



## Çok Fonksiyonlu Protez El Hareketleri İçin Uzman Sistem Tasarımı

### *Design of Expert Systems for Movements of Multi-Function Prosthetic Hand*

Yalçın İşler<sup>1,2,\*</sup> , Özlem İşler<sup>2</sup> 

<sup>1</sup>İzmir Katip Çelebi Üniversitesi, Mühendislik ve Mimarlık Fakültesi, Biyomedikal Mühendisliği Bölümü, Çiğli, İzmir, Türkiye

<sup>2</sup>İslerya Medikal ve Bilişim Teknolojileri, Bornova, İzmir, Türkiye

### Öz

Kısmen felçli hastalarda ve el, kol yada bacak kaybına uğramış bireylerde eksik uzuvlarının yerine kullanılmak üzere protez tasarımları bulunmaktadır. Günümüzde mevcut olan protez eller temel birkaç fonksiyonel özellik sunmasına rağmen, gündelik hayatta bir elin sahip olduğu özelliklere kıyasla çok kısıtlı ve yetersizdir. Son zamanlarda EMG sinyalleri insan-makine arabirimleri tasarımlarının vazgeçilmez unsurlarından biri haline gelmiştir. Protezlerin gerçek bir uzvuva benzemeleri için EMG sinyallerinin kullanımı bir seçenek olacaktır. Örüntü tanıma tabanlı el kontrol algoritmaları, özürü kişiler için yapay el üretmek amacı ile kullanılmaktadır. Bu çalışmada; önkol kaslarındaki EMG (ElektroMiyoGrafı) işaretlerini kullanarak, çok işlevli (dört önkol hareketi: el serbest, el sıkılı, kasılma ve gevşeme) el kontrolü için dört sınıflandırıcı (k-yakın komşuluk, MLP, RBF ve SVM) incelenmiştir. Sınıflandırıcıların eğitim ve testinde, EMG işareti tabanlı zaman alanı istatistiksel ölçümler kullanılmıştır. Sonuç olarak, SVM sınıflandırıcısı ile en yüksek sınıflandırıcı başarıyı elde edilmiştir.

**Anahtar Kelimeler:** Yüze EMG, Protez el, Uzman sistemler.

### Abstract

There are prosthetic designs that can be used for patients who are partially paralyzed or are amputated of hand, arm or leg to use instead of their lack of limbs. Although recent commercial prosthetic hands provide some functional properties, they are so limited and inefficient when they are compared with original hand of everyday life. Recently, EMG signals have become an indispensable part in human-machine interface designs. Using EMG is an option to establish similarity between prosthesis and original extremite. Pattern recognition based prosthesis hand control algorithms have largely been used to produce artificial hand for handicapped people. This paper investigated (k-nearest neighbor, MLP, RBF and SVM) for multi-functional (four forearm movements: hand open, hand wrist, flexion and extension) hand control by using EMG signals from forearm muscles. In training and testing of classifiers, EMG signal based statistical features were used. As a result, SVM classifier has shown maximum accuracy for all subjects.


**Keywords:** EMG, Prosthetic hand, Expert systems


### 1. Giriş

EMG kasılma esnasında kaslarda oluşan elektriksel potansiyelerin izlenmesi ve kayıt edilmesi yöntemidir. Tıbbi açıdan, sinir ve kasla ilgili rahatsızlıklarda tanı koymak için ve sinir iletim çalışmalarında da EMG'den yararlanılmaktadır. Sağlıklı kişilerde görülen EMG kayıtlarıyla kıyaslanarak normal olmadığı görülen sinyaller kas ve sinir sistemi problemleri tespit edilebilmektedir. Bu tür sorunlar genellikle istem dışı kasılmalar ve spazmlar olarak görülmektedir.

EMG ile elektriksel aktiviteyi ölçebilmek için elektrotlar kullanılır. Girişimsel EMG ölçümleri kas dokusunun içine yerleştirilen elektrotlar aracılığıyla elde edilmektedir. Girişimsel EMG ölçümleri çok doğru sonuçlar vermektedir. Bunun sebebi kasların içindeki hedefe yönelik potansiyelleri hedef alması, vücut-elektrot temasında oluşan etkilere maruz kalmaması ve kayıt alınan kaslar ile hareketi hedeflenen kasların doğrudan komşu olması olarak sayılabilir (Raez et al. 2006). Bununla birlikte girişimsel elektrotlar hastalar için rahatsız edici olmakta ve az da olsa bulaşma riskine sahip bulunmaktadır. Dahası girişimsel olan elektrotların bir kısmı hastaya ameliyatla takılmaktadır. Diğer yandan, vücut dışı elektrotlar derinin üstüne yapıştırılan yüze elektrotlarıdır ve derinin altındaki kas grubunun elektriksel aktivitesini

\*Sorumlu yazarın e-posta adresi: [islerya@yahoo.com](mailto:islerya@yahoo.com)

Yalçın İşler  [orcid.org/0000-0002-2150-4756](https://orcid.org/0000-0002-2150-4756)

Özlem İşler  [orcid.org/0000-0002-0949-2748](https://orcid.org/0000-0002-0949-2748)

algılamak için kullanılır. Yüzey elektrotlarının dezavantajı ise elektrotun yerleştirildiği derinin altındaki kas grubunun elektrik sinyalini topladığı için tek kasın elektriksel sinyalini kayıt etmeyi sağlayan girişimsel elektrotlar doğru ölçüm veremiyor olmalarıdır. Böylece elde edilen sinyalin içinde istenmeyen gürültü ve girişimler karışmaktadır (Raez et al. 2006).

Literatürde kastan alınan sinyaller kullanılarak protez tasarımı temelleri 1945 yıllarına dayanmaktadır. Geçmişte yapılan çalışmaların sinyal işleme ve temel örüntü tanıma teknikleri alanında iken, günümüzde elektronik devrelerin boyutlarının küçültülmesi, mekanik yapının hafifletilmesi, protezin gerçek uzuv görüntüsüne ve işlevlerine yaklaştırılması ve enerji tüketiminin azaltılması alanına kaydığı görülmektedir (İsler 2017). Bu nedenle çalışmada günümüz modern örüntü tanıma teknikleri kullanılarak daha gerçekçi protez el hareketlerinin yapılabilmesi hedeflenmiştir.

Yakın bir çalışmada sinyal işleme teknikleri kullanılmadan protez el parmaklarının hareketi gerçekleştirilebilmiştir. Bu tasarımda nesnelere tutabilen vücut dışı protez sağlanmış olsa da, pasif bir cihaz olması en büyük hatasıdır. Cihazın parmakları bir nesneyle temas etmesi halinde sensörler esnemektedir. Sinyal işleme teknikleri kullanılmadığından hatalı sinyal gelen sensörler nedeniyle sıklıkla problem yaşanmakta ve yeterince güçle nesnelere kavranması sağlanamamaktadır (Dechev et al. 2001).

Başka bir tasarımda, girişimsel yöntemlerle elde edilen EMG sinyalleri kullanılmaktadır (Kamavuako et al. 2009). Bu çalışma ile diğer tasarımlara göre daha yüksek güçle nesnelere kavranması sağlanabilmiştir. Bununla birlikte, tasarım girişimsel olduğu için hastaya uygulanması aşamasında çok sorun yaşanmaktadır.

Matrone ve arkadaşları tarafından gerçekleştirilen başka bir tasarımda ise, protez elin parmak hareketleri temel bileşen analizi yöntemiyle sinyal işleme yapılmıştır (Matrone et al. 2010). Protez elin mekanik parmakları tarafından nesnelere kavranması başarılı bir şekilde bir hasta üzerinde gerçekleştirilebilmiş olmasına rağmen, çoğu diğer hastada aynı tasarımın kullanılmaması ile çalışma sonuçlanmıştır. Bu sorunlar hastalar arasındaki farklılıkların giderilememesi, protezin kalibre edilmesinde yaşanan güçlükler ve elektrot konumlarının seçimi şeklinde ortaya çıkmıştır.

Graupe ve Cline öznitelik olarak EMG sinyalinin öz bağlantım katsayılarını kullanarak 85% başarıyla ilk sınıflandırmayı yapan grup olarak anılır (Graupe and Cline 1975).

Basmajian ve De Luca ise sinyalin orta değer ve ortalama frekans değerlerini sinyal tanımlamada güvenilir bilgiler olduğunu belirtmişlerdir (Basmajian and Luca 1985). Zardoshti et al. (1995) EMG sinyallerinin mutlak değerinin integralini, varyans değerini ve sıfır kesişi sayısını öznitelik değeri olarak kullanıp K-en yakın komşu sınıflandırma metodunu kullanmıştır (Zardoshti et al. 1995). Englehart ve grubu EMG sinyalini hem zaman hem de frekans alanında incelemek amacıyla kısa zamanlı Fourier dönüşümü, dalgacık dönüşümü ve dalgacık paket dönüşümü metodlarını ayrı ayrı uygulamış ve dalgacık metodu ile biceps ve triceps kasları üzerinden 93.75% başarı elde etmiştir (Scheme et al. 2011, Englehart et al. 2001). Nishikawa ve grubu Fourier dönüşüm metodunu kullanarak sinyalin ortalama mutlak değerini öznitelik olarak belirlemişlerdir (Nishikawa et al. 2002). Boostani ve grubu dalgacık metodu sonucu elde edilen kastayların enerjilerini öznitelik olarak belirlerken (Boostani and Moradi 2003). Kilby ve Hosseini ise ayrı dalgacık metodunun farklı dalgacık ailelerini ve dalgacık paket dönüşümü metodlarını öznitelik metodları olarak kullanmışlardır (Kilby and Hosseini 2004). Liu ve grubu Coiflet ana dalgacığını kullanarak hareketlerin sınıflandırılması üzerine çalışmıştır (Haihuna et al. 2005). Zheng ve grubu optimum öznitelik vektörlerini bulabilmek için optimizasyon tekniklerinin uygulanmasının gerekli olduğunu öne sürmüştür (Zheng and He 2005). Arieta ve grubu EMG sinyalinin hızlı Fourier dönüşümü sonucu elde ettiği ilk sekiz değeri öznitelik vektörü olarak belirlerken (Arieta et al. 2006), Zhao ve grubu mutlak ortalama değeri, oranı ve dördüncü dereceden özbağlanımlı model değerlerini sinyal özniteligi olarak belirlemişlerdir (Zhao et al. 2007).


## 2. Gereç ve Yöntem

### 2.1. Veri


BIOPAC MP36 sistemi kullanılarak EMG kayıtları alınmaktadır. Bu aşamada sistemin kendi yazılımı aracılığıyla elde edilen kayıtların MATLAB uyumlu biçimde kayıt edilmesi sağlanmaktadır. Yüzey EMG tabanlı çalışmalarda kullanılan genel elektrot konumları kullanılmıştır (Şekil 1).

Denek grubu, yaşları 22-25 arasında değişen dört normal bireyden (iki bayan ve iki erkek) oluşmaktadır. Denekler, deneysel bir platformda oturtulmuş ve temel el hareketlerini gerçekleştirmişlerdir (Şekil 2).


Oluşturulan deney düzeneği ile kas grafiği (EMG) kayıt işlemi gerçekleştirilmiştir (Şekil 3). Elde edilen şekil üzerinde iki adet grafik bulunmaktadır. Üstteki grafikte ham EMG kaydı bulunurken alttaki grafikte de EMG işaret işleme



Şekil 1. Farklı el hareketlerine göre tespit edilen yüzey EMG için elektrot konumları.



Şekil 2. Yapılan el hareketleri (A) serbest el konumu, (B) yumruk halinde gevşeme ve kasılma hareketi birlikte, (C) yukarı doğru kıvrıma (yani kasılma) ve (D) aşağı doğru kıvrıma (yani gevşeme).



Şekil 3. Örnek ham EMG kaydı (üstte) ve hareketli ortalamalı EMG kaydı.



çok kullanılan hareketli ortalama değerleri bulunmaktadır. Bu grafiklerin alınmasında sırasıyla iki saniye aralıklarla ikişer saniye daha kuvvetli bir şekilde yumruk sıkılarak elde edilmiştir.

## 2.2. Önışlem

Bu aşamada elde edilen verilerin basit alçak geçiren ve yüksek geçiren filtrelerden geçirilerek 0,5-1000 Hz arası sinyallerin kalması sağlanmaktadır. Ayrıca şebeke geriliminin etkisinin azaltılması için 50 Hz frekanslı bileşenlerin etkisini -3 dB kadar azaltan bir çentik filtre kullanımına gidilmektedir. Bu aşama için gerekli kodlar MATLAB içindeki hazır bulunan *filter* komutu ile gerçekleştirilmektedir.

## 2.3. Öznitelik Çıkarma

Bu aşamada EMG sinyalinden anlamlı özet bilgiler elde edilmesi sağlanmaktadır. Bu kısım ile ilgili tüm MATLAB kodları hazırlanmış ve EMG verisi üzerinden aşağıdaki öznitelikler çıkarılarak veri seti oluşturulmuştur (Nishikawa et al. 2002, Boostani and Moradi 2003):

$$\text{Enerji: } E = \sum_{i=1}^N x_i^2 \quad (1)$$

$$\text{Aritmetik Ortalama: } \bar{x} = \frac{1}{N} \sum_{i=1}^N x_i \quad (2)$$

$$\text{Tümleşik EMG: } TEMG = \sum_{i=1}^N |x_i| \quad (3)$$

$$\text{Etkin Değer: } ED = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2} \quad (4)$$

$$\text{Willison Genliği: } WG = \sum_{i=1}^{N-1} f(|x_i - x_{i+1}|) \quad (5)$$

$$f(x) = \begin{cases} 1, & x \geq \text{eşik} \\ 0, & \text{diğer} \end{cases} \quad (5)$$

$$\text{Varyans: } ED = \sqrt{\frac{1}{N-1} \sum_{i=1}^N (x_i - \bar{x})^2} \quad (6)$$

$$\text{Sıfır Geçiş Sayısı: } ZC = \sum_{i=1}^{N-1} f(-x_i * x_{i+1}) \quad (7)$$

$$f(x) = \begin{cases} 1, & x \geq \text{eşik} \\ 0, & \text{diğer} \end{cases} \quad (7)$$

$$\text{Ortalama Mutlak Değer: } AO = \frac{1}{N} \sum_{i=1}^N |x_i| \quad (8)$$

$$\text{Çarpıklık (Skewness): } Sk = \frac{\sum_{i=1}^N (x_i - \bar{x})^4}{N * \sigma^4} \quad (9)$$

$$\text{Basıklık (Kurtosis): } Kr = \frac{\sqrt{N * (N-1)}}{N * (N-1)} * \frac{\sum_{i=1}^N (x_i - \bar{x})^3}{\sigma^3} \quad (10)$$

## 2.4. Sınıflandırma

Literatürde çeşitli makine öğrenmesi yöntemleri geliştirilmiştir. Bu yöntemlerin temelinde ise sınıflandırma algoritmaları bulunmaktadır. Bu çalışmada çıkarılan özniteliklere uygulanan dört ayrı algoritma kullanılmıştır.

Bu algoritmalarla ilgili özet bilgi aşağıda verilmiş olup ayrıntılı bilgiye Duda, Hart ve Stork'un meşhur Pattern Classification kitabından ulaşılabilir (Duda et al. 2001).

### 2.4.1. K-en yakın komşu (KNN) sınıflandırıcı

K en yakın komşu (KNN) sınıflandırıcısı örnek tabanlı bir sınıflandırıcı olup doğrudan sınıfı bilenen eğitim kümesindeki örneklerle kıyaslama yapar. Eğitim aşaması giriş verilerinin ait oldukları sınıf bilgisinin saklanması ibarettir. Bu algoritmada sınıflandırılmak istenen örnek ile eğitim kümesindeki en yakın k adet örneğin ait olduğu sınıfların çoğunluğuna bakılarak sınıflandırma işlemi yapılır. İki örnek arasındaki uzaklığın ölçülmesinde ise Öklid uzaklık ifadesi kullanılmıştır.

### 2.4.2. Çok katmanlı algılayıcı (MLP)

Yapay sinir ağı uygulamalarında çok kullanılan ağ yapısıdır. Hem doğrusal uygulamalarda hem de doğrusal olmayan uygulamalar için kullanılabilir. MLP giriş katmanı, bir veya birden çok saklı katman ve çıkış katmanından oluşmaktadır. MLP'nin her bir katmanında birçok sinir hücresi bulunmaktadır. Bu sinir hücreleri birbirlerine ağırlıklarla bağlıdır. Bu ağırlıklar beklenen çıktı ile ağın çıktısı arasındaki hata minimum olana kadar ağın eğitimi gerçekleştirilir. Ağın çıktı fonksiyonu ve hata fonksiyonu:

$$y_i = f\left(\sum_{j=1}^n w_{ij} x_j\right) \quad (11)$$

$$E = \frac{1}{2} \sum_i (y_{di} - y_i)^2 \quad (12)$$

Burada  $x_j$  girdi verisi,  $w_{ij}$  ağırlık,  $f(\cdot)$  aktivasyon fonksiyonu,  $y_i$  ağı çıktısı,  $y_{di}$  beklenen çıktıdır.

### 2.4.3. Radyal Tabanlı Fonksiyon (RBF)

Radyal tabanlı fonksiyon (RBF) yapay sinir ağları da girdi katmanı, saklı katman ve çıktı katmanı olmak üzere üç katmandan oluşmaktadır. MLP ağlarına oranla daha hızlı çalışırlar. RBF diğer bir ifadeyle yapay sinir ağlarının çok boyutlu bir uzayda eğri uydurma yaklaşımıdır. Bu ağ türünün saklı katmanında aktivasyon fonksiyonu olarak Gauss fonksiyonu kullanılmaktadır. Gauss aktivasyon fonksiyonu ifadesi:

$$y_i(x) = \sum_{j=1}^k w_{ji} \exp\left(-\frac{\|x - \mu_j\|^2}{2\sigma_j^2}\right) \quad (13)$$

Burada  $w_{ji}$  ağırlıkları,  $k$  gizli katman nöron sayısı,  $x$  girdi verisi,  $\mu_j$  j'inci nöron merkezi,  $\sigma_j$  j. dağılım parametresi olmak üzere  $y_i$  ağı çıktısını vermektedir. Ağı çıktısı saklı katman çıkışlarının  $w_{ji}$  ağırlıkla çarpımı sonucu elde edilir ve amaç optimum ağırlık değerlerinin bulunmasıdır.

#### 2.4.4. Destek Vektör Makineleri (SVM)

Destek vektör makineleri istatistiksel öğrenme teorisine dayalı bir yöntemdir. SVM sınıflandırma ve regresyon amaçlı hem doğrusal hem de doğrusal olmayan veri gruplarında kullanılmaktadır. Bu yöntemde amaç iki grubu bir birinden ayıran düzlemin bulunmasıdır. Bunun için iki gruba da yakın ve birbirine paralel iki sınır çizgisi belirlenir. Bu sınır çizgilerine destek vektörleri denmektedir. Bu sınıflandırıcı iki sınır çizgisinden yola çıkarak ortak bir düzlemin belirlenmesi işlemine dayanmaktadır. SVM'de bazı veriler doğrusal bir şekilde ayıramamaktadır. Bu durumda ise çekirdek fonksiyonları kullanılarak veriler başka bir boyuta taşınıp doğrusal olmayan dönüşümler de kullanılabilir.

#### 2.5. Değerlendirme

Sınıflandırıcıların başarımlarında kullanılan ölçütleri şu şekilde verilmektedir (Eberhart and Dobbins 1990):

$$ACC = \frac{TP + TN}{TP + FN + FP + TN} \quad (14)$$

Burada el hareketinin sınıflandırıcı tarafından doğru olarak bulunan kayıtların sayısı  $TP$ , diğer hareketlerden birisi olduğu halde doğru olarak bulunan kayıtların sayısı  $TN$ , yanlışlıkla denenen harekete ait olduğu tespit edilen kayıtların sayısı  $FP$  ve gerçekte tespit edilmeye çalışılan harekete ait olduğu halde değilmiş gibi tespit edilen kayıtların sayısı  $FN$  olarak tanımlanır. Bu değerler kullanılarak sınıflandırıcı performansları için  $ACC$  (genel başarımlar) değerleri hesaplanmıştır. Bu çalışmada başarımların hesaplanması için  $k$ -parçalı çapraz değerlendirme yöntemi kullanılmıştır. Bu yöntemde  $k$  parçaya ayrılan verilerden  $(k-1)$  adedi sınıflandırıcının eğitimi için kullanılır ve kalan parçayla algoritma test

edilir. Bu işlem tüm parçalar test için kullanılacak şekilde tekrarlanarak  $TP$ ,  $TN$ ,  $FP$  ve  $FN$  değerleri bu denemelerin toplamı şeklinde bulunur.

### 3. Sonuçlar

Bu çalışmada, dört önkol hareketi için dört farklı sınıflandırıcı test edildi. Sınıflandırıcıların eğitimi ve testinde, iki kas grubuna ait onar öznitelik kullanılmıştır. Her deneğe ait her bir hareketteki bölütlerden rastgele seçilmiş olanların %50'si sınıflandırıcıları eğitmek ve geriye kalan %50'si de test etmek amacı ile kullanılmıştır. Altı adet denekten onar defa yapılan hareketler sonucunda her hareket ve iki kas grubu için toplam yüz yirmişer kayıt elde edilmiştir. Veri setinde kullanılan hareketler (a) serbest el, (b) yumruk, (c) kasılma ve (d) gevşeme'dir. Buna göre, KNN sınıflandırıcısı için sınıflandırıcı başarımları  $ACC = \%78,75$  olarak bulunmuştur. Bu sınıflandırıcı için  $K=1$  olarak alınmış ve sadece en yakın komşu sınıflandırıcısı denenmiştir (Çizelge 1). Çizelgede %83,3 oranında kasılma hareketinin sınıflandırıcı tarafından doğru olarak tespit edilebildiği ve en yüksek yanlışlama payının ise %10,0 ile gerçekte serbest bırakılan elin yumruk olarak algılandığı veya gerçekte kasılma olan el hareketinin yumruk hareketi olarak algılandığı veya gerçekte gevşeme olan el hareketinin kasılma hareketi olarak algılandığı görülmektedir.

MLP sınıflandırıcısı için sınıflandırıcı başarımları  $ACC = \%87,50$  olarak bulunmuştur. Bu sınıflandırıcı için gizli katman içinde 1'den 50'ye kadar olan değerler denenmiş ve 13 gizli nöron sayısı için elde edilen en iyi başarımlar Çizelgeye aktarılmıştır (Çizelge 2). Bu çizelgeye göre, %91,7 oranında elin serbest bırakılması hareketinin doğru olarak algılandığı

Çizelge 1. KNN sınıflandırıcı sonuçları.

		Gerçek hareket			
		Serbest	Yumruk	Kasılma	Gevşeme
Sınıflandırıcı Cevabı	Serbest	%80,0	%8,3	%6,7	%5,0
	Yumruk	%10,0	%75,0	%10,0	%8,3
	Kasılma	%6,7	%13,3	%83,3	%10,0
	Gevşeme	%3,3	%3,3	%0,0	%76,7

Çizelge 2. MLP sınıflandırıcı sonuçları.

		Gerçek hareket			
		Serbest	Yumruk	Kasılma	Gevşeme
Sınıflandırıcı Cevabı	Serbest	%91,7	%3,3	%3,3	%5,0
	Yumruk	%5,0	%85,0	%8,3	%3,3
	Kasılma	%1,7	%8,3	%86,7	%5,0
	Gevşeme	%1,7	%3,3	%1,7	%86,7

**Çizelge 3.** RBF sınıflandırıcı sonuçları.

		Gerçek hareket			
		Serbest	Yumruk	Kasılma	Gevşeme
Sınıflandırıcı Cevabı	Serbest	%93,3	%3,3	%1,7	%5,0
	Yumruk	%3,3	%88,3	%6,7	%1,7
	Kasılma	%1,7	%6,7	%90,0	%3,3
	Gevşeme	%1,7	%1,7	%1,7	%90,0

**Çizelge 4.** SVM sınıflandırıcı sonuçları.

		Gerçek hareket			
		Serbest	Yumruk	Kasılma	Gevşeme
Sınıflandırıcı Cevabı	Serbest	%96,7	%3,3	%1,7	%3,3
	Yumruk	%1,7	%93,3	%3,3	%0,0
	Kasılma	%0,0	%3,3	%93,3	%1,7
	Gevşeme	%1,7	%0,0	%1,7	%95,0

görülmektedir. Tersine ise, %8,3 oranında gerçekte yumruk olan el hareketinin kasılma olarak veya elin kasılması olan hareketin yumruk hareketi olarak algılandığı görülmektedir.

Bir sonraki sınıflandırıcı tasarımı olan RBF sınıflandırıcısı için sınıflandırıcı başarımı ACC = %90,42 olarak bulunmuştur (Çizelge 3). Bu çizelgeye göre, %93,3 en yüksek doğrulukla elin serbest bırakıldığı el hareketi algılanabilmiştir. Öte yandan, %6,7 oranında en yüksek yanılma ise yumruk olan el hareketinin kasılma hareketi olarak veya kasılma olan el hareketinin yumruk olarak algılanması ile ortaya çıktığı görülmektedir.

Son olarak, SVM sınıflandırıcısı için sınıflandırıcı başarımı ACC = %94,58 olarak bulunmuştur (Çizelge 4). Tüm hareketler için SVM en yüksek doğrulukta sınıflandırma yapmıştır. Bu çizelgeye göre, %96,7 oranında doğru olarak tahmin edilen el hareketi elin serbest bırakılması hareketi olmuştur. Yapay sinir ağları tabanlı MLP, RBF ve SVM sınıflandırıcılarının tamamında elin serbest bırakıldığı hareketin en yüksek oranda tahmin edilebildiği görülmektedir.

#### 4. Tartışma

Kas tipi seçiminin tüm sınıflandırıcılar için elde edilen doğruluk oranı değerlerini etkileyebileceği söylenebilir. Çizelgelere göre en yüksek sınıflandırıcı başarımı SVM sınıflandırıcısı ile elde edilebilmiştir. Bunun sonucunda da bütün sınıflandırıcılarda en yüksek doğruluk oranı değeri bilek uzatma hareketinde elde edilmiştir. Bu konumda, alt önkol ve yan önkol kas grubundan alınan EMG işaretinin, diğer kas bölgelerine nazaran konumu daha etkili temsil edi-

ci olduğu görüşü klinik uzmanlarca da desteklenmektedir. Çalışmadan da görüldüğü gibi, gerçekleştirilen her harekete yardımcı olan kas grubunun belirlenip, o kas grubundan EMG kaydı alınması sınıflandırma başarılarını arttıracaktır. Birbirinden çok farklı hareketlerin gerçekleştirilmesi isteniyor ise ikiden fazla kanala sahip (ikiden fazla kas grubu) EMG kaydı ile sınıflandırma başarımları artırılabilir. Ayrıca, uygulamalarda sistemin kullanıcıya göre ayarlanması gereklidir. Bu ayarlama ile daha yüksek başarımlar elde edilmiş olacaktır.

Bu çalışmada, kişinin kendi seçtiği kasıtlı hareketlere karşılık gelen önkol kasına ait EMG işaretleri sınıflandırılmıştır. Sınıflandırma için düşük boyutlu öznitelik vektörü oluşturulmuş olup, işlem yükü az olan istatistiksel sınıflandırıcılar ile denenmiş ve önerilen EMG öznitelikleri ve kullanılan sınıflandırıcıların, kas hareketlerinin sınıflandırılmasında yeterli başarımlar göstermiştir. Sonuç olarak, destek vektör makineleri (SVM) tabanlı sınıflandırma sisteminin potansiyel olarak protez el kontrolü için kullanılabileceği görülmüştür. Gerçek zamanlı uygulamalar gerçekleştirmek için, ileriki çalışmalarda gömülü sistem tabanlı bir sınıflandırıcı tasarlanabilir. Sonuç olarak, literatürdeki benzer çalışmalarla kıyaslandığında yüksek bir sınıflandırıcı başarımı elde edilebilmiştir.

#### 5. Teşekkür

Bu çalışma İzmir Katip Çelebi Üniversitesi Bilimsel Araştırma Projeleri Koordinatörlüğü tarafından 2013-2-FMBP-49 nolu Öncelik Alan Projesi olarak ve TÜBİTAK tarafından 2170241 nolu TEYDEB BIGG (Bireysel Genç Girişimci) Projesi olarak desteklenmiştir.

## 6. Kaynaklar

- Arieta, AH., Katoh, R., Yokoi, H., Wenwei, Y. 2006.** Development of Multi-DOF Electromyography Prosthetic System Using the Adaptive Joint Mechanism. *Appl. Bionics. Biomech.*, 3:101-112.
- Basmajian, MD., De Luca, CJ. 1985.** *Muscles Alive*. ed: Williams & Wilkins, Baltimore.
- Boostani, R., Moradi, MH. 2003.** "Evaluation of the Forearm EMG signal Features for the Control of a Prosthetic Hand. *Physiol. Meas.*, 4(2):309-319.
- Dechev, N., Cleghorn, WL, Naumann, S. 2001** Multiple Finger, Passive Adaptive Grasp Prosthetic Hand. *J. Mech. Mach. Theory*, 36:1157-1173.
- Duda, RO., Hart, PE., Stork, DG. 2001.** *Pattern Classification*, John Wiley & Sons Inc., 2001.
- Eberhart, RC., Dobbins, RW. 1990.** *Neural Network PC Tools*, Academic Press, San Diego, 1990.
- Englehart, K., Hudgin, B., Parker, PA. 2001.** A Wavelet-Based Continuous Classification Scheme for Multifunction Myoelectric Control. *IEEE T. BioMed. Eng.*, 48(3):302-311.
- Graupe, D., Cline, WK. 1975.** Functional Separation of EMG Signals via ARMA Identification Methods for Prosthesis Control Purposes. *IEEE Trans. Syst. Man. Cyber.*, 5(2):252-259.
- Haihua, L., Xinhao, C., Yaguang, C. 2005.** Wavelet Transform and Real-Time Learning Method for Myoelectric Signal in Motion Discrimination. *First International Conference on Neural Interface and Control*, 127-130.
- Isler, Y. 2017.** Çok Fonksiyonlu Protez El Hareketleri İçin Yüzey EMG Sinyali Tabanlı Uzman Sistem Tasarımı. *Akıllı Sistemlerde Yenilikler ve Uygulamaları Konferansı (ASYU'2017) Bildiri Özetleri Kitabı*, ISBN: 978-605-84722-8-0, 36.
- Kamavuako, EN., Farina, D., Yoshida, K., Jensen, W. 2009.** Relationship Between Grasping Force and Features of Single-Channel Intramuscular EMG Signals. *J. Neurosci. Methods*, 185(1):143-150.
- Kilby, J., Hosseini, HG. 2004.** Wavelet Analysis of Surface Electromyography Signals. *26th Annual International Conference of the IEEE EMBS*, 1: 384 – 387.
- Matrone, GC., Cipriani, C., Secco, EL., Maganes, G., Carrozza, MC. 2010.** Principal Components Analysis Based Control of a Multi-DOF Underactuated Prosthetic Hand. *J. Neuroeng. Rehabil.*, 7(16):1-13.
- M. Zardoshti, M., Wheeler, B., Badie, K., Hashemi, MR. 1995.** EMG Feature Evaluation for Movement Control of Upper Extremity Prostheses. *IEEE T. Bio-Med Eng.*, 3(4):324-333.
- Nishikawa, D., Yu, W., Yokoi, H., Kakazu, Y. 2002.** On-Line Supervising Mechanism For Learning Data In Surface Electromyogram Motion Classifiers. *Sys. Comput. Japan*, 33(14): 1-11.
- Raez, MBI., Hussain, MS., Mohd-Yasin, F. 2006.** Techniques of EMG Signal Analysis: Detection, Processing, Classification and Applications. *Biol. Proced. Online*, 8: 11–35
- Scheme, EJ., Englehart, KB., Hudgins, BS., 2011.** Selective Classification for Improved Robustness of Myoelectric Control Under Nonideal Conditions. *IEEE T. Bio-Med. Eng.*, 58(6):1698-1705.
- Zhao, Z., Chen, X., Zhang, X., Yang, J., Tu, Y., Lantz, V., Wang, K. 2007.** Study on Online Gesture SEMG Recognition. *Advanced Intelligent Computing Theories and Applications With Aspects of Theoretical and Methodological Issues*, 1257-1265.
- Zheng, L., He, X. 2005.** Classification Techniques in Pattern Recognition. *WSCG Conference Proceedings*, ISBN 80-903100-8-7, 2005.