekilde ifade edilebilir;




Yukarıdaki denklemde yer alan  $n$  katot C'nin değerliğini göstermektedir, aynı şekilde  $m$  ise anot A'nın değerliğini temsil eder.

Elektrodlar imal edildikleri malzemelere, uygulanma yöntemlerine (invaziv, non-invaziv) veya elektro-kimyasal özelliklerine göre farklılıklar gösterebilirler. Genel olarak elektrodlar elektro-kimyasal özellikleri bakımından polarlanabilen ve polarlanamayan olmak üzere iki kısımda incelenir. Polarlanabilen elektrodlar yüksek kapasitif özellik gösterdiği için elektrod-elektrolid ara yüzünde akım geçişi sınırlıdır bu yüzden sEMG'nin ölçülmesi için kullanışlı değildir [36]. Bunun aksine polarlanamayan elektrodların elektrod-elektrik ara yüzünden akım geçişi rahatlıkla sağlanmaktadır. İdeale yakın polarlanamama özelliği gösteren Ag-AgCl elektrodları oldukça kararlı davranır ve gürültü seviyesi diğer metalik elektrodlara göre daha düşüktür. Bu tez çalışmasında kullanılan sEMG sinyal verileri, Ag-AgCl elektrodları kullanılarak elde edilmiştir.

### 1.3.2 Derinin Temizlenmesi


Yüzey EMG elektrotları cilt yüzeyine yerleştirilmeden önce cilt yüzeyinin ölçüm için uygun hale getirilmesi gerekmektedir. Kaliteli bir EMG sinyali elde etmek için, cildin empedansı önemli ölçüde azaltılmalıdır. Bu amaçla, elektrotların yerleştirileceği cilt yüzeyi tamamen temizlenmeli ve traş edilmelidir. Cildin kuru tabakasını azaltmak için aşındırıcı bir jel kullanılması tavsiye edilir. Cilt yüzeyindeki nem olmamalıdır. Ciltte herhangi bir ıslaklık veya terin var olması durumunda cilt alkol ile temizlenmelidir [37].



**Şekil 1.11** Pratik uygulamalar için kullanılacak bir EMG sensörünün tipik yapısı [38].

### 1.3.3 Elektrotların Yerleşimi

Mümkün olan en iyi sinyali elde edebilmek için sEMG elektrotlarının doğru bölgeye yerleştirilmesi büyük önem taşımaktadır. Elektrotlar kasın orta hattı boyunca motor birimi ve tendon arasındaki bölgeye yerleştirilmelidir [38]. Tendon bölgesinde kas lifleri ince ve daha az sayıdadır bu sebeple bu bölgedeki sinyalin genliği daha düşüktür. Ayrıca kas bölgesinin kenarlarına yerleştirilen elektrotlar başka kaslardan da sinyal alabilmektedir bu yüzden elektrotların orta hatta hedef kas liflerinin en yoğun olduğu bölgede, olması sinyalin güvenilirliğini arttırmaktadır. Şekil 1.12’de elektrod için uygun yerleşim bölgesi gösterilmektedir.



Şekil 1.12 Elektrod için uygun konum (motor birimi ve tendon arasında) [38].

#### 1.4 3B Yazıcı ve Protez Eller

Üst uzuv eksiliğine sahip bireylerin kullanacakları protezlerin standart boyut ve ölçülerde olması, bu protezlerin kullanımının verimliliğini düşürecektir. Bu sebeple her kullanıcının sahip olduğu amputasyon çeşidine ve kullanıcıların kendi fiziksel özelliklerine göre bu protezler kişiselleştirilmelidir. Ayrıca kullanılan protezlerin kontrol algoritmalarına göre düzenlemeleri de yapılabilirdir. Tüm bu faktörleri göz ardı etmeden, kişiselleştirilmiş protez ellerin üretilmesini sağlayacak yöntemleri geliştirmek ya da temin etmek geliştirilen teknolojinin uygulanabilirliği açısından oldukça önemlidir.

Protez el üretiminin hızlı, esnek, özelleştirilmiş ve kişisel olarak üretilebilmesine olanak sağlayan ve diğer yöntemlerle karşılaştırıldığında daha az maliyetle çalışan 3B yazıcılar[39], günümüzde sadece protezler için değil, sağlık sektöründe birçok alanda kendine kullanım alanı bulmaktadır [40]. Geleneksel üretim yöntemlerinde malzeme kaldırılarak parçalar üretilirken, 3B yazıcılar malzeme ekleyerek üretimi gerçekleştirirler. Son ürün, katman katman malzemenin eklenmesiyle ortaya çıkar. Bu sebeple, bu üretim yöntemlerine katmanlı üretim de denilmektedir.

3B yazıcıların bir başka önemli özelliği ise çok karmaşık geometrilere sahip modellerin dahi üretimini kısa zamanda yapabilmesidir. Bu da farklı modellerin tasarlanıp rahatça denenmelerine olanak sağlayarak, ampute bir birey için kullanılabilir, işlevsel ve faydalı bir protez elin hızlı bir şekilde üretilebilmesinin yolunu açar. İtalyan Del Bene Orthopedi Laboratory verilerine göre, protez üretiminde geleneksel yöntemler yerine 3B yazıcıların kullanılmasıyla beraber, üretim hızı %75 artmıştır [40].

Günümüzde 3B yazıcı teknolojisinin gelişimi ve daha kolay olarak ulaşılabilmesiyle beraber birçok farklı mekanizmaya sahip protez el üretilmiştir. Protez bir el üretilmeden önce hangi ihtiyaçları karşılayacağı ve nasıl kontrol edileceği gibi temel faktörler göz önünde bulundurulmalıdır. Başlıca faktörler şu şekilde sıralanabilir[41];

- Serbestlik derecesi
- Motor fonksiyonu sayısı
- Hareket sınıfları
- Giriş sinyalinin türü
- Kontrol stratejisi

Verilen tüm bu özelliklere göre doğru bir şekilde dizayn edilen protez bir elin istenen performansı vermesi beklenir. Biyolojik sinyal (EMG ve EEG) kontrollü ve mekanik hareket kontrollü (bilek ve dirsek hareketi) el protezleri gibi farklı konseptlerde çalışabilen bu protez eller ampute bireyler tarafından kullanılmaktadır. Protez eller üzerine yapılan çalışmaların artmasıyla beraber açık kaynak protez el modellerinin sayısı da artmaya başlamıştır. Inmoov 2, Hackberry, Ada Hand gibi açık kaynak modeller EMG sinyali kontrolüne uygun olup literatürde farklı çalışmalarda kullanılmıştır [41].



**Şekil 1.13** Open Bionic Ada Hand protez eli [42].



## 2. MATERYAL METOD

### 2.1 Veri Seti

Bu çalışma için kullanılan veri seti [43] tek taraflı amputasyona sahip dokuz bireyden (7'si travmatik, 2'si doğuştan) elde edilmiştir. Çizelge 2.1'de katılımcılara ait bilgilerin detayları yer almaktadır. En az sekiz kanallı, örnekleme frekansı 2000 Hz ve çözünürlüğü 16 bit olan EMG edinim sisteminin (USB-6210, National Instruments) kullanımıyla toplamda altı farklı kavrama ve parmak hareketine ait işaretleri içeren veri seti oluşturulmuştur. Kazanç faktörü 1000 olan çok kanallı EMG yükseltici kullanılarak her bir kanal için elde edilen sinyal yükseltilmiştir. Toplanan EMG işaretinden gürültüyü arındırmak için kesim frekansı 450 Hz olan dördüncü dereceden alçak geçiren analog Butterworth filtre ile ikinci dereceden kesim frekansı 10 Hz olan yüksek geçiren analog Butterworth filtre kullanılmıştır. Altı farklı parmak hareketi için her bir katılımcıdan beş ila sekiz adet kayıt alınmıştır ve alınan bu kayıtlar ortalama 8-12 saniye sürmüştür. Böylelikle veri setinin güvenilirliği artırılırken, gürbüz yöntemlerin geliştirilmesine olanak sağlanmıştır. Veri setindeki 6 el hareketi Şekil 2.1'de gösterildiği gibidir. Sırasıyla; başparmak (BP), işaret parmağı (İP), çimdik (ÇK), tripod kavrama (TK) kanca kavrama (KK) ve küresel kavrama (KÜK) hareketleri için toplam 9 amputeden 54 farklı EMG sinyali örneği içeren veri seti bu çalışmada kullanılmıştır.



**Şekil 2.1** Altı sınıflı veri seti el hareketleri (1: BP, 2: İP, 3: ÇK, 4:TK, 5: KK, 6:KÜK).

Elektrodlar yerleştirilmeden önce katılımcıların derileri alkol ve aşındırıcı cilt hazırlama jeli ile temizlenmiştir.

Sonrasında 8 çift Ag/AgCl yüzey elektrodu SENIAM (Surface ElectroMyoGraphy for the Non-Invasive Assessment of Muscles) tarafından belirlenen kıstaslara göre katılımcıların kalan uzuvları üzerine yerleştirilmiştir.

**Tablo 2.1** Çalışmada yer alan katılımcıların bilgisi.

Katılımcı	Yaş	Cinsiyet	Ampute Türü
Ampute 1	25	E	Travmatik
Ampute 2	33	E	Travmatik
Ampute 3	30	E	Travmatik
Ampute 4	27	E	Travmatik
Ampute 5	35	E	Travmatik
Ampute 6	29	E	Travmatik
Ampute 7	57	E	Travmatik
Ampute 8	19	K	Doğuştan
Ampute 9	31	K	Doğuştan

Toplanan veri setinde her hareket için düşük, orta ve yüksek kuvvet seviyelerine ait kayıtlar bulunmaktadır. Bu çalışmada ise düşük kuvvet seviyesine ait hareketler kullanılmıştır. Tablo 2.1’de verilerin toplandığı katılımcılara ait bilgiler verilmiştir.

## 2.2 EMG Sinyal İşleme

EMG sinyalinin içerdiği bilgiyi doğru bir şekilde kullanabilmek ve sinyalin kalitesini arttırmak için sinyale ön-işleme metotlarının uygulanması gerekmektedir. Kas kasılması ile ortaya çıkan sinyal, gürültünün varlığında kendi karakteristiğini tam olarak yansıtmayabilir. Sinyalin kalitesi sinyal/gürültü oranı ile doğru orantılı olarak değişmektedir. EMG sinyaline karışan gürültüler farklı etkenlerden dolayı ortaya çıkabilir. Kayıt esnasında kullanılan elektronik ekipmanlardan, elektromanyetik radyasyondan, hareket artefaktı ve şebeke hattından kaynaklanan gürültülerdir. Sinyalin kaydı esnasında güç hattındaki girişimlerden ötürü ortak mod gerilimi oluşur. Ortak modun elimine edilmesi kayıt esnasında kullanılan diferansiyel yükseltici vasıtasıyla gerçekleştirilir.

EMG edinim sisteminin çevresinde yer alan cihazlardan ve elektromanyetik radyasyondan kaynaklanan gürültüler yüksek frekans seviyelerinde görülmektedir. Bu gürültüler alçak geçiren filtre aracılığıyla elimine edilebilir. EMG sinyalinin verimli bir şekilde kullanılmasını engelleyici diğer bir faktör ise hareket artefaktlarıdır.

Bunlar elektrodla deri yüzeyi arasındaki temastan ve elektrod kablolarından kaynaklanmaktadır.

Kaydedilen sinyalin 0-20 Hz aralığına karışan bu gürültü, yüksek geçiren filtre kullanılarak engellenebilir ya da buna ek olarak elektrodun ve kabloların uygun şekilde bağlanmasıyla minimize edilebilir [19].

### **2.2.1 Filtreleme**

Bir önceki bölümde bahsedilen bozucu etkenler ile baş edebilmek için, sEMG sinyalleri ile işlem yapılmadan önce filtrelenmeleri gerekmektedir. Rasgele bir karakteristiğe sahip olan sEMG sinyali için başarılı bir filtreleme yapmak kullanılan yöntemle bağlı olduğu gibi sinyalin karakteristiğini doğru olarak tanımaya da bağlıdır.

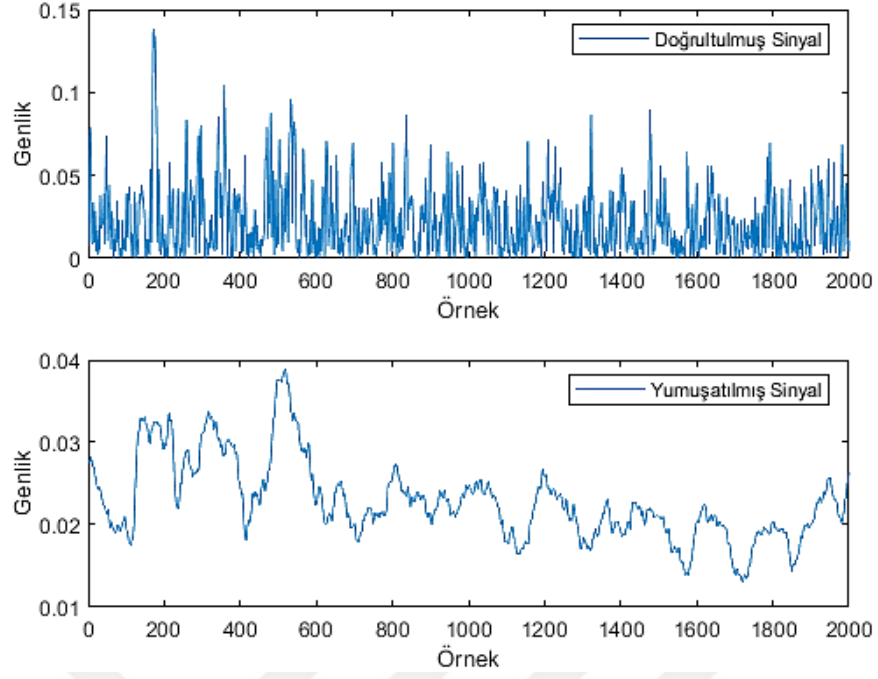
Bu kapsamda Balmirot [44] sEMG sinyali filtreleme işleminde 20 Hz ve 500 Hz kesim frekanslarına sahip bant geçiren filtre kullanmıştır. Bir başka çalışmada Sapsanis [20] 15- 500 Hz arası bant geçiren filtre kullanmıştır. Ayrıca düşük frekans bandındaki hareket artefaktlarını bastırmak adına literatürde 20 Hz ve 10 Hz altındaki frekans bileşenlerinin filtrelenmesi önerilmiştir. [45] Bu çalışma kapsamında kullanılan ham sEMG sinyalleri analog 10 - 450 Hz bant geçiren filtre kullanılarak filtrelenmiştir.

### **2.2.2 Doğrultma ve Yumuşatma**

Ham EMG sinyalinin doğrultulması ve yumuşatılması literatürde genel olarak yer alan bir işlemdir. EMG sinyalinin doğrultulmasıyla motor ünitesi grubunun ateşlemesine ait geçici bir örüntüsü, aksiyon potansiyelinin şeklinden bağımsız olarak elde edilir [46]. Bunun yanında doğrultma işlemi ile beraber EMG işaretine ait zamanlama ve ateşleme oranı bilgisi daha net elde edilir.

Bu çalışmada EMG işaretinin mutlak değeri alınarak tam dalga doğrultma işlemi yapılmıştır. Doğrultma uygulandıktan sonra hareketli ortalama filtre uygulanıp yumuşatma işlemi yapılarak işaretin zarfı elde edilmiştir.

Yumuşatmanın doğrultmadan sonra yapılmasına dikkat edilmelidir çünkü doğrultulmamış EMG'nin ortalaması sıfırdır. Şekil 2.2'de örnek doğrultulmuş ve yumuşatılmış EMG sinyaline ait grafikler yer almaktadır.



**Şekil 2.2** Doğrultma (üstte) ve yumuşatma (altta) işlemi.


### 2.3 Görgül Kip Ayrışımı

Görgül Kip Ayrışımı (GKA) Huang ve arkadaşları [47] tarafından geliştirilmiş olup doğrusal olmayan ve durağan olmayan sinyallerin işlenmesinde başarılı sonuçlar veren bir sinyal ayrıştırma algoritmasıdır. Sinyali, kendi içinde barındırdığı sonlu sayıdaki genlik ve frekans modüleli özgül kip fonksiyonlarına (ÖKF) ayırıştırır ve doğal salınım kiplerini gösteren bir eleme sürecidir. Fourier analizinde sinüs ve kosinüs dalgalarıyla temsil edilen salınım kipleri, GKA algoritmasında özgül kip fonksiyonları ile temsil edilmektedir. GKA ile eleme süreci neticesinde elde edilen fonksiyonların özgül kip fonksiyonu olması için gerek ve yeter iki şart şu şekildedir;

1. Tüm zaman serisi boyunca mevcut olan yerel maksimum ve yerel minimum nokta sayısı sıfır geçiş sayısına eşit olmalı ya da aralarında en fazla bir fark olmalıdır.
2. Yerel maksimum noktalarının oluşturduğu üst zarf ile yerel minimum noktalarının oluşturduğu alt zarfın ortalaması sıfıra eşit olmalıdır.

Yukarıda verilen şartlar ampirik olarak elde edilir bu yüzden elde edilecek ÖKF'lerin bant aralığı ve sayısı önceden kestirilemez. İkinci şartta ifade edilen yerel maksimum ve yerel minimum noktalarının ortalaması, zarf boyunca noktasal olarak hesaplanan yerel ortalamayı belirtmektedir.


ÖKF'ler orijinal sinyalin farklı frekans bantlarını ve zaman ölçeklerini gösteren fonksiyonlardır. ÖKF'ler sinyalin yerel ortalamalarının hesaplanmasıyla bulunur ve böylelikle yerel ölçekte sinyalin analizi gerçekleştirilebilir.



Şekil 2.3 Örnek  $x(t)$  sinyali.

GKA algoritmasını verilen Şekil 2.3'te verilen örnek bir  $x(t)$  sinyaline etkili bir şekilde uygulamak için, eleme süreci olarak adlandırılan işlem yerine getirilmelidir. İzlenmesi gereken adımlar şu şekildedir;


- i.  $x(t)$  sinyalinin tüm yerel maksimum noktaları  $M_k$ ,  $k = 1, 2, 3, \dots$  ve tüm yerel minimum noktaları  $M_i$ ,  $i = 1, 2, 3, \dots$  tespit edilir.
- ii. Kübik spline interpolasyonu uygulanarak yerel maksimum ve yerel minimum noktaları birleştirilir ve sinyalin üst ve alt zarfları  $e_{\max}(t)$  ve  $e_{\min}(t)$  bulunur.
- iii. Bulunan üst ve alt zarfların ortalaması  $m(t) = (e_{\min}(t) + e_{\max}(t)) / 2$  hesaplanır.
- iv. Sonuç olarak  $m(t)$  fonksiyonu sinyalin kendisinden çıkarılır.  $h_1(t) = x(t) - m_1(t)$  elde edilir. Bulunan  $h_1(t)$  ÖKF olma şartlarını yerine getirmiyorsa,  $h_1(t)$  üzerinde ÖKF şartları sağlanıncaya kadar eleme süreci devam eder. Böylece  $h_1(t)$  yeni veri olarak kabul edilir.



Şekil 2.4  $x(t)$  (mavi) sinyalinin yerel ekstremum noktaları ile bulunan alt ve üst zarfları (yeşil) ve zarfların ortalaması (kırmızı) [48].

$$h_k(t) = h_{(k-1)} - m_k(t) \quad (2.1)$$

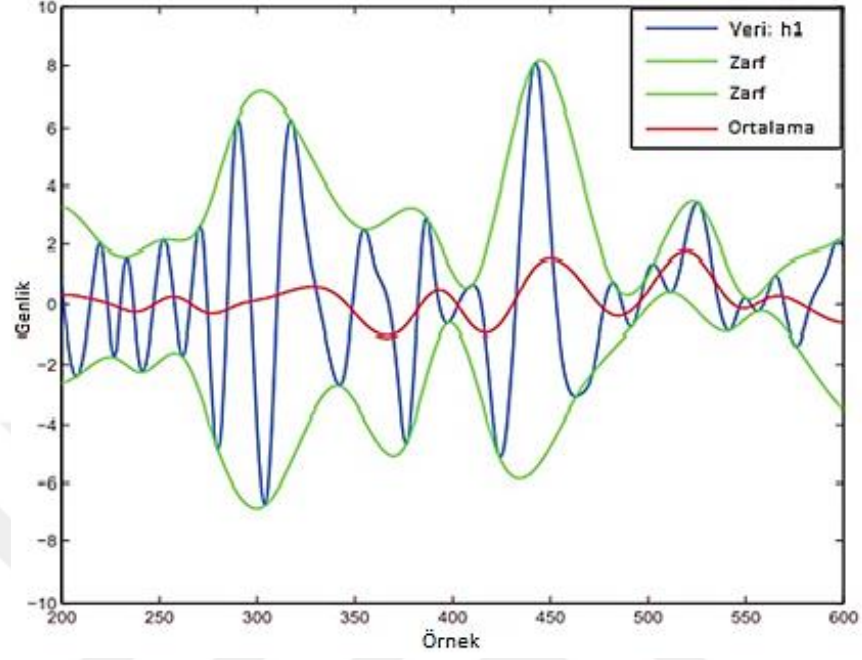
ÖKF bulmak için eleme sürecinin genel ifadesi Denklem 2.1'de verilmiştir. Uygun  $h_k$  değeri bulununcaya dek süreç devam eder.



Şekil 2.5  $x(t)$  verisi (kırmızı) ve  $h_1(t)$  (mavi) [48].

ÖKF şartlarını sağlamayan  $h_1(t)$  üzerinden eleme sürecinin devam ettirilmesi;


$$h_2(t) = h_1(t) - m_2(t) \quad (2.2)$$



Şekil 2.6  $h_1$  ve  $m_2$  ile devam eden eleme süreci [48].

ÖKF şartlarını sağlamayan  $h_2(t)$  üzerinden eleme sürecinin devam ettirilmesi;

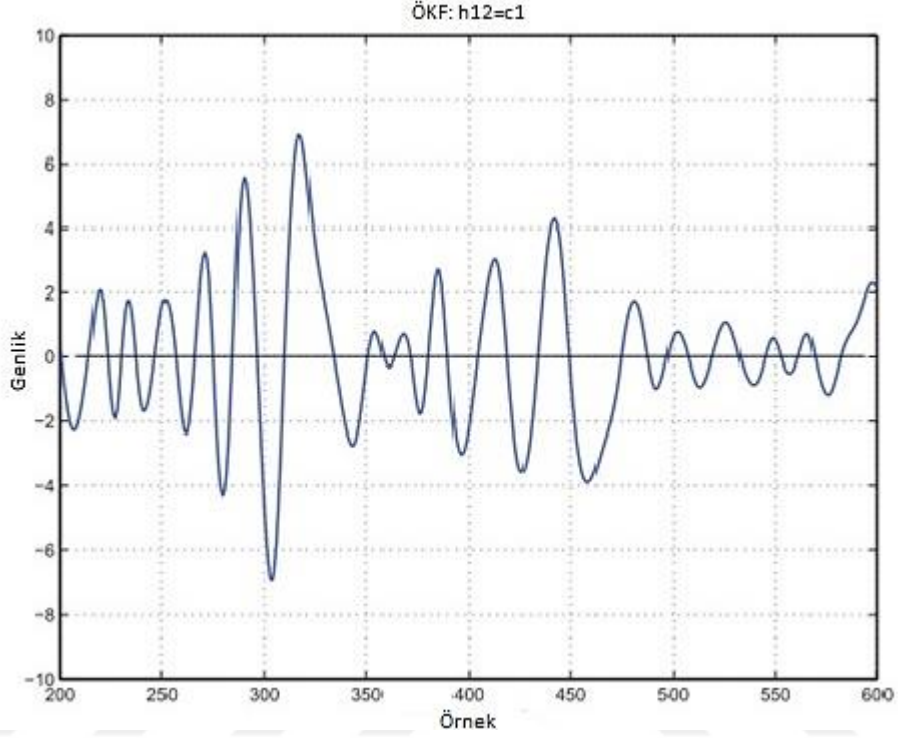
$$h_3(t) = h_2(t) - m_3(t) \quad (2.3)$$



Şekil 2.7  $h_2$  ve  $m_3$  ile devam eden eleme süreci [48].

ÖKF koşullarını yerine getiren bir sonuç fonksiyonu bulunana kadar bu işlem  $k$  kez tekrarlanmalıdır. Bu işlemi ifade eden genel eşitlik şu şekilde olur:

$$\mathbf{h}_k = \mathbf{h}_{(k-1)} - \mathbf{m}_k \quad (2.4)$$



**Şekil 2.8** Eleme sürecinde 12. adım ve İlk ÖKF bileşeni  $c_1$  [48].


ÖKF şartlarını sağlayan ilk ÖKF,  $\mathbf{h}_k$  fonksiyonu,  $c_1$  olarak kaydedilir.

$$c_1 = h_k \quad (2.5)$$

Orijinal veri  $\mathbf{x}(t)$ 'nin içerdiği en küçük zaman-ölçeklerini içeren  $c_1$ , verinin kendisinden çıkarılır ve artık olarak adlandırılan yeni fonksiyon üzerinden ikinci ÖKF'yi bulmak için eleme süreci devam ettirilir.

$$\mathbf{x}(t) - c_1(t) = r_1(t) \quad (2.6)$$





**Şekil 2.9** Orijinal veri  $x(t)$  (mavi) ve artık  $r_1(t)$ .

Denklem 2.6'da elde edilen  $r_1(t)$  yeni veri olarak kabul edilir ve eleme süreci baştan başlayıp yeni ÖKF'yi bulana kadar devam eder.


$$r_1 - c_2 = r_2, \dots, r_2 - c_3 = r_3, \dots, r_{n-1} - c_n = r_n \quad (2.7)$$

**5. ÖKF bulma süreci,  $h(t)$  durdurma şartlarını sağlayıp monotonik bir fonksiyon olana kadar devam eder ve bu durumda  $h(t) = r(t)$  artık fonksiyon, olarak belirlenir. Orijinal sinyal artık tüm ÖKF'ler ve artık fonksiyonun toplamıyla ifade edilebilir.**

$$x(t) = \sum_{k=1}^L c_k(t) + r(t) \quad (2.8)$$

Eleme süreci ÖKF'leri bulmak için uygulanır ve tek seferde bulacağını garanti etmez. Tek bir eleme sürecinden sonra ortaya çıkan dalga formu asimetrik olabilir bunun sonucu olarak da alt ve üst zarfların yerel ortalaması yanlış olarak hesaplanabilir. Bu yüzden asimetri düzeltilip ÖKF olma şartları sağlanıncaya dek eleme süreci devam eder. Eleme süreci boyunca ortaya çıkabilecek diğer bir durum ise eğri uydurma neticesinde oluşan bitiş etkisidir. Zarfları elde etmek için kullanılan kübik eğri uydurma metodu bitiş noktasına gelindiğinde büyük salımlara sahip olabilir. Bitiş etkisinin neticesinde verinin içerdiği düşük frekanslı bileşenler bozulmaya uğrar.

Eleme süreci kendi içerisinde bozucu etkiler içermesine rağmen, sinyalin genlik ve frekans modüleli salınım kiplerinin zaman-ölçeklerini doğru olarak çıkartabilmektedir.



Şekil 2.10 GKA Algoritması Akış Diyagramı.

Eleme süreci boyunca simetriyi sağlayabilmek için eşit seviyede olmayan genlikler yumuşatılmaktadır. Fakat bu durum fiziksel olarak anlamlı dalgalanmaları yok edebilir. Bu yüzden eleme işlemi dikkatle uygulanmalıdır. Eleme sürecinin çok uzaması durumunda ÖKF'lerin barındırdığı genlik çeşitliliği azalıp sabit bir forma yaklaşır.

Fiziksel olarak anlamsız ÖKF'lerden kaçınmak için durdurma kriterine dikkat edilmelidir. Standart sapma bu amaçla bir kriter olarak kullanılmaktadır ve bu tür olumsuzluklardan kaçınmak için hesaplanması gerekmektedir.

$$S = \sum_{t=0}^T \left[ \frac{[h_{1(k-1)}(t) - h_{1k}(t)]^2}{h_{1(k-1)}^2(t)} \right] \quad (2.9)$$

İki ardışık eleme işlemi arasındaki normleştirilmiş kare farkı  $S$ , önceden belirlenen 0.3 değerinden küçük olması durumunda eleme işlemi durdurulur.

## 2.4 Çok Değişkenli Görgül Kip Ayırışımı


GKA algoritması, tek-kanal tabanlı bir analiz yöntemi olup, çok kanallı EMG sinyallerini işlemek için doğrudan uygulanamaz. Ayrıca GKA algoritması, çok kanallı sinyaller için ayrıştırılmış ÖKF'lerin sayısının eşitliğini garanti etmez ve bu da çok kanallı EMG sinyal analizlerinin fiziksel olarak anlamsız olmasına neden olabilir. Çok kanallı sinyallerin analizinde yetersiz kalan GKA yöntemine alternatif olarak Rehman ve Mandic tarafından [49] geliştirilen çok değişkenli görgül kip ayrışımı yöntemi (ÇDGKA), tüm kanallardaki sinyallerden aynı sayıda ÖKF elde edilmesine olanak sağlar. ÇDGKA yöntemi, çok boyutlu sinyallerin salınım modlarının ortak analizini yaparak mod-hizalama sorununu çözmeye yardımcı olur. Bu da farklı kanallardaki aynı indeksli ÖKF'ler arasındaki frekans bantlarının tutarlılığının sağlanmasıyla gerçekleştirilir. Ayrıca frekans bantlarının birbiriyle tutarlı olması aynı sayıda ÖKF elde edilmesine katkı sağlayarak çok boyutlu sinyalin genel analizini yapmayı kolaylaştırır ve daha doğru bilgi elde edilmesini sağlar.

GKA algoritması, yerel ekstremum noktalarının interpolasyonu ile elde edilen üst ve alt zarfların ortalamasını alarak, yerel ortalama değerini kolaylıkla hesaplayabilir. Fakat çok değişkenli sinyallerin direkt olarak yerel ekstremum noktalarını bulmak kolay bir işlem değildir. Bu işlemin üstesinden gelebilmek amacıyla, ÇDGKA yöntemi, çok kanallı sinyallerin n-boyutlu bir uzayda farklı doğrultulardaki gerçek değerli iz düşümlerini kullanır. Çok kanallı sinyalin farklı doğrultulardaki bu iz düşümleri genliği temsil eder. Bu iz düşümler kullanılarak sinyalin her bir kanalındaki zarfları elde edilir. Farklı doğrultular boyunca uzanan bu zarfların, n-boyutlu uzaydaki integralinin hesaplanmasıyla yerel ortalama bulunabilir. Yerel ortalama hesaplamasının doğruluğunu yön vektörlerinin uniform dağılımına bağlıdır bu yüzden vektörler belirlenirken;

a) uniform açısal koordinatlar

b) düşük tutarsızlıklı nokta kümesi

olmak üzere iki farklı yöntem kullanılabilir. Bu yöntemlerden, en uygun vektör dağılımının veren ve yerel ortalamanın doğru olarak hesaplanmasını sağlayan yöntemin kullanılmasıyla en iyi sonuçların bulunması amaçlanmaktadır.




**Şekil 2.11** (a) Üç boyutlu düzlemde O merkezli küre (b) Örnek dönme eksenini  $u$ .

Yön vektörleri küre üzerinde seçilen noktalar vasıtasıyla bulunur. Küre üzerinde bulunan her nokta, başlangıcı kürenin merkezinde yer alan vektörlerin bitiş noktası olmaktadır. Şekil 2.11 (a)'da 3 boyutlu düzlemde yer alan bir küre bulunmaktadır. Küre üzerinde yön vektörü OA gösterilmiştir. Farklı yön vektörleri bulabilmek amacıyla daha fazla noktaya ihtiyaç vardır bu sebeple Şekil 2.11 (b)'de kürenin üzeri boyunca uzanan eşit aralıklı noktalar oluşturulur. Sinyal xy düzleminde bulunan dönme eksenini boyunca döndürülerek yön vektörleri boyunca sinyalin iz düşümleri bulunur ve z eksenine aktarılır. Şekil 2.11'de örnek dönme eksenini  $u$  gösterilmiştir.

Küreyi tamamen kaplayacak sayıda nokta oluşturmak için farklı yöntemler vardır. Şekil 2.12 (a)'da basit ve kullanışlı bir yöntem olan açısız birim örnekleme yöntemi kullanılarak oluşturulmuş nokta dağılımı yer almaktadır. 3 boyutlu düzlemdeki bu noktaların  $(n+1)$  boyutlu düzlemde yer alan  $n$  boyutlu kürede şu şekilde ifade edilebilir;

$$R = \sum_{j=1}^{n+1} (x_j - C_j)^2 \quad (2.10)$$

Bu denklemde  $R$ ,  $n$  boyutlu kürenin çapını,  $x$  küre üzerindeki noktaları  $C$  ise kürenin merkezini temsil etmektedir. Şekil 2.12 (a)'da bu yöntemle oluşturulmuş noktalar görülmektedir. Noktaların dağılımının kürenin kutuplarında yoğunlaşması sebebiyle uniform dağılım bozulmuştur.



**Şekil 2.12** Yön vektörlerini oluşturacak nokta dağılımları (a) Uniform açısıl örnekleme yöntemi (b) düşük tutarsızlıklı Hammersley yöntemi.

Daha düzgün bir dağılım elde etmek için ise ‘düşük tutarsızlıklı nokta kümeleri’ olarak adlandırılan yöntem Rehman ve Mandic [49] tarafından önerilmiştir. Düşük tutarsızlık noktaları oluşturmak için Hammersley dizisi kullanılmış ve uniform açısıl örnekleme yöntemine göre daha düzgün bir nokta dağılımı elde edilmiştir. Şekil 2.12 (b)’de iki boyutlu kürenin üzerinde düşük tutarsızlıklı Hammersley dizisi ile elde edilmiş noktalar gösterilmiştir.


n-boyutlu bir zaman serisine ait ÇDGKA yönteminin uygulama süreci şu şekildedir.

- i.  $(n-1)$  boyutlu kürede uygun bir nokta kümesi oluşturulur.
- ii. Giriş sinyalinin  $\{v(t)\}_{t=1}^T$  her bir kanaldaki iz düşümleri,  $p^{0_k}(t)\}_{k=1}^K$ , yön vektörleri,  $x^{0_k}$  boyunca hesaplanarak bulunur.
- iii. Sinyallerin iz düşümlerinin  $p^{0_k}(t)\}_{k=1}^K$  maksimum ve minimum noktalarına karşılık gelen anlar  $\{t_i^{0_k}\}$  belirlenir.
- iv. Çok değişkenli zarf eğrisini  $e^{0_k}(t)\}_{k=1}^K$  elde etmek için  $\{t_i^{0_k}, v(t_i^{0_k})\}$  interpolate edilir.
- v. K adet yön vektörü için zarf eğrilerinin ortalaması  $m(t)$  hesaplanır.


$$m(t) = \frac{1}{K} \sum_{k=1}^K e^{0_k}(t) \quad (2.11)$$

- vi.  $d(t) = x(t) - m(t)$  işlemiyle “ayrıntı” hesaplanır. Hesaplanan ayrıntı durdurma kriterlerini sağlıyorsa ÖKF olarak belirlenir ve  $x(t) - d(t)$  hesaplanarak işlem tekrar ilk adımdan başlatılır aksi bir durumda  $d(t)$  üzerinden ilk adımdan başlanarak süreç devam ettirilir.

ÇDGKA yöntemine ait tüm bu süreçlerin şekil 2.13’te verilen örnek EMG işaretine uygulanmasıyla elde edilen ÖKF’ler şekil 2.14’te gösterilmiştir. ÖKF’lerin her bir adımda giderek daha az salınımlı yapıya ulaşıldığı açıkça görülmektedir.



Şekil 2.13 Örnek sEMG Sinyali.



Şekil 2.14 Amputenin 4. Kanalından alınan sEMG sinyalinin ilk 10 ÖKF'sine ait veriler.

## 2.5 Öznitelik Çıkarma

EMG sinyalleri aracılığıyla, farklı el hareketlerinin ayrıştırılması için yapılması gereken önemli işlemlerden birisi de uygun öznitelik çıkarmaktır. Sınıflandırma işleminin sonucu, sınıflandırıcının kendisinden çok, kullanılan özniteliklerin etkisine bağlıdır. Öznitelik çıkarma işlemi, verinin içerisinde barındırdığı faydalı bilgileri elde etmek için kullanılan bir yöntemdir. Sinyalin kendisinden daha küçük boyutlu öznitelik vektörü elde etmek sınıflandırıcının hızını arttırarak, gerçek zamanlı uygulamaların daha iyi bir performans sergilemesini sağlayacaktır. sEMG sinyalinden çıkarılacak öznitelikler zaman tabanına, frekans tabanına ve zaman-frekans tabanına dayanan öznitelikler olmak üzere üç ana gruba ayrılabilir [7].

Öznitelikler doğrudan EMG sinyalinin kendisinden elde edilebileceği gibi, sinyalin ayrıştırılması sonucu ortaya çıkan bileşenler kullanılarak da elde edilebilir. Fakat el hareketleri sonucunda ortaya çıkan EMG işaretleri doğrusal olmayan ve durağan olmayan bir zaman serisi olarak kabul edildiğinden, doğrusallığı ve durağanlığı varsayan ayrıştırma algoritmaları yanıltıcı sonuçlar verebilmektedir [50]. Bu yüzden ayırt edilmesi kolay öznitelikleri kullanabilmek için, EMG sinyalinin karakteristik özelliklerini dikkate alan teknikler kullanarak öznitelikler elde edilmelidir. ÇDGKA EMG sinyallerine uygulanabilecek potansiyel bir yöntemdir. Sinyali adaptif olarak bileşenlerine ayıran ÇDGKA yöntemi, sinyalden ilgili özniteliklerin çıkarılmasına olanak sağlarken aynı zamanda arkaplan gürültüsünün bastırılmasında ve motor ünitelerinin tespit edilmesinde de işlevsel bir rol oynar [21] [51]. Sonuç olarak ÇDGKA yönteminin kullanılması neticesinde elde edilen özgül kip fonksiyonlarından çıkarılan özniteliklerin performansı bu çalışma kapsamında incelenecektir. Bu çalışmada kullanılan özniteliklere ait kısa tanımlamalar aşağıda verilmiştir.

**1. Varyans:** Sinyalin ortalamadan ne kadar uzaklaştığının bir ölçüsü olan standart sapmanın karesidir. Varyans ( $\sigma^2$ ), bu dalgalanmanın gücünü temsil eder. N elemanlı bir dizinin varyans hesabı;

$$\sigma^2 = \frac{1}{N-1} \sum_{i=1}^N |x_i - \mu|^2 \quad (2.12)$$

şeklindedir. Denklemden yer alan  $\mu$  dizinin ortalamasını temsil etmektedir.

**2. Sıfır Geçiş Sayısı:** Sıfır geçiş sayısı (ZC), zaman alanında tanımlı bir EMG sinyalinin, frekans bilgisinin hesabıdır yani sinyalin genliğinin sıfır olduğu noktalardan geçme sayısını veren bir özneliktir. Birbirine bitişik iki EMG örneğinin genliği sırasıyla  $x_k$  ve  $x_{k+1}$  olursa sıfır geçiş sayısı şu şekilde hesaplanabilir;

$$ZC = \sum f(x)$$

$$f(x) = \begin{cases} 1, & (x_k < 0 \cap x_{k+1} > 0) \text{ ya da} \\ & (x_k > 0 \cap x_{k+1} < 0) \text{ } k=1,2,\dots,N-1 \\ 0, & \text{diğer tüm durumlar için} \end{cases} \quad (2.13)$$

**3. Dalga Formu Uzunluğu:** Dalga formu uzunluğu (WL), EMG sinyalinin her bir segmentindeki karmaşıklık ölçüsünü ifade eden bir özneliktir. Sinyalin ardışık genlikleri  $x_m$  ve  $x_{m-1}$  arasındaki mutlak farkın toplamına eşittir.

$$WL = \sum_{m=1}^N |x_m - x_{m-1}| \quad (2.14)$$

**4. Etkin Değer:** Etkin değer (RMS), kasılma esnasında motor ünitelerdeki fizyolojik aktivitelerin seviyesini yansıttığı için sık seçilen bir parametredir.

$$RMS = \sqrt{\frac{1}{N} \sum_{n=1}^N |x_n|^2} \quad (2.15)$$

## 2.6 Sınıflandırma

EMG sinyallerinin temsil ettiği hareketlerin sınıflandırma başarısı, seçilen ve çıkarılan özneliklerin kalitesine büyük ölçüde bağlıdır. Sınıflandırma gerçekleştirilmeden önce gerçekleştirilen öznelik çıkarma adımı, bilgi yoğunluğunu arttırmaktadır. Bu özneliklerin sergilediği örüntüyü tanımak için ise makine öğrenmesi algoritmaları kullanılmaktadır. Kullanılan bu algoritmaların her biri kendine özgü yöntemler kullanarak örüntüyü tanır ve farklı örüntüleri birbirinden ayırt eder.

Bu tez kapsamında sEMG sinyalinin ÇDGKA metoduyla analizinin gerçekleştirilmesi sonucunda elde edilen özneliklerin, her bir el hareketi için ayırt etme yeteneğini ölçmek amacıyla en yakın komşu algoritması ( $k$ -NN), doğrusal ayırım analizi (LDA) ve destek vektör makineleri (SVM) kullanılmıştır. Bu kısımda bu sınıflandırıcıların kullandığı metodlar hakkında bilgi verilecektir.



### 2.6.1 *k*-Yakın Komşu Sınıflandırıcı


*k*-en yakın komşu algoritması (*k*-NN), sınıflandırma problemlerinde sıklıkla kullanılan bir danışmanlı öğrenme algoritmasıdır. Aynı zamanda veriye ait herhangi bir ön bilgiye ihtiyaç duymadan sınıflandırma yapabilen parametrik olmayan bir sınıflandırıcıdır. Bir sınıflandırma probleminde her bir sınıfın kendine ait karakteristik özellikleri vardır. Bu özellikleri temsil eden öznitelikler ise sınıflandırma probleminde araç olarak kullanılır. Bu algoritma kapsamında eğitim aşaması yoktur. Genellikle, mevcut veriler iki farklı kısma bölünür Sınıflandırma için eğitim verilerini (eğitim verisi ayrılır fakat model bu verileri herhangi bir eğitim aşamasına tabi tutmaz) kullanırken, test için geri kalan kısmını kullanır.

Öncelikle analiz edilmek istenilen veri setinden, eğitim örnekleri seçilir. Seçilen *N* adet örnek  $\bar{\mathbf{X}} = \{x_1, x_2, x_3, \dots, x_N\}$  eğitim kümesini oluşturur. Böylelikle kalan *k* adet örnek test verisini oluşturur  $\bar{\mathbf{Y}} = \{y_1, y_2, y_3, \dots, y_K\}$  seçilen her bir örnek ile eğitim setinde yer alan *k* adet örnek için uzaklık mesafesi hesaplanarak test örneğine ait sınıf bulunur.

$$d(\mathbf{X}, \mathbf{Y}) = \|\mathbf{X} - \mathbf{Y}\| \quad (2.16)$$

$d(\mathbf{X}, \mathbf{Y})$  mesafeyi temsil etmektedir. Test edilen örneğe en yakın *k* adet *x* eğitim örneği bulunur. Bu örneklerin sınıfları belirlenip aralarında oylama yapılır ve karar verme süreci tanımlanır. Şekil 2.15'te bilinmeyen bir test örneğinin *k*=4 için sınıflandırma işlemi yapılmaktadır. Bilinmeyen örneğe en yakın dört örnek bulunmuş ve bu örneklerden üçü A sınıfına ait iken birisi B sınıfına ait çıkmıştır. Sonuç olarak bilinmeyen örnek A sınıfına atanmış olur.

Sınıflandırma işlemini gerçekleştirmeden önce dikkate alınması gereken iki önemli özellik vardır. Biri kullanılacak olan *k* değeridir; *k* sayısının değeri isteğe bağlı olarak karar verilebilir ya da en uygun değeri bulmak için deneysel olarak *k* atanabilir. Diğer bir husus ise uzaklık hesaplamasında kullanılacak yöntemdir. Bu çalışma kapsamında öklid mesafesi hesaplamalarda kullanılmıştır.



Şekil 2.15  $k$ -NN sınıflandırma aşaması

## 2.6.2 Doğrusal Ayırım Analizi

LDA sınıflandırıcısı, sEMG sinyaline özgü özelliklerin ayırt edilmesinde geçmişte yaygın olarak kullanılmış bir algoritmadır [52]. Bir veri matrisi olan  $\mathbf{X} \in R^{N \times M}$ ,  $N$  adet  $\mathbf{x} \in R^{1 \times M}$  özellik vektöründen oluşmaktadır. Bayes olasılık kuramı ile verilen bir  $\mathbf{x} \in R^{1 \times M}$   $M$  elemanlı bir özellik vektörünün, bir  $y$  sınıfına ait olma olasılığı şu şekilde hesaplanır;

$$p(y_i | x) > p(y_j | x) \quad i \neq j \text{ için} \quad (2.17)$$

Yukarıda verilen test sonrası olasılıkların hesaplanıp karşılaştırılması için öncül olasılık bilgisine ihtiyaç vardır. Bayes kuralına göre test öncesi ve sonrası olasılıklarının arasındaki ilişki şu şekildedir;

$$p(y_i | x) = \frac{p(y_i) p(x | y_i)}{p(x)} \quad (2.18)$$

Denklem 2.18'de yer alan  $p(x | y_i)$  ifadesi  $y_i$  sınıfı için  $\mathbf{x} \in R^{1 \times M}$  özellik vektörünün olasılık dağılım fonksiyonunu temsil ederken  $p(y_i)$  ise öncül olasılığını vermektedir. Genelde ve bu çalışmada test öncesi olasılığı tüm sınıflar için eşit olarak kabul edilmektedir. Sonuç olarak test sonrası olasılığı yerine denklem 2.18'in sağ tarafındaki ifade kullanılırsa eşitlik şu hale gelir;

$$p(x | y_i) > p(x | y_j) \quad i \neq j \text{ için} \quad (2.19)$$

Böylelikle her bir sınıfa ait olasılık dağılım fonksiyonunun hesaplanmasıyla esasında sınıflandırma işlemi yapılabilmektedir. Ayrıca dağılımların çok değişkenli Gauss dağılımına sahip olduğu varsayılırsa;

$$p(x | y_i) = \frac{1}{(2\pi)^{k/2} \det(C)^{k/2}} \exp\left(-\frac{1}{2}(x - \mu)^T C^{-1}(x - \mu)\right) \quad (2.20)$$

Denklemden yer alan  $C \in R^{k \times k}$  boyutlu kovaryans matrisini,  $k$  ise değişken sayısını temsil etmektedir. LDA algoritması, farklı sınıflara ait örneklerin kolay bir şekilde ayrıştırılmasını sağlayıp olasılık dağılım fonksiyonlarını doğru olarak bulmayı amaçlamaktadır. Bu sebeple yüksek boyutlu orijinal veri uzayından, farklı sınıfların birbirinden ayrıştırılması kolaylaştıracak daha düşük boyutlu bir uzaya geçişi sağlayan transformasyon matrisini,  $W \in R^{M \times M}$  bulmak gerekmektedir. Bu transformasyon matrisi sadece boyut düşürmekle kalmayıp aynı zamanda sınıflar-arası dağılım matrisinin, sınıf-içi dağılım matrisine oranını,  $\frac{|W^T S_b W|}{|W^T S_w W|}$  maksimize edebilmelidir.

Transformasyon matrisini bulurken kullanılan  $S_b \in R^{M \times M}$  ve  $S_w \in R^{M \times M}$  dağılım matrislerinin hesaplanması şu şekildedir;

$$S_b = \frac{1}{N} \sum_{i=1}^c N_i (m_i - m)(m_i - m)^T \quad (2.21)$$

Sınıf arası dağılım matrisi veride yer alan tüm sınıfların birbiriyle olan ilişkisini temsil etmektedir. Denklemden yer alan  $N$  toplam örnek sayısını,  $N_i$  ifadesi  $i$ . sınıfa ait örnek sayısını ve  $c$  ise sınıf sayısını temsil etmektedir. Veri setindeki örneklerin ortalama değeri  $m$  ile gösterilirken  $m_i$  ise  $i$ . sınıfın ortalama değeridir.

$$S_w = \frac{1}{N} \sum_{i=1}^c \sum_{x \in C_i} (x - m_i)(x - m_i)^T \quad (2.22)$$

Sınıf içi dağılım matrisi, bir sınıfın içinde yer alan verilerin varyansları arasındaki ilişkiyi vermektedir. Denklemden yer alan  $x$ ,  $C_i$  sınıfında yer alan her bir veriyi temsil etmektedir. Sınıf içi ve sınıf arası dağılım matrislerinin hesaplanmasıyla beraber  $W \in R^{M \times M}$  transformasyon matrisi şu şekilde bulunabilir [53];

$$W = S_w^{-1} S_b \quad (2.23)$$


Veriyi daha düşük boyutlu bir uzaya yansıtma için transformasyon matrisine ait olan öz vektörleri ( $\mathbf{V} = [\mathbf{v}_1, \mathbf{v}_2, \dots, \mathbf{v}_M]$ ) ve bu öz vektörlere karşılık gelen öz değerlerin bulunmasına ( $\lambda = [\lambda_1, \lambda_2, \dots, \lambda_M]$ ) ihtiyaç vardır. En büyük  $k$  tane öz değere sahip öz vektör matrisi ( $\mathbf{V} \in R^{M \times k}$ ) kullanılarak, veri matrisi ( $\mathbf{X} \in R^{N \times M}$ ) daha düşük  $k$  boyutlu bir uzaya yansıtılır. Sonuç olarak daha düşük boyutlu bir uzaya yansıtılan veri şu şekilde ifade edilebilir;

$$\mathbf{Y} = \mathbf{XV} \quad (2.24)$$

Verinin daha düşük boyutlu bir uzaya aktarılmasıyla sınıflar arası varyans artırılırken, sınıf içi varyans azaltılmış olur ve sınıfların birbirinden ayrılması sağlanır.

### 2.6.3 Destek Vektör Makinesi

Gözlemlenen veriler üzerinde, genelleştirilmiş bir model oluşturularak verilerin en az hatayla doğru bir şekilde sınıflandırmasını amaçlayan destek vektör makineleri (SVM) esasında bir konveks optimizasyon problemidir. Farklı sınıflara ait verilerin arasındaki marjini en büyük yapacak hiperdüzlemi oluşturarak iki sınıfı birbirinden ayırmaya çalışır. Marjin, sınıfların oluşturulan hiperdüzleme olan minimum mesafesini temsil etmektedir. Şekil 2.16'da sınıflandırma işlemi için bulunan olası hiperdüzlemler (a) ve maksimum marjini sağlayacak hiperdüzlem (b) ayrı ayrı gösterilmiştir.



**Şekil 2.16** SVM algoritması için verileri sınıflandırma işleminin gerçekleştirilmesi (a) Olası hiperdüzlemler (b) Maksimum marjini sağlayan hiperdüzlem.

İki sınıf arasındaki en büyük marjini bulmak sınıflandırma esnasında ortaya çıkabilecek olası hatalardan kaçınmayı sağlamaktadır.

Bir sınıflandırma probleminde, sınıfların özelliklerini temsil eden veri kümesi  $\mathbf{X} = \{x_1, x_2, \dots, x_n\}$  ve  $\mathbf{x}_i \in R^m$  olarak tanımlanmaktadır. Bu verilere karşılık gelen sınıflar ise  $\mathbf{Y} = \{y_1, y_2, y_3, \dots, y_n\}$  ve  $y_i \in \{A, B\}$  şeklinde tanımlanmaktadır. İki sınıfı birbirinden ayırmak ve en büyük marjini bulmak için öncelikle hiperdüzlem belirlenmelidir ve şu şekilde ifade edilir;

$$\mathbf{w}^T \mathbf{x} + b = 0 \quad (2.25)$$

Belirlenen hiperdüzlemin bir tarafında A sınıfına ait örnekler, diğer tarafında ise B sınıfına ait örnekler bulunur. Bu sınıflar  $A \rightarrow -1$  ve  $B \rightarrow 1$  olarak atanırsa;

$$\begin{aligned} \mathbf{w}^T \mathbf{x}_i + b > 0 \text{ ise } y_i &= 1 \\ \mathbf{w}^T \mathbf{x}_i + b < 0 \text{ ise } y_i &= -1 \end{aligned} \quad (2.26)$$

hiperdüzlem iki sınıf arasında bir sınır olur ve karar vermek için kullanılır. Sınıfların ayrımını netleştirmek amacıyla merkezinde hiperdüzlem yer alacak şekilde hiperdüzleme paralel iki adet karar sınırı belirlenir. Bu sınırlar hiperdüzleme en yakın  $\mathbf{x}_i$  noktaları üzerinden geçer. Bu noktalara destek vektörleri ismi verilir. Yeni karar sınırları şu şekilde belirlenir;

$$\begin{aligned} \mathbf{w}^T \mathbf{x} + b &= 1 \\ \mathbf{w}^T \mathbf{x} + b &= -1 \end{aligned} \quad (2.27)$$

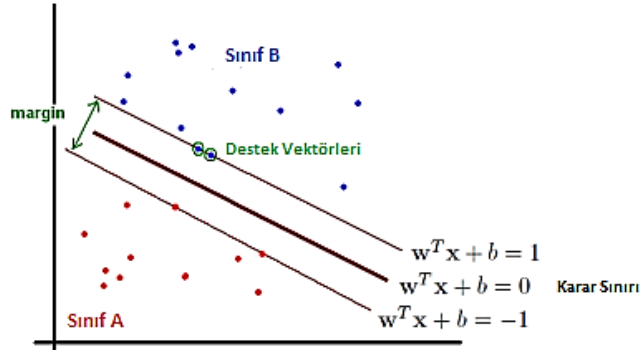
A sınıfına ait  $\mathbf{x}_1$ ,  $\mathbf{w}^T \mathbf{x}_1 + b = -1$  karar sınırı üzerinde ve B sınıfına ait  $\mathbf{x}_2$ ,  $\mathbf{w}^T \mathbf{x}_2 + b = 1$  üzerinde bulunursa  $\mathbf{x}_1$  ve  $\mathbf{x}_2$  arasındaki mesafe ' $\alpha \|\mathbf{w}\|$ ' olur ve bu mesafe  $\mathbf{x}_1$  ve  $\mathbf{x}_2$  arasındaki en küçük mesafe olmakla beraber en büyük marjini verir. Şekil 2.17'de A ve B sınıflarını birbirinden ayıran marjin ve karar sınırları gösterilmiştir.

İki farklı sınıfın birbirinden ayırt edilmesini sağlayacak ve en büyük marjini verecek  $\alpha$  değeri bulunmaya çalışılır. Bu değeri elde etmek için sırasıyla şu işlemler gerçekleştirilir;

$$\begin{aligned}
\mathbf{w}^T \mathbf{x}_2 + b - \mathbf{w}^T \mathbf{x}_1 + b &= 2 \\
\mathbf{w}^T (\mathbf{x}_2 - \mathbf{x}_1) &= 2 \\
\mathbf{w}^T \alpha \mathbf{w} &= 2 \\
\alpha &= \frac{2}{\mathbf{w}^T \mathbf{w}}
\end{aligned} \tag{2.28}$$

Elde edilen  $\alpha$  değerini kullanarak marjini en büyük yapacak mesafeyi hesaplamak için işlem şu şekilde devam ettirilir;

$$\alpha \|\mathbf{w}\| = \frac{2}{\mathbf{w}^T \mathbf{w}} \|\mathbf{w}\| = \frac{2}{\sqrt{\mathbf{w}^T \mathbf{w}}} \tag{2.29}$$



Şekil 2.17 Karar sınırları ve marjin.

Açıkça görüldüğü gibi karar sınırları arasındaki mesafeyi en büyük değerine getirmek için,  $\mathbf{w}^T \mathbf{w}$  minimize edilmelidir.

$$\begin{aligned}
\min_{\mathbf{w}, b} \frac{1}{2} \mathbf{w}^T \mathbf{w}, \text{ problem} \\
y_i (\mathbf{w}^T \mathbf{x}_i + b) &\geq 1, \text{ kısıt} \\
\mathbf{w} \in R^n, b \in R
\end{aligned} \tag{2.30}$$

Sonuç olarak en büyük marjinin belirlenmesi, ikinci dereceden bir konveks en uygun şekle sokma probleminin çözümüne bağlıdır. Bununla birlikte bu problem ayrıca  $y_i (\mathbf{w}^T \mathbf{x}_i + b) \geq 1$  kısıtına maruz kalmaktadır. Bu tarz kısıtlanmış optimizasyon problemlerini çözmek için Lagrange çarpanları  $a_i \in R_+$  kullanılmaktadır. Bu problem tekrar düzenlenirse;

$$J(\mathbf{w}, b, a) \min_{\mathbf{w}, b} \max_{a_i \geq 0} = \frac{1}{2} \mathbf{w}^T \mathbf{w} - \sum_i a_i [y_i (\mathbf{w}^T \mathbf{x}_i + b) - 1] \tag{2.31}$$

Yeniden düzenlenen denklemde  $\mathbf{w}$  ve  $b$  için minimum değeri bulmak maksadıyla bu ifadenin  $\mathbf{w}$  ve  $b$ 'ye göre kısmi türevi alınıp sıfıra eşitlenir;

$$\begin{aligned}\frac{\partial J}{\partial \mathbf{w}} &= \mathbf{w} - \sum_i a_i y_i \mathbf{x}_i = 0 \\ \frac{\partial J}{\partial b} &= \sum_i a_i y_i = 0\end{aligned}\quad (2.32)$$

Türev işleminin gerçekleştirilmesiyle  $\mathbf{w} = \sum_i a_i y_i \mathbf{x}_i$  bulunur. Aynı zamanda problem  $\sum_i a_i y_i = 0$  kısıtına maruz kalmaktadır.

Elde edilen değerler Lagrange denkleminde yerlerini konulursa;

$$\min_{\mathbf{w}, b} J(\mathbf{w}, b, a) = \sum_i a_i - \frac{1}{2} \sum_{i,j} a_i a_j y_i y_j \mathbf{x}_i^T \mathbf{x}_j \quad (2.33)$$

Problemin çözümü için gereken diğer bir şart ise şu şekilde olur;

$$\begin{aligned}\max_{a>0} \sum_i a_i - \frac{1}{2} \sum_{i,j} a_i a_j y_i y_j \mathbf{x}_i^T \mathbf{x}_j \\ 0 \leq a_i \leq C\end{aligned}\quad (2.34)$$


Denklem 2.34'te verilen  $C$  değeri aşırı uyumu engellemek için belirlene bir sınırdır. Denklem 2.33 ve 2.34'ün çözümüyle uygun parametreler bulunur.

## 2.7 Deney Süreci

Bu kısımda daha önceki bölümlerde tanıtılan metodların uygulama sürecine yönelik bilgiler verilecektir. ÇDGKA yöntemi sinyali frekans bantlarına ayırırken, ortaya çıkacak frekans bantlarının sayısı analiz edilen sinyalin uzunluğuna bağlıdır. Bu sebeple çalışmanın ilk kısmında sinyalin içerdiği tüm frekans bantlarının elde edilmesi için  $L$  adet örnekli sEMG sinyalleri kullanılmıştır. Bu işlem sonucunda elde edilen  $K$  adet ÖKF bileşeninin herbirine ait varyans, sıfır geçiş sayısı, etkin değer ve dalga formu uzunluğu değerleri hesaplanır. Böylelikle tek bir harekete ait öznitelik vektörünün uzunluğ ise kanal sayısı, ÖKF sayısı ve öznitelik sayısının çarpımı olarak bulunur (x vb vermeden yaz yeter) . Elde edilen öznitelik vektörleri  $k$ -NN, LDA ve SVM sınıflandırıcıları kullanılarak sınıflandırılmıştır ve elde edilen sonuçlara göre uygun bilgi barındıran bant bileşenleri tespit edilmeye çalışılmıştır.

Sınıflandırma performansını düşüren  $e$  adet ÖKF bileşeninin elimine edilmesiyle yeterli bilgiyi barındıran ÖKF sayısı tespit edilmiştir.


ÇDGKA yöntemi, ampirik olarak ÖKF bileşenlerini elde ettiğinden ve analiz gerçekleştirilmeden önce ÖKF sayısı kestirilemediği için ihtiyaç duyulan ' $K-e$ ' adet ÖKF sayısının belirlenmesi ampirik olarak gerçekleştirilmiştir. Bu işlem sonucunda uygun ÖKF bileşenlerini elde etmeyi sağlayacak sinyal uzunluğu tespit edilmiştir. Şekil 2.18'de bu işleme ait süreç gösterilmiştir.



Şekil 2.18 Analiz edilecek uygun sinyal uzunluğunun belirlenmesi.

### 2.7.1 Öznitelik Çıkarma Süreci

Sinyalin analizi için gereken uygun uzunluk bulunduktan sonra sinyale pencereleme işlemi uygulanmıştır. Gerçek zamanlı uygulamalarda örtüşen pencereleme işlemi daha avantajlı olduğundan bu çalışma kapsamında örtüşen pencereleme işlemi yapılması tercih edilmiştir. Şekil 2.19'da pencereleme işlemine ait süreç gösterilmiştir.




Şekil 2.19 Sinyale uygulanana pencereleme işlemi.

Veri setinde yer alan toplamda altı el ve parmak hareketine ait sinyallere pencereleme işleminin uygulanmasıyla uygun uzunluktaki sinyaller ÇDGKA yöntemi ile salınım

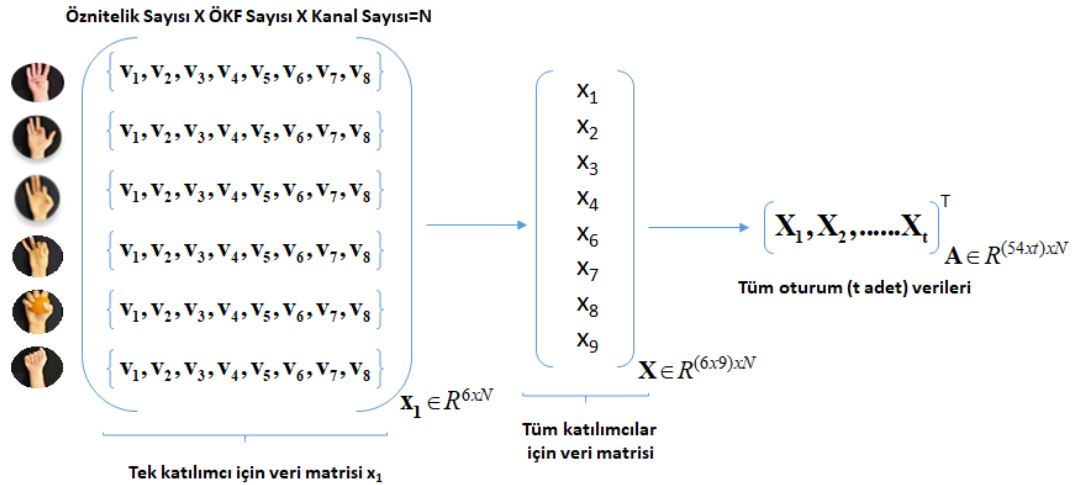


modlarına ayrıştırılır. Tüm ÖKF'lerden öznitelik çıkarılmasıyla öznitelik vektörü elde edilir. Şekil 2.20'de BP hareketine ait pencerelenmiş çok kanallı sEMG sinyalinin birinci kanalına ait öznitelik çıkarma süreci gösterilmiştir.



Şekil 2.20 Tek bir kanal için öznitelik vektörünün elde edilmesi.

Şekil 2.20'de birinci kanala ait verilen öznitelik çıkarma işlemi, sekiz kanal için uygulanarak tek bir harekete ait öznitelik vektörü oluşturulur. Veri setinde yer alan tüm hareketler için bu işlem tekrarlanarak sınıflandırma için gereken veri matrisi oluşturulur. Şekil 2.21'de el ve parmak hareketlerine ait sEMG sinyallerinin tek bir penceresinden elde edilen ÇDGKA tabanlı özniteliklerin oluşturduğu veri matrisinin yapısı gösterilmiştir.



Şekil 2.21 Sınıflandırma için tüm verilerin elde edilme süreci.


Tüm pencerelerden gelen öznitelikler kullanılarak sınıflandırma işlemi için veri matrisi hazır hale getirilmiş olur.

## 2.7.2 Sınıflandırma Süreci

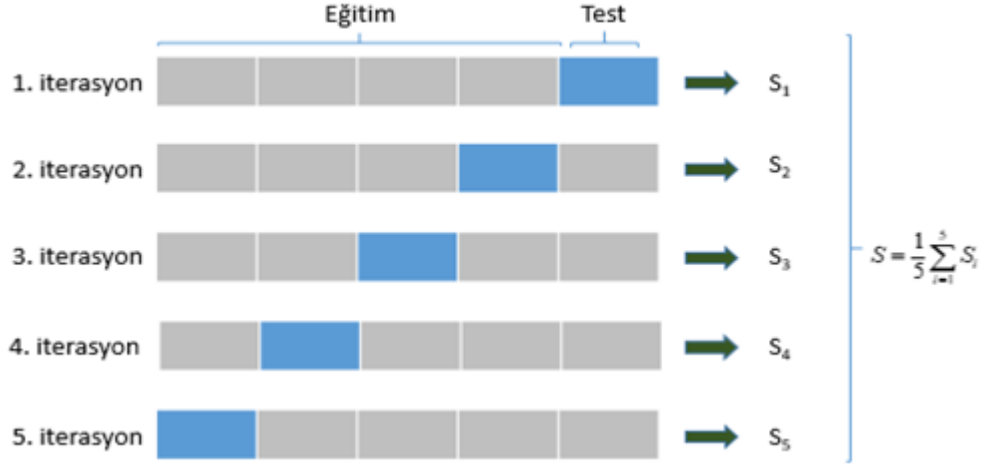
ÇDGKA tabanlı özneliklerin performansını incelemek için çalışma kapsamında k-NN, LDA ve SVM sınıflandırıcıları kullanılmıştır. Sınıflandırma işlemi kullanıcı ve kuvvet bağımsız, kullanıcı-bağımlı, kullanıcı-bağımsız olmak üzere üç parçaya ayrılmıştır.

Kullanıcı-bağımlı sınıflandırmada, sınıflandırıcı tek bir kullanıcıdan gelen verilerle eğitilip test edilir. Tüm kullanıcılar için ayrı ayrı sınıflandırma sonuçları bulunarak performans değerlendirmesi yapılır. Kullanıcı-bağımsız sınıflandırma işlemi için sınıflandırıcı tüm kullanıcılardan gelen veriler ile eğitilip test edilir ve özneliklerin kullanıcılardan bağımsız olarak performansları test edilir.

Kullanıcı ve kuvvet bağımsız sınıflandırıcı işleminde ise tüm kullanıcıların gerçekleştirdikleri hareketlere ait düşük, orta ve yüksek kuvvet seviyeleri karışık olarak sınıflandırıcının eğitimi için kullanılır. Aynı şekilde test işlemi bu verilerle gerçekleştirilir ve özneliklerin hem kullanıcıdan hem de kuvvetten bağımsız performansları incelenir. Şekil 2.22’de bu üç farklı sınıflandırma bölümünde kullanılan veri matrisler ve genel sınıflandırma süreci gösterilmiştir.



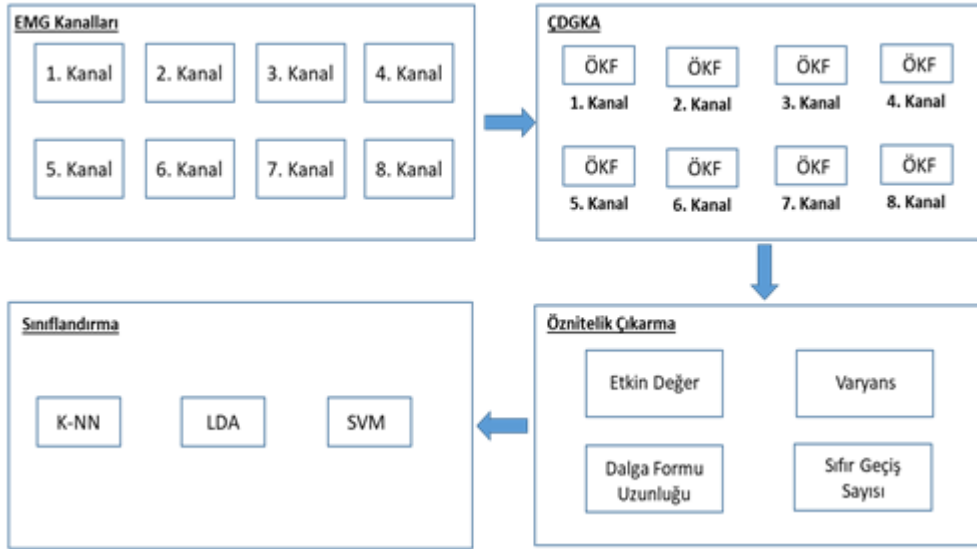
Şekil 2.22 Verilerin sınıflandırılmasında izlenen süreç



**Şekil 2.23** Sınıflandırma sürecinde 5- katlamalı çapraz doğrulama yönteminin uygulanması

Şekil 2.23'te aynı veri seti için beş farklı eğitim ve test kısmı oluşturulmuştur. Tüm iterasyonlar sonucunda elde edilen sonuçların ortalaması bulunarak önerilen özneliklerin performansı daha gürbüz bir şekilde değerlendirilmiş olur.

Deney sürecine ilişkin öznelik ve sınıflandırma adımlarına ait akış diyagramı Şekil 2.24'te gösterilmiştir.

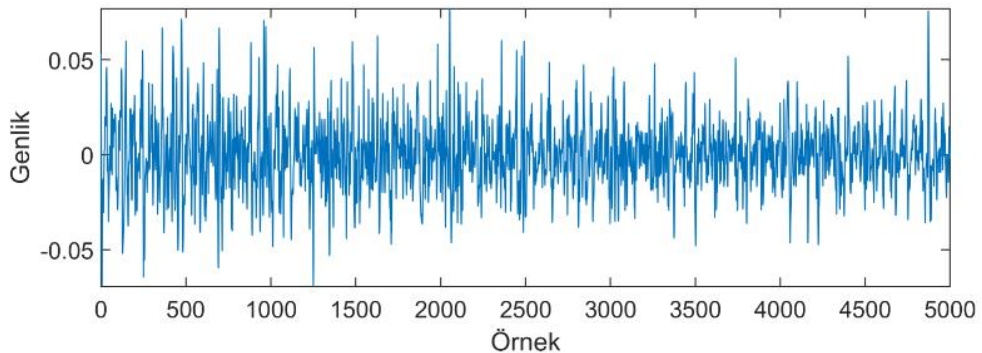


**Şekil 2.24** ÇDGKA tabanlı öznelik çıkarma süreci genel akış diyagramı

### 3. BULGULAR

Bu bölümde, EMG kontrollü el protezinin geliştirilmesine yönelik yapılan çalışmaların ve uygulanan yöntemlerin sonuçları yer almaktadır. EMG sinyal işlemesi için alternatif bir yöntem olan ÇDGKA kullanılmıştır. Ampute katılımcılardan toplanan düşük, orta ve yüksek kuvvet seviyelerine ait EMG sinyalleri ile altı farklı el ve parmak hareketinin sınıflandırılması yapılmıştır. Sınıflandırma işlemi yapılmadan önce sekiz kanallı EMG sinyali üzerinde ÇDGKA yöntemi uygulanarak ÖKF bileşenleri elde edilmiştir. Ampute bireylerden toplanan sekiz kanallı 5000 örneklilik sinyalin ayrıştırılması neticesinde her bir kayıttan 13 ile 15 arasında ÖKF elde edilerek ilk 10 ÖKF'den öznitelikler çıkarılmıştır. Böylelikle tek bir kayıt için elde edilen öznitelik vektörü 320 elemanlı olmuştur(8 Kanal x 10 ÖKF x 4 öznitelik ).


Öznitelik çıkarma ve sınıflandırma algoritmaları sEMG sinyallerinden elde edilen ÖKF'lere uygulanarak sonuçlar elde edilmiştir. Bu çalışmada etkin değer, varyans, sıfır geçiş sayısı ve dalga formu uzunluğu olmak üzere dört adet zaman tabanlı öznitelik kullanılmıştır. Sınıflandırma işlemi için k-en yakın komşu ( $k$ -NN), destek vektör makineleri (SVM) ve doğrusal ayırt etme analizi (LDA) algoritmaları uygulanıp test edilmiş ve doğruluk sonuçları karşılaştırılmıştır. Şekil 3.1'de amputelerden toplanan örnek bir sEMG işaretine ait zaman-genlik grafiği verilmiştir.




**Şekil 3.1** İlk amputeden alınan orta kuvvet seviyesindeki BP hareketine ait EMG sinyali.

### 3.1 ÇDGKA Yöntemi ile ÖKF Bileşenlerinin Bulunması

Şekil 3.2 ve Şekil 3.3'te örnek bir sEMG işaretinin tek bir kanalına ait ÖKF'ler yer almaktadır. İlk ÖKF'den son ÖKF'ye doğru gidildikçe bileşenlerin periyotlarındaki değişimin artma eğiliminde olduğu görülmektedir. Her ÖKF, orijinal sinyalin farklı frekans bantlarındaki salınımlarını temsil etmektedir.




Şekil 3.2 İlk amputeden alınan orta kuvvet seviyesindeki BP hareketinin, birinci kanal sEMG sinyaline ait ilk 7 ÖKF bileşeni.



**Şekil 3.3** İlk amputeden alınan orta kuvvet seviyesindeki BP hareketinin, ilk kanal sEMG sinyaline ait son 6 ÖKF bileşeni ve artık.


Şekil 3.4’te orta kuvvet seviyesindeki BP hareketinin tüm kanallarındaki her bir ÖKF’nin ortalama frekans değerleri verilmiştir. sEMG sinyalinin ediniminde kullanılan sekiz kanalın her birinde toplam 13 ÖKF bileşeni ve bir de artık vardır. Her ÖKF bileşeninin farklı bir salınım modunu temsil ettiği verilen şekilde açıkça görülmektedir.

Ayrıca ÇDGKA yöntemi kanalların tümünden aynı sayıda ÖKF bileşeni çıkararak, tüm kanalların salınım modlarının aynı ölçekte hizalanmasını da sağlamaktadır. ÇDGKA algoritmasının kanallar arasındaki mod hizalama ve ÖKF’ler arasındaki mod karışımı ölçütlerini uygun bir şekilde yerine getirdiği görülmektedir.



**Şekil 3.4** Orta kuvvet seviyesindeki BP hareketine ait 8 kanallı sEMG sinyalinin ÇDGKA kullanılarak elde edilen ÖKF'lerinin ortalama frekans değerleri.

Tablo 3.1'de, bulunan tüm ÖKF'lerin ortalama frekans değerleri verilmiştir. Ortalama frekans değerleri ÖKF'lerin hangi bant aralığında salınım yaptığına dair bilgi vermektedir. ÇDGKA yöntemi sinyalin ayrıştırılmasında kullanılırken bununla birlikte her ÖKF'nin farklı frekans bandında salınım yapması sebebiyle sinyalin gürültüden temizlenmesi için de kullanılabilir. Özellikle kayıt esnasında ve elektromanyetik girişim sebebiyle ortaya çıkan düşük frekans bandındaki gürültülerin temizlenmesi için 20 Hz frekans değeri altında kalan ÖKF'ler sınıflandırma performansını arttırmak için kullanılmamıştır.



**Şekil 3.5** Sinyallerden elde edilen ÖKF sayılarının dağılımı.




**Tablo 3.1** Bütün kuvvet seviyelerinden elde edilen ÖKF'lerin ortalama frekans değerleri.

Toplam ÖKF Sayısı	Düşük Kuvvet (Hz)	Orta Kuvvet (Hz)	Yüksek Kuvvet (Hz)
1	348,96	345,85	345,26
2	199,55	198,36	198,37
3	116,56	115,82	115,90
4	66,60	66,38	66,33
5	40,57	40,44	40,36
6	23,29	23,60	23,63
7	14,02	14,24	14,21
8	8,75	8,76	8,65
9	5,32	5,34	5,32
10	3,37	3,34	3,35
11	2,17	2,16	2,15
12	1,51	1,52	1,47


### 3.2 ÖKF Tabanlı Özniteliklerin Sınıflandırılması ve ÖKF'lerin Eliminasyonu

ÇDGKA yönteminin herhangi bir taban fonksiyonu kullanmadan adaptif olarak sinyali ayrıştırmasından dolayı, analiz işlemi bitmeden çıkarılabilecek ÖKF sayısını kestirebilmek mümkün değildir. Şekil 3.5'te toplamda 810 farklı kayıttan elde edilmiş çok kanallı sinyallerin ÖKF sayılarının genel dağılımı gösterilmiştir. Bu dağılımdan da anlaşılacağı üzere ÖKF sayılarındaki bu değişkenlik, sEMG sinyalinin ayırt edilmesinde kullanılacak öznitelik vektörünün boyutunun farklı örnekler için farklı uzunlukta olmasına sebep olabilir. Bu faktörleri göz önünde bulundurarak çalışma kapsamında öznitelik vektörünün tutarlılığını sağlamak için ilk 10 ÖKF öznitelik çıkarmak için kullanılmıştır. Analiz edilen sinyalin örnek sayısı arttıkça sinyalden elde edilen ÖKF sayısı da arttığından öncelikle 5000 örneklilik sinyal kullanılmıştır. Bunun sonucu olarak sinyalden daha detaylı bilgi edinilmesi amaçlanmıştır. Şekil 3.6'da tüm kanalların ÖKF bileşenlerinden çıkarılan özniteliklerin dağılımı altı farklı hareket için gösterilmiştir. Şekil 3.7'de ise KÜK hareketinin tüm katılımcılardan toplanan özniteliklerinin dağılımı yer almaktadır. ÖKF bileşenlerinden çıkarılan özniteliklerin performansı  $k$ -NN, LDA ve SVM sınıflandırma algoritmaları kullanılarak test edilmiştir.






**Şekil 3.6** Üçüncü amputenin düşük kuvvet seviyesindeki tüm kanallara ait 10 ÖKF'sinin WL-  $\sigma^2$ -Rms öznitelikleri dağılımı.




**Şekil 3.7** Tüm amputelerden alınan düşük kuvvet seviyesindeki KÜK hareketinin tüm kanallarına ait 10 ÖKF'sinin WL-  $\sigma^2$ -rms öznitelikleri dağılımı.

Şekil 3.6 ve Şekil 3.7'de verilen dağılımlar, özniteliklerin ait oldukları kullanıcıya ve sınıfa göre değişimlerini göstermektedir. ÖKF bileşenlerinden elde edilen bu özniteliklerin performansı öncelikle kullanıcı-bağımlı olarak sınıflandırılmıştır.

Veri setinde yer alan üç farklı kuvvet seviyesine ait EMG örneklerinin ÇDGKA ile analizinin yapılması sonucunda elde edilen ÖKF'lere ait özneliklerin sınıflandırılmasıyla her bir katılımcıya ait doğruluk sonuçları sırasıyla Şekil 3.8, Şekil 3.9 ve Şekil 3.10'da verilmiştir.




Şekil 3.8 Kullanıcı-Bağımlı düşük kuvvet seviyesi sınıflandırma sonuçları.

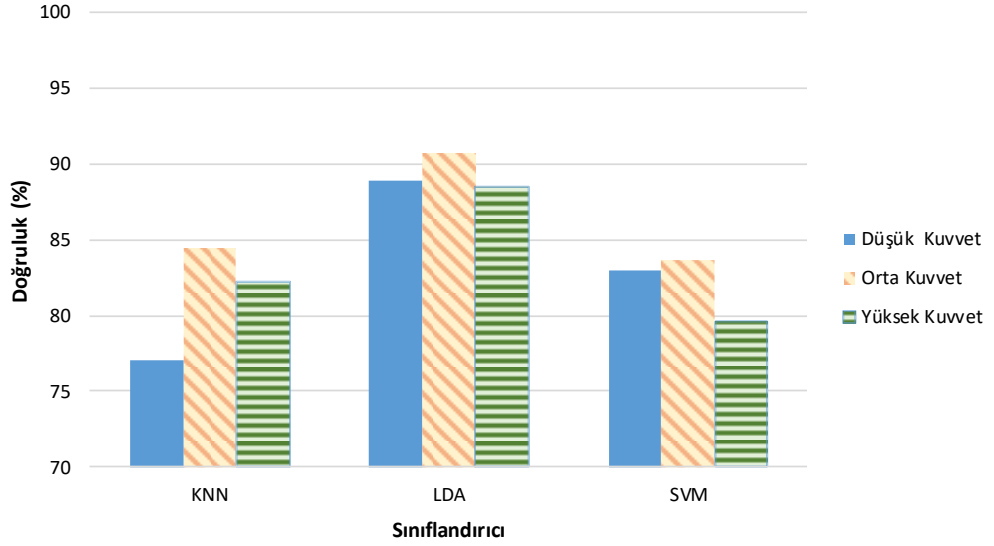


Şekil 3.9 Kullanıcı-Bağımlı orta kuvvet seviyesi sınıflandırma sonuçları.

Parmak hareketlerinin kullanıcı bağımlı sınıflandırma sonuçlarını veren KNN, LDA ve SVM sınıflandırıcılarının performansları Şekil 3.11'de gösterilmiştir. Elde edilen sonuçlara göre LDA sınıflandırıcısı %90,7'e kadar başarı sağlamıştır ve her üç kuvvet seviyesi için diğer sınıflandırıcılara üstün geldiği açıkça görülmektedir.



Şekil 3.10 Kullanıcı-Bağımlı yüksek kuvvet seviyesi sınıflandırma sonuçları.



Şekil 3.11 KNN, LDA ve SVM için sınıflandırma sonuçları.

Tabloda 3.2’de verilen bilgilere göre ÖKF sayısının fazla olmasının sınıflandırma performansı üzerinde olumlu bir etki oluşturmadığı görülmektedir. Bu yüzden sEMG sinyali için daha kısa uzunlukta örnek kullanmak sinyalin analizi için yeterli olacaktır. ÇDGKA öncelikle yüksek salınımlı bileşenlerden başlayarak sinyali ayrıştırdığından, sinyalin analizi için gerekli olan bantlar ilk bileşenlerde yer almaktadır. İlk 6 ÖKF yani 20 Hz üstünde yer alan frekans bileşenlerinin kullanılması yeterlidir. Bu sebeple bu bileşenleri veren en kısa uzunluktaki sinyal analiz edilmelidir. ÖKF bileşenlerinin sayısını önceden kestirebilmek mümkün olmadığı için, bu işlem ampirik olarak gerçekleştirilmelidir.

**Tablo 3.2** Tüm kuvvet seviyeleri için ÖKF sayısına göre elde edilen doğruluk oranları.


ÖKF Sayısı	Sınıflandırıcı	Doğruluk (%)
İlk 3 ÖKF	<i>k</i> -NN	80,1
	LDA	90,6
	SVM	85,6
İlk 6 ÖKF	<i>k</i> -NN	81,9
	LDA	<b>92,1</b>
	SVM	86,6
İlk 10 ÖKF	<i>k</i> -NN	82,3
	LDA	89,3
	SVM	82,1
Ham Sinyal	<i>k</i> -NN	87,5
	LDA	86,6
	SVM	86,6

ÇDGKA tabanlı özneliklerin sınıflandırma performansının, ham sinyalden direkt olarak çıkarılan özneliklerin sınıflandırma performansı ile karşılaştırılmasına dair sonuçlar Tablo 3.2’de ayrıca verilmiştir.

Sonuçlara göre ÇDGKA ile elde edilen ilk 6 ÖKF’den çıkarılan özneliklerin doğruluk oranı maksimum %92,1 iken, ham sinyalden çıkarılan özneliklerin doğruluk oranı ise maksimum %87,5 olmuştur.


### 3.3 sEMG Sinyallerinin Protez Kontrolü için Kısa Zamanlı Analizi

sEMG sinyali kontrollü bir protez elin pratik olarak uygulamalarda kontrolünü gerçekleştirmek için, kısa örneklili sEMG sinyallerinin analizinin yapılması gerekmektedir. Bu kısımda ÇDGKA yönteminin bu amaca yönelik uygulanması ve performansı incelenecektir. Bir önceki kısımda sEMG sinyali üzerinde uygulanan ÇDGKA yöntemi ile bulunan ÖKF’lerin sınıflandırma performansına olan etkileri incelenmiştir. Elde edilen sonuçlara göre ilk 6 ÖKF’nin sınıflandırma performansında en iyi sonucu almak için yeterli olduğu gözlemlenmiştir. Ayrıca bu sonucun ham sinyalde direkt olarak elde edilen özneliklere göre daha ayırt edici olduğu görülmüştür. Bu sebeple en az 6 ÖKF elde etmeyi sağlayacak uzunluktaki sinyali kullanmak hem hesaplama yükünü azaltmaktadır hem de ÇDGKA tabanlı örüntü tanıma modelinin gerçek zamanlı olarak uygulanabilmesine yönelik performansı arttırmaktadır. Ampirik olarak gerçekleştirilen çalışmalar sonucunda 256 ms uzunluğundaki sinyalin en az 6 ÖKF bileşeni çıkarmayı temin ettiği görülmüştür.



**Şekil 3.12** Yüksek kuvvet sEMG işaretine uygulanan pencereleme işlemi.


Çalışma boyunca 14580 adet 256 ms uzunluğunda pencere üzerinde ÇDGKA yöntemi uygulanmıştır ve tüm pencereler gereken ÖKF bileşenlerini sağlamıştır. Pencereleme işlemi için 256 ms uzunlukta normal pencere kullanılmıştır. Pencereleme işlemi için 256 ms uzunlukta normal pencere kullanılmıştır. Pencereleme işlemi için 256 ms uzunlukta normal pencere kullanılmıştır. Bu işleme ait süreç Şekil 3.12’de gösterilmiştir. Pencereleme sonucunda elde edilen örnek sinyaller ise Şekil 3.13’te gösterilmiştir.



**Şekil 3.13** Sinyalden elde edilen ilk üç pencere

### 3.3.1 ÇDGKA ile ÖKF'lerin bulunması

Pencerelenen sinyaller ÇDGKA ile ÖKF bileşenlerine ayrıştırılmıştır. Şekil 3.14'te tek bir kanalın, bir penceresinden çıkarılan ÖKF bileşenleri gösterilmiştir.



Şekil 3.14 Tek bir pencereden elde edilen ÖKF bileşenleri.

Ayrıca bu sinyale ait ÖKF'lerin her birine ait ortalama frekans değerleri Tablo 3.3'te yer almaktadır. Pencerelenmiş sinyalde halen ilk 6 ÖKF bileşeninin, 20 Hz ve üstünde yer alan salınım bileşenlerini barındırdığı görülmektedir.

Tablo 3.3 ÖKF'lerin ortalama frekans değerleri.

ÖKF	1.ÖKF	2.ÖKF	3.ÖKF	4.ÖKF	5.ÖKF	6.ÖKF	7.ÖKF	8.ÖKF	Artık
<b>Ortalama Frekans (Hz)</b>	374,8	216,5	126,8	78,2	44,6	24	15,1	7,51	4,7

Sinyal uzunluğu kısılmasına rağmen ÇDGKA yöntemi sEMG sinyalinden halen ihtiyaç duyulan frekans bantlarını çıkarabilmektedir. Sinyalin kısılması sadece düşük frekans bantlarındaki bileşenlerin elde edilememesine sebep olmuştur fakat bu bantlar sEMG sinyali analizi için gereken bileşenler değildir. Çalışmalar neticesinde pencerelerden en az 7 en fazla 11 ÖKF bileşeni elde edilmiştir ve bu da öznelik çıkarma işlemi için uygun olan bantları kullanmak için elverişli bir imkân sunmaktadır.

### 3.3.2 Kullanıcı Bağımlı Sınıflandırma

Bu kısımda pencerelenen sinyallerden elde edilen ÖKF'ler ve bu ÖKF'lerden elde edilen özniteliklerin kullanıcı-bağımlı sınıflandırma sonuçları gösterilmiştir. Bu kısımda deneysel gözlemler sonucunda ÖKF tabanlı sıfır geçiş sayısı özniteliklerinin sınıflandırma performansını düşürdüğü tespit edilmiştir. Dolayısıyla ÖKF'lerin varyans, etkin değer ve dalga formu uzunluğu hesaplanarak öznitelikler elde edilmiştir.

Tablo 3.4'te pencereleme yöntemiyle elde edilen örnekler kullanılarak yapılan sınıflandırma sonuçları verilmiştir.

**Tablo 3.4** Kullanıcı-Bağımlı sınıflandırma sonuçları.

Kuvvet Seviyesi	Sınıflandırıcı	ÇDGKA Doğruluk (%)	Ham Doğruluk(%)
Düşük Kuvvet	<i>k</i> -NN	94,9	93,8
	LDA	96,7	95,9
	SVM	82,8	66,5
Orta Kuvvet	<i>k</i> -NN	96,2	95,5
	LDA	<b>98,3</b>	97,6
	SVM	83,9	61,4
Yüksek Kuvvet	<i>k</i> -NN	95,2	93,6
	LDA	98,2	96,6
	SVM	77,1	62,9
Ortalama	<i>k</i> -NN	95,2	94,3
	LDA	97,8	96,7
	SVM	81,3	63,6

Tüm sınıflandırıcılarda ve tüm kuvvet seviyelerinde ÇDGKA tabanlı öznitelik çıkarma yönteminin ham veriden doğrudan öznitelik çıkarma yöntemine göre *k*-NN ve LDA için ortalama %1, SVM için ortalama %16 daha başarılı olduğu açıkça görülmektedir. Ayrıca en yüksek başarı oranı %98.3 ile orta kuvvet seviyesindeki ÇDGKA tabanlı öznitelikler kullanılarak elde edilmiştir.

**Tablo 3.5** Kullanıcı içi kuvvetten bağımsız sınıflandırma sonuçları.

Yöntem	Sınıflandırıcı	Doğruluk (%)
ÇDGKA Tabanlı	<i>k</i> -NN	93,8
	LDA	92,8
	SVM	<b>95,4</b>
Ham Sinyal	<i>k</i> -NN	91,8
	LDA	88,8
	SVM	94,4


Çıkarılan özniteliklerin kuvvetten bağımsız bir şekilde kullanıcı içi sınıflandırma sonuçları Tablo 3.5'te verilmiştir. Sınıflandırıcılar her bir katılımcı için tüm kuvvet seviyeleriyle eğitilip test edilmiştir. Kuvvetten bağımsız olarak yapılan sınıflandırma

sonuçları için de ÇDGKA yöntemi tabanlı öznelikler ham sinyalden doğrudan çıkarılan özneliklere göre her üç sınıflandırıcıda da daha yüksek oranda başarı sağlamıştır. En yüksek başarı oranı ise %95.4 ile ÇDGKA tabanlı özneliklerin SVM ile sınıflandırılması neticesinde elde edilmiştir.


### 3.3.3 Kullanıcı Bağımsız Sınıflandırma

Bu kısımda ÇDGKA yöntemi tabanlı özneliklerin kalitesini test etmek için sınıflandırma işlemleri kullanıcıdan bağımsız olarak gerçekleştirilmiştir.

Şekil 3.15 ve Şekil 3.16'da sırasıyla ÇDGKA tabanlı ve ham sinyalden elde edile özneliklerin dağılımı gösterilmiştir.




**Şekil 3.15** Tüm kuvvet seviyeleri için altı farklı parmak hareketinin 1. kanal 6 ÖKF'sine ait özneliklerin dağılımı.



**Şekil 3.16** Tüm kuvvet seviyeleri için altı farklı parmak hareketinin 1. kanalına ait ham sinyallerden çıkarılan özneliklerin dağılımı.



Şekil 3.17’de ÇDGKA tabanlı ve ham sinyal tabanlı özniteliklerin kullanıcı-bağımsız sınıflandırma sonuçları gösterilmiştir. Bu sonuçlara karşılık gelen sayısal veriler ise Tablo 3.6’da verilmiştir. Tabloda verilen değerlere göre önerilen ÇDGKA yöntemi elde edilen sonuçlar tüm kuvvet seviyelerinde ayrı ayrı ve tüm kuvvet seviyeleri bir arada olmak üzere tüm durumlarda ham sinyalden doğrudan elde edilen özniteliklerin performansı aşmıştır.



**Şekil 3.17** KNN, LDA ve SVM sınıflandırıcıları ile her bir kuvvet seviyesi kullanıcı-bağımsız olarak.

Ayrıca tüm kuvvet seviyeleri ile birlikte yapılan sınıflandırma sonuçlarının daha düşük seviyede başarılı olduğu görülmektedir. ÇDGKA tabanlı sınıflandırma performansı, ham sinyal tabanlı sınıflandırma performansına göre %15 ile %20 arasında daha fazla başarılı sonuç vermiştir. En yüksek sınıflandırma sonuçlarını k-NN verirken en düşük sonuçları LDA sınıflandırıcısı vermiştir.

**Tablo 3.6** Tüm kuvvet seviyeleri bir arada ve ayrı ayrı olarak kullanıcı-bağımsız sınıflandırma sonuçları.

Kuvvet	Yöntem	k-NN	LDA	SVM
Düşük Kuvvet	<b>ÇDGKA</b>	<b>94,2</b>	<b>69,3</b>	<b>82,81</b>
	Ham	92,9	51,5	66,5
Orta Kuvvet	<b>ÇDGKA</b>	<b>95,7</b>	<b>68,1</b>	<b>81,9</b>
	Ham	94,7	47,3	62,1
Yüksek Kuvvet	<b>ÇDGKA</b>	<b>94,8</b>	<b>62,2</b>	<b>77,9</b>
	Ham	92,8	48,6	61,0
Tüm Kuvvetler	<b>ÇDGKA</b>	<b>93,4</b>	<b>52,6</b>	<b>65,4</b>
	Ham	91,3	37,4	52,9

Şekil 3.18, Şekil 3.19, Şekil 3.20 ve Şekil 3.21’de sırasıyla üç kuvvet seviyesi ve karışık kuvvetler için  $k$ -NN sınıflandırıcısına ait karışıklık matrisleri gösterilmiştir. Her bir el hareketinin ayırt edilebilme performansı matrislerde ayrı ayrı gösterilmiştir.

**Karışıklık Matrisi**

Tahmin	BP	773 15.9%	2 0.0%	10 0.2%	11 0.2%	22 0.5%	2 0.0%	94.3% 5.7%
	KK	3 0.1%	782 16.1%	10 0.2%	8 0.2%	10 0.2%	4 0.1%	95.7% 4.3%
	KÜK	7 0.1%	2 0.0%	754 15.5%	33 0.7%	11 0.2%	4 0.1%	93.0% 7.0%
	TK	7 0.1%	11 0.2%	23 0.5%	729 15.0%	21 0.4%	5 0.1%	91.6% 8.4%
	ÇK	17 0.3%	6 0.1%	7 0.1%	26 0.5%	745 15.3%	1 0.0%	92.9% 7.1%
	İP	3 0.1%	7 0.1%	6 0.1%	3 0.1%	1 0.0%	794 16.3%	97.5% 2.5%
		95.4% 4.6%	96.5% 3.5%	93.1% 6.9%	90.0% 10.0%	92.0% 8.0%	98.0% 2.0%	94.2% 5.8%
	BP	KK	KÜK	TK	ÇK	İP		
	Gerçek							

Şekil 3.18  $k$ -NN ile ÇDGKA tabanlı özneliklerin kullanıcı-bağımsız düşük kuvvet seviyesi sınıflandırma sonuçlarına ait karışıklık matrisi.

**Karışıklık Matrisi**

Tahmin	BP	792 16.3%	4 0.1%	1 0.0%	1 0.0%	16 0.3%	1 0.0%	97.2% 2.8%
	KK	5 0.1%	779 16.0%	8 0.2%	3 0.1%	5 0.1%	1 0.0%	97.3% 2.7%
	KÜK	2 0.0%	15 0.3%	765 15.7%	30 0.6%	16 0.3%	5 0.1%	91.8% 8.2%
	TK	0 0.0%	3 0.1%	22 0.5%	760 15.6%	7 0.1%	13 0.3%	94.4% 5.6%
	ÇK	11 0.2%	3 0.1%	8 0.2%	6 0.1%	764 15.7%	0 0.0%	96.5% 3.5%
	İP	0 0.0%	6 0.1%	6 0.1%	10 0.2%	2 0.0%	790 16.3%	97.1% 2.9%
		97.8% 2.2%	96.2% 3.8%	94.4% 5.6%	93.8% 6.2%	94.3% 5.7%	97.5% 2.5%	95.7% 4.3%
	BP	KK	KÜK	TK	ÇK	İP		
	Gerçek							

Şekil 3.19  $k$ -NN ile ÇDGKA tabanlı kullanıcı-bağımsız orta kuvvet seviyesi sınıflandırma sonuçlarına ait karışıklık matrisi.

Tahmin \ Gerçek	BP	KK	KÜK	TK	ÇK	İP	
BP	773 15.9%	4 0.1%	11 0.2%	14 0.3%	14 0.3%	1 0.0%	94.6% 5.4%
KK	3 0.1%	764 15.7%	10 0.2%	1 0.0%	13 0.3%	2 0.0%	96.3% 3.7%
KÜK	6 0.1%	22 0.5%	765 15.7%	20 0.4%	15 0.3%	13 0.3%	91.0% 9.0%
TK	11 0.2%	6 0.1%	12 0.2%	759 15.6%	2 0.0%	14 0.3%	94.4% 5.6%
ÇK	16 0.3%	10 0.2%	7 0.1%	3 0.1%	766 15.8%	0 0.0%	95.5% 4.5%
İP	1 0.0%	4 0.1%	5 0.1%	13 0.3%	0 0.0%	780 16.0%	97.1% 2.9%
	95.4% 4.6%	94.3% 5.7%	94.4% 5.6%	93.7% 6.3%	94.6% 5.4%	96.3% 3.7%	94.8% 5.2%


Şekil 3.20  $k$ -NN ile ÇDGKA tabanlı kullanıcı bağımsız yüksek kuvvet seviyesi sınıflandırma sonuçlarına ait karışıklık matrisi.

Tahmin \ Gerçek	BP	KK	KÜK	TK	ÇK	İP	
BP	2289 15.7%	12 0.1%	31 0.2%	46 0.3%	63 0.4%	9 0.1%	93.4% 6.6%
KK	11 0.1%	2286 15.7%	34 0.2%	21 0.1%	33 0.2%	14 0.1%	95.3% 4.7%
KÜK	28 0.2%	44 0.3%	2256 15.5%	92 0.6%	43 0.3%	25 0.2%	90.7% 9.3%
TK	37 0.3%	35 0.2%	65 0.4%	2203 15.1%	39 0.3%	37 0.3%	91.2% 8.8%
ÇK	58 0.4%	25 0.2%	24 0.2%	40 0.3%	2246 15.4%	2 0.0%	93.8% 6.2%
İP	7 0.0%	28 0.2%	20 0.1%	28 0.2%	6 0.0%	2343 16.1%	96.3% 3.7%
	94.2% 5.8%	94.1% 5.9%	92.8% 7.2%	90.7% 9.3%	92.4% 7.6%	96.4% 3.6%	93.4% 6.6%

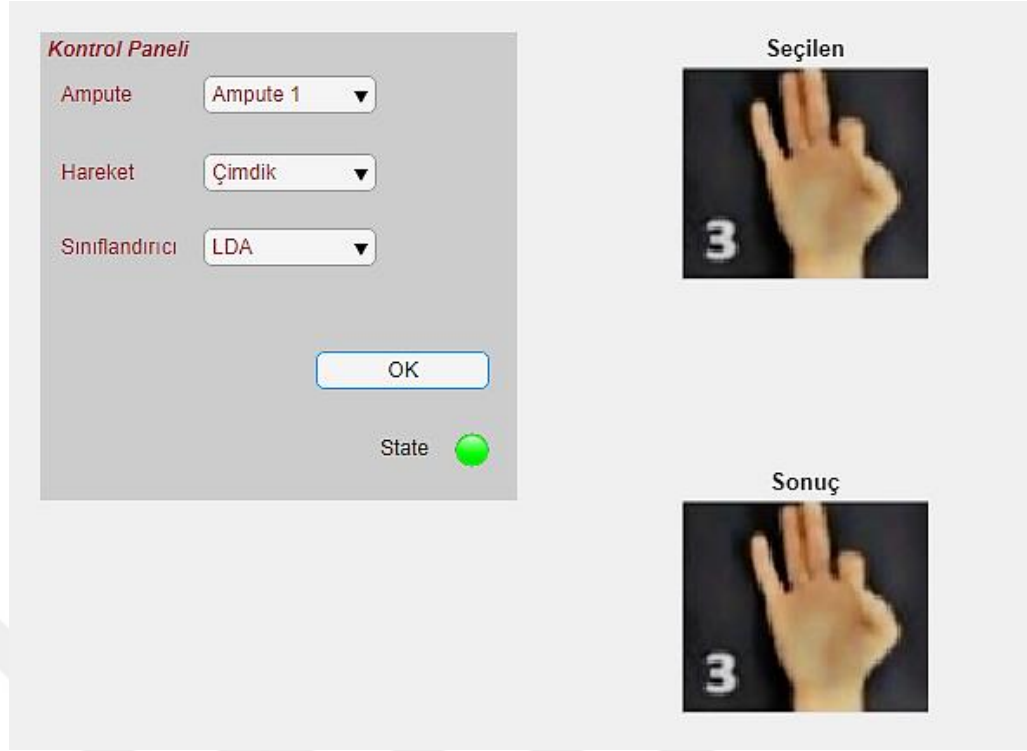
Şekil 3.21  $k$ -NN ile ÇDGKA tabanlı kullanıcı bağımsız tüm kuvvet seviyeleri bir arada sınıflandırma sonuçlarına ait karışıklık matrisi.

### 3.4 Protez El Kontrolü ve Uygulaması

Veri setinde yer alan sEMG sinyallerinin önerilen yöntem ile bulunan özniteliklerinin kullanılmasıyla oluşturulan sınıflandırıcı modelleri, prototip olarak üretilen bir protez el üzerinde test edilmiştir. Protez el parçalarının imalatı 3B yazıcı ile PLA malzeme kullanılarak 15 saatte gerçekleştirilmiştir. Üretilen protez el Şekil 3.22’de gösterilmiştir. Protez elin kontrolünün gerçekleştirilmesi için  $k$ -NN ve ÇDGKA tabanlı özniteliklerle eğitilmiş LDA ve SVM sınıflandırıcıları kullanılmıştır. Veri setinde yer alan sEMG sinyallerinin temsil ettiği altı el ve parmak hareketinin gerçekleştirilmesi için beş adet servo motor kullanılmıştır. Bu motorların kontrolü sınıflandırıcının verdiği karara göre yapılmıştır. Şekil 3.23’te prototip protez elin kontrolünün gerçekleştirilmesi için oluşturulan arayüz gösterilmiştir. Bu arayüz aracılığıyla veri setinde yer alan herhangi bir harekete ait özniteliklerin çıkarılıp sınıflandırıcılarda test edilmesi ve sonuca göre protez elin motorlarının kontrolü gerçekleştirilmiştir.




Şekil 3.22 Üretilen prototip protez el (a) KÜK hareketi (b) ÇK Hareketi



**Şekil 3.23** Prototip protez el kontrolü için Matlab arayüzü

Şekil 3.24'te prototip protez elin kontrol sürecine ilişkin blok diyagram gösterilmiştir. Örnek sinyaller, bilgisayar ortamında ÇDGKA yöntemi ile analiz edilmiştir.



**Şekil 3.24** Protez Elin Kontrol Süreci

Bu işlem sonucunda elde edilen öznitelikler ile sınıflandırıcılar eğitilmiştir. Eğitilen bu modeller protez elin kontrolünde karar verme konumunda bulunmaktadır. Bu yüzden sınıflandırıcının eğitimi kontrol işleminden önce gerçekleştirilip bir model oluşturulur. Bu model ile yeni veriler test edilerek sınıflandırıcı sonuçlarına göre Arduino mikrodenetleyici kartı vasıtasıyla servo motorlar sürülür ve protez elin istenilen hareketi yapması sağlanır.

#### 4. SONUÇLAR

Bu çalışma kapsamında, EMG sinyallerini işlemek ve özelliklerini tespit etmek için kullanılan ÇDGKA yöntemi ile elde edilen özniteliklerin el ve parmak hareketlerini ayırt etme performansı, ham sinyal tabanlı öznitelikler ile karşılaştırılmıştır. Bu karşılaştırmanın sonucunda elde edilen sonuçlar, protez ellerin kontrolüne yönelik EMG sinyallerini ayırtmak ve analiz etmek için yeni bir yöntemin geliştirilmesine olanak sağlamıştır.

EMG sinyallerinin çok kanallı olarak analizini gerçekleştirmek ve farklı kuvvet seviyelerindeki el hareketlerine ait sinyalleri de kullanarak el ve parmak hareketlerini ayırt edebilmek için, özniteliklerin geliştirilmesi amaçlanmıştır. Bu sebeple sinyaller ÇDGKA yöntemi ile özgül kip fonksiyonlarına ayrıştırılarak, sinyalin yerel ölçekte daha detaylı bir gözlemi yapmak mümkün kılınmıştır. Ayrıca farklı salınım modları arasında meydana gelebilecek mod karışımından kaçınılması ve kanallar arası mod hizalamasının düzgün bir şekilde gerçekleştirilmesi, ÇDGKA yönteminin çok kanallı sEMG sinyallerinin analizinde elverişli bir şekilde kullanılabilmesini sağlamıştır. ÇDGKA yönteminin, sinyalin uzunluğuna göre farklı sayıda ÖKF çıkarması sebebiyle, sinyalin lokal bilgilerini kaybetmeden uygun uzunluktaki sinyali seçmek için ampirik olarak yeni bir metod geliştirilmiştir. Bunun neticesinde sEMG sinyallerinin analiziyle elde edilen ÖKF'lerin her birinden öznitelikler çıkarılmış ve sınıflandırma performanslarına göre sinyalin yapısını en iyi temsil eden ÖKF bileşenleri tespit edilmiştir. Bu şekilde genel bir şablon oluşturularak, ÇDGKA yönteminin gerçek zamanlı uygulamalarda, en uygun ÖKF'lerin belirlenmesine yönelik işlem yoğunluğundan kaçınılması amaçlanmıştır.

Çalışma kapsamında etkin değer, sıfır geçiş sayısı, varyans ve dalga form uzunluğu öznitelikleri kullanılmıştır. Gerçek zamanlı uygulamalara yönelik yapılan çalışmalarda, ÖKF'lerden elde edilen sıfır geçiş sayısı özneliğinin, hareketleri ayırt etme performansını düşürmesinden dolayı ve hesaplama yükünü azaltmak adına öznitelik sayısı üçe düşürülmüştür.

Sonuç olarak, ÇDGKA tabanlı özniteliklerin ham sinyal tabanlı özniteliklere göre kullanıcı-bağımlı için %1, kullanıcı-bağımsız için %15 - %20, kullanıcı ve kuvvet bağımsız için %15'e kadar üstünlük sağladığı belirlenmiştir.

Uygun el protezi üretilerek, kayıtlı EMG sinyallerden hangi el hareketin yapılmak istendiği tespit edilerek protezin bilgisayar destekli kontrolü gerçekleştirilmiştir.

Bu çalışmada ÇDGKA yöntemi tabanlı özniteliklerin işlevselliğinin gösterilmesi amaçlanmıştır. Bu özniteliklerin, özellikle kullanıcı-bağımsız ve kuvvetten-bağımsız sınıflandırma işlemlerinde, ham sinyal tabanlı özniteliklere sağladığı üstünlük açıkça gösterilmiştir. Fakat bu üstünlüğe rağmen ÇDGKA yöntemi tabanlı öznitelik çıkarma yönteminin, halen geliştirilmeye ihtiyacı olduğu görülmektedir. Bunun yanında gerçek zamanlı uygulamalara yönelik hesaplama yükünün azaltılması için de çalışmalara ihtiyaç vardır. Kullanıcıdan ve kuvvetten bağımsız genel bir yönteminin başarılı bir şekilde geliştirilmesi ile akıllı el protezlerinin güvenilirliğinin artması ve geleceğe yönelik olarak, bu protezlerin uzuv kayıplarının eksikliğini temin etmesi umulmaktadır.

## KAYNAKLAR

- [1] **Bright, D., Nair, A., Salvekar, D., & Bhisikar, S.** (2016). EEG-based brain controlled prosthetic arm. In *Conference on Advances in Signal Processing, CASP 2016*.
- [2] **Barea, R., Boquete, L., Mazo, M., Lopez, E., & Bergasa, L. M.** (2000). EOG guidance of a wheelchair using neural networks. *Proceedings 15th International Conference on Pattern Recognition. ICPR-2000*.
- [3] **Al-Rousan, M., & Assaleh, K.** (2011). A wavelet- and neural network-based voice system for a smart wheelchair control. *Journal of the Franklin Institute*, 348(1), 90-100.
- [4] **Pylatiuk, C., Kargov, A., & Schulz, S.** (2006). Design and evaluation of a low-cost force feedback system for myoelectric prosthetic hands. In *Journal of Prosthetics and Orthotics*, 18.2 (2006): 57-61.
- [5] **Côtéallard, U., Nougrou, F., Fall, C. L., Gigu'ere, P., Gosselin, C., Laviolette, F., & Gosselin, B.** (2016). A Convolutional Neural Network for robotic arm guidance using sEMG based frequency-features. *IEEE International Conference on Intelligent Robots and Systems, 2016-Novem*, 2464–2470.
- [6] **Moon, I., Lee, M., Chu, J., & Mun, M.** (2005). Wearable EMG-based HCI for electric-powered wheelchair users with motor disabilities. In *proceedings of the 2005 IEEE International Conference on Robotics and Automation* (pp. 2649-2654).
- [7] **Hakonen, M., Piitulainen, H., & Visala, A.** (2015). Current state of digital signal processing in myoelectric interfaces and related applications. *Biomedical Signal Processing and Control*, 18, 334–359.
- [8] **Bock, O.** (2006). Myoelectric Control Of Powered Upper- Limb Prostheses.
- [9] **Stashuk, D.** (2001). EMG signal decomposition: How can it be accomplished and used. *Journal of Electromyography and Kinesiology*, 11(3), 151–173..
- [10] **Hargrove, L. J., Englehart, K., & Hudgins, B.** (2007). A comparison of surface and intramuscular myoelectric signal classification. *IEEE Transactions on Biomedical Engineering*, 54(5), 847-853.
- [11] **Englehart, K., Hudgins, B., Parker, P. A., & Member, S.** (2001). A Wavelet-Based Continuous Classification Scheme for Multifunction Myoelectric Control, 48(3), 302–311.
- [12] **Veer, K., & Sharma, T.** (2016). A novel feature extraction for robust EMG pattern recognition. *Journal of Medical Engineering and Technology*, 40(4), 149–154.



- [13] **Reaz, M. B. I., Hussain, M. S., & Mohd-Yasin, F.** (2006). Techniques of EMG signal analysis: Detection, processing, classification and applications. *Biological Procedures Online*, 8(1), 11–35.
- [14] **Altamirano, A. A.** (2017). EMG Pattern Prediction for Upper Limb Movements Based on Wavelet and Hilbert-Huang Transform. (Doctoral dissertation, Université de Lorraine; Instituto Politécnico Nacional (México)).
- [15] **Wojtczak, P., Amaral, T. G., Dias, O. P., Wolczowski, A., & Kurzynski, M.** (2009). Hand movement recognition based on biosignal analysis. *Engineering Applications of Artificial Intelligence*, 22(4-5), 608-615.
- [16] **Internationale, C., Tenore, F., Ramos, A., Fahmy, A., Acharya, S., Etienne-cummings, R., & Thakor, N. V.** (2007). Towards the Control of Individual Fingers of a Prosthetic Hand Using Surface EMG Signals, 6145–6148.
- [17] **Jiang, M., Wang, R., Wang, J., & Jin, D.** (2005). A method of recognizing finger motion using wavelet transform of surface EMG signal, *IEEE Engineering in Medicine and Biology 27th Annual Conference* (pp. 2672-2674). IEEE.
- [18] **Lucas, M. F., Gaufriau, A., Pascual, S., Doncarli, C., & Farina, D.** (2008). Multi-channel surface EMG classification using support vector machines and signal-based wavelet optimization. *Biomedical Signal Processing and Control*, 3(2), 169–174.
- [19] **Naik, G.** (2014). *Applications, Challenges, and Advancements in Electromyography Signal Processing*. IGI Global.
- [20] **Sapsanis, C., Georgoulas, G., Tzes, A., & Lymberopoulos, D.** (2013). Improving EMG based Classification of basic hand movements using EMD. *2013 35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, 5754–5757.
- [21] **Andrade, A. O., Nasuto, S., Kyberd, P., Sweeney-Reed, C. M., & Van Kanijn, F. R.** (2006). EMG signal filtering based on Empirical Mode Decomposition. *Biomedical Signal Processing and Control*, 1(1), 44-55.
- [22] **Zhang, Y., Xu, P., Li, P., Duan, K., Wen, Y., Yang, Q., ... Yao, D.** (2017). Noise-assisted multivariate empirical mode decomposition for multichannel EMG signals. *BioMedical Engineering Online*, 16(1), 1–17.
- [23] **Rilling, G., Flandrin, P., Goncalves, P., & Lilly, J. M.** (2007). Bivariate Empirical Mode Decomposition. *Signal Processing Letters, IEEE*, 14(12), 936–939.
- [24] **Rehman, N., & Mandic, D. P.** (2009). Empirical mode decomposition for trivariate signals. *IEEE Transactions on signal processing*, 58(3), 1059-1068.
- [25] **Rehman, N., & Mandic, D. P.** (2010b). Multivariate empirical mode decomposition. *Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 466(2117), 1291-1302.
- [26] **Merletti Roberto, Farina, D.** (2015). *Surface Electromyography: Physiology, Engineering and applications*. John Wiley & Sons.

- [27] **Yazgan, E.** (2004). *Tip Elektroniği İTÜ*.
- [28] **Emil Nina.** (n.d.). Membrane Potentials and Action Potentials. Retrieved from <https://www.slideshare.net/hamzehbattikhi/general-physiology-action-potential>.
- [29] **David, P., & Barbara, S.** (2013). *Electromyography and Neuromuscular Disorders E-Book: Clinical-Electrophysiologic Correlations (Expert Consult-Online and Print)*. Elsevier Health Sciences.
- [30] **Fırmınoğulları, M., yavuz, B., & Koç, F.** (2015). Ön Boynuz Tutulumuyla Giden Hastalıklar. *Arşiv Kaynak Tarama Dergisi*, 25(3), 269-303.
- [31] **Hussein Ali, A.** (2013). An Investigation of Electromyographic (EMG) Control of Dextrous Hand Prostheses for Transradial Amputees. *2014 Wireless Telecommunications Symposium*, 1–276.
- [32] **De Luca, C. J., Adam, A., Wotiz, R., Gilmore, L. D., & Nawab, S. H.** (2006). Decomposition of surface EMG signals. *Journal of neurophysiology*, 96(3), 1646-1657.
- [33] **Karpati, G., Hilton-jones, D., Bushby, K., Griggs, R. C., & Floeter, M. K.** (2010). *Disorders of voluntary muscle*. Cambridge University Press.
- [34] **Amon, C.** (2013). Design and Evaluation of an EMG-based Recording and Detection System, (Project Thesis, University of Music and Performing Arts Graz).
- [35] **Naik, G. R., Kumar, D. K., & Palaniswami, M.** (2008). Multi run ICA and surface EMG based signal processing system for recognizing hand gestures. *8th IEEE International Conference on Computer and Information Technology, 2008*, 700–705.
- [36] **Merletti, R., Botter, A., Troiano, A., Merlo, E., & Minetto, M. A.** (2009). Technology and instrumentation for detection and conditioning of the surface electromyographic signal: State of the art. *Clinical Biomechanics*, 24(2), 122–134.
- [37] **Jamal, M. Z.** (2012). Signal Acquisition Using Surface EMG and Circuit Design Considerations for Robotic Prosthesis. *Computational Intelligence in Electromyography Analysis-A Perspective on Current Applications and Future Challengers*, 427–445.
- [38] **Luca, C. J. De.** (2002). Surface Electromyography : Detection and Recording. *DelSys Incorporated*, 10(2), 1–10.
- [39] **ten Kate, J., Smit, G., & Breedveld, P.** (2017). 3D-printed upper limb prostheses: a review. *Disability and Rehabilitation: Assistive Technology*, 12(3), 300–314.
- [40] **Hornick, J.** (2017). 3D printing in Healthcare. *Journal of 3D Printing in Medicine*, 1(1), 13–17.
- [41] **Fougner, A., Stavadahl, O., Kyberd, P. J., Losier, Y. G., & Parker, P. A.** (2012). Control of upper limb prostheses: Terminology and proportional myoelectric control review. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 20(5), 663–677.

- [42] **Openbionics | Ada Hand V1.1** (t.y). Erişim: 9 Şubat 2019 <https://openbionicslabs.com/obtutorials/ada-v1-assembly>.
- [43] **Al-Timemy, A. H., Khushaba, R. N., Bugmann, G., & Escudero, J.** (2016). Improving the Performance Against Force Variation of EMG Controlled Multifunctional Upper-Limb Prostheses for Transradial Amputees. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 24(6), 650–661.
- [44] **Balbinot, A., & Favieiro, G.** (2013). A neuro-fuzzy system for characterization of arm movements. *Sensors*, 13(2), 2613-2630.
- [45] **De Luca, C. J., Donald Gilmore, L., Kuznetsov, M., & Roy, S. H.** (2010). Filtering the surface EMG signal: Movement artifact and baseline noise contamination. *Journal of Biomechanics*, 43(8), 1573–1579.
- [46] **Myers, L. J., Lowery, M., O'Malley, M., Vaughan, C. L., Heneghan, C., St. Clair Gibson, A., ... Sreenivasan, R.** (2003). Rectification and non-linear pre-processing of EMG signals for cortico-muscular analysis. *Journal of Neuroscience Methods*, 124(2), 157–165.
- [47] **Huang, N. E., Shen, Z., Long, S. R., Wu, M. C., Shih, Zheng.** (1998). The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis. *Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 454(1971), 903–995.
- [48] **Huang, Norden E., & Shen, S. S. P.** (2014). Hilbert Huang Transform and Its Applications. In *Interdisciplinary Mathematical Sciences* (Vol. 16, p. 400).
- [49] **Rehman, N., & Mandic, D. P.** (2010a). Multivariate empirical mode decomposition. *Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 466(2117), 1291–1302.
- [50] **Sapsanis, C., Georgoulas, G., Tzes, A., & Member, S.** (2013). A. EMG Data Collection, 716–722.
- [51] **Ruiz-Olaya, A. F., & Lopez-Delis, A.** (2013). Surface EMG signal analysis based on the empirical mode decomposition for human-robot interaction. In *Symposium of Signals, Images and Artificial Vision - 2013, STSIVA 2013*.
- [52] **Andrews, A. J.** (2008). Finger Movement Classification using Forearm EMG. *Project Report (Queen's University)*.
- [53] **Tharwat, A., Gaber, T., Ibrahim, A., & Hassanien, A. E.** (2017). Linear discriminant analysis: A detailed tutorial. *AI Communications*, 30(2), 169–190.

## EKLER

### CDGKA Tabanlı Öznitelik Çıkarma

```

%* ÇDGKA Tabanlı Öznitelik Çıkarma İşlemi *
%* Rehman ve Mandic ÇDGKA algoritması kullanılmıştır. *
%-----*
%                               Fatih ONAY *
%-----*

str_participants={'A1','A2','A3','A4','A5','A6','A7','A8','A9'};
str_position={'Ball','Ind','LRMI','Th','ThInd','ThIndMid'};
str_force={'low','med','high'};
str_trial={'t1','t2','t3','t4','t5'};

%%% Cell Boyutları
ff=length(str_participants);
ii=length(str_position);
jj=length(str_force);
kk=length(str_trial);

epoch=5000; % Analiz edilen toplam sinyal uzunluğu
class={}; okf_feature={}; % Öznitelik ve Sınıf
winsize = 512; % Pencere Boyutunun Belirlenmesi
wininc = winsize/2; % Örtüşme oranının ayarlanması
datawin = rectwin(winsize); % Pencerenin oluşturulması
no=6; % IMF Sayısının Seçimi
hh=0;

for j=1:3 % kuvvet seviyesi

for f=1:9 % katılımcının seçimi

for i=1:6 % hareket seçimi

for k=1:5 % trial seçimi

FFF=load
(strcat(str_participants{f},'_',str_position{i},'_',str_force{j},'_',
,str_trial{k}));
signal1=FFF.(matlab.lang.makeValidName(str_trial{k})); % Veri
setinden sinyalin alınması
[b,a] = butter(3,[10 600]/1000); % Filtreleme
ss= filter(b,a,signal1)';
signalf=ss(1:8,800:800+epoch-1)';

datasize = size(signalf,1); % Sinyal uzunluğu
Nsignals = size(signalf,2); % Kanal Sayısı
numwin = floor((datasize - winsize)/wininc)+1; % Pencere Sayısının
Hesaplanması

```

```

st=1; en=winsize;

for ij=1:numwin % Tüm pencerelerin kullanılması

    hh=hh+1;
    curwin = signalf(st:en,:).*repmat(datawin,1,Nsignals);
    %Sinyalin pencerelenmesi

    IMFs=memd(curwin,16); % ÇDGKA yönteminin uygulanması
    okf=reshape(IMFs(:,1:no,:),8*no,winsize)'; % ÖKF'lerin
düzenlenmesi

    %%%% Öznitelik Çıkarma İşlemi

    %zc_okf=getzcfat(okf,0);
    var_okf=var(okf);
    rms_okf=rms(okf);
    WL_okf=getwlfeat(okf);

    st = st + wininc;
    en = en + wininc;

    okf_feature(hh,:)= [WL_okf,rms_okf,var_okf];
    class{hh}=str_position{i};
end
end
end
end
end

```

## ÖZGEÇMİŞ

**Ad-Soyad** : Fatih ONAY  
**Doğum Tarihi ve Yeri** : 09.02.1993 / İzmir  
**E-posta** : fatih.onay@btu.edu.tr



### ÖĞRENİM DURUMU:

- **Lisans** : 2016, Erciyes Üniversitesi, Mühendislik Fakültesi, Mekatronik Mühendisliği
- **Lisans** : 2016, Erciyes Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği
- **Yüksek Lisans** : 2019, Bursa Teknik Üniversitesi, Mekatronik Anabilim Dalı

### MESLEKİ DENEYİM VE ÖDÜLLER:

- Araştırma Görevlisi (Bursa Teknik Üniversitesi 2017-2019)

### TEZDEN TÜRETİLEN ESERLER, SUNUMLAR VE PATENTLER:

- Multivariate empirical mode decomposition based EMG signal analysis for smart prosthesis / 26th Signal Processing and Communications Applications Conference (SIU) 2018, İzmir, Türkiye

### DİĞER ESERLER, SUNUMLAR VE PATENTLER:

- Empirical Mode Decomposition Based Feature Extraction for Intelligent Emotion Recognition International Conference on Engineering Technologies, 2017, Konya, Türkiye

