

## ÇOK İŞLEVİLİ PROTEZ EL KONTROLÜ İÇİN ÖNKOL ELEKTROMİYOGRAFİ İŞARETLERİNİN SINIFLANDIRILMASI

*(THE CLASSIFICATION OF FOREARM ELECTROMYOGRAPHIC SIGNALS  
FOR MULTIFUNCTION PROSTHESIS HAND CONTROL)*

Erkan Zeki ENGİN<sup>1</sup>, Deniz TAŞAN, Mehmet ENGİN<sup>2</sup>

### ÖZ

Örüntü tanıma tabanlı el kontrol algoritmaları, özürlü kişiler için yapay el üretmek amacı ile kullanılmaktadır. Bu çalışmada; önkol kaslarındaki EMG (ElektroMiyografı) işaretlerini kullanarak, çok işlevli (altı önkol hareketi: el açık, el kapalı, bileği bükme, bilek uzatma, dirsek sapma ve açılma sapma) el kontrolü için dört sınıflandırıcı (doğrusal ayırma analizi, k-en yakın komşuluğu, en yakın komşuluk ve k-ortalama) incelenmiştir. Sınıflandırıcıların eğitim ve testinde, EMG işareti tabanlı etkin değer, varyans, dalgacık tabanlı entropi ve sıfır geçiş oranı öznelikleri kullanılmıştır. Sonuç olarak, doğrusal ayırma analizi sınıflandırıcısı tüm denekler ( $94,68 \pm 3,96$ ) ve hareketler ( $94,68 \pm 3,58$ ) için en fazla doğruluk göstermiştir.

**Anahtar Kelimeler:** EMG, öznelik çıkartımı, sınıflandırıcı, protez el

### ABSTRACT

*Pattern recognition based prosthesis hand control algorithms have largely been used to produce artificial hand for handicapped people. This paper was investigated four classifiers (linear discriminant analysis, k-nearest neighbor, nearest neighbor and k-means) for multi-functional (six forearm movement: hand open, hand close, wrist flexion, wrist extension, ulnar deviation, and radial deviation) hand control by using EMG signals from forearm muscles. In training and testing of classifiers, EMG signal based RMS, variance, wavelet-based entropy, and zero-crossing rate features were used. As a result, linear discriminant analysis classifier has shown maximum accuracy for all subjects ( $94,68 \pm 3,96$ ) and movements ( $94,68 \pm 3,58$ ).*

**Keywords:** EMG, feature extraction, classifier, prosthesis hand

<sup>1</sup> Ege Üniversitesi, Elektrik-Elektronik Mühendisliği Bölümü, Bornova, İZMİR, erkan.zeki.engin@ege.edu.tr (sorumlu yazar)

<sup>2</sup> Ege Üniversitesi, Elektrik-Elektronik Mühendisliği Bölümü, Bornova, İZMİR, mehmet.engin@ege.edu.tr

## 1. GİRİŞ

Elektromiyografi (EMG) işaretleri, miyoelektrik protez elleri kontrol etmek için kullanılabilir. Bu işaretler, istemli kasılma koşulları sırasında kas zarının kutupsuzluk (depolarization) ve tekrar kutuplanmalarında (repolarization) oluşmaktadır. Ancak EMG analizinde hala EMG işareti ve ilgili hareketler arasındaki ilişkiyi modellemede farklı teknik sınırlamalar mevcuttur [1]. Bu tür işaretleri toplamak için kuru veya ıslak tip elektrotlar kullanılabilir. Protezin kontrolünde kullanılan EMG işaretleri genellikle önkoldan tek veya çok kanallı olarak alınır. Protezde çoklu işlevleri kontrol etmek için EMG işaretleri, çeşitli kas kasılmalarına karşılık gelmelidir. Bu uygulama genellikle çevrimdışı şekilde olsa da, gerçek zamanlı sınıflandırma büyük önem taşımaktadır. En büyük sınıf ayrılabilirliği, sağlamlık ve karmaşıklık ilgili sınıflandırıcıların önemli özellikleridir. Bu nedenle, en uygun özniteliklerin ve sınıflandırıcıların seçimi protez el kontrolü için hala sorun teşkil etmektedir.

Englehart vd. çalışmalarında, EMG için en uygun öznitelikleri araştırmışlardır [2]. İki farklı kas grubundan dört farklı el ve bilek hareketi için alınan EMG işaretlerini işleyerek, zaman ve frekans tabanlı öznitelikler çıkartmışlardır. Sınıflandırma aşamasında, çok katmanlı algılama tabanlı Yapay Sinir Ağı (YSA) kullanmışlardır. Diğer bir çalışmada [3], dört farklı dirsek ve bilek hareketi için YSA ve bulanık tabanlı sınıflandırıcıları karşılaştırmak için yeni bir yöntem önerilmiştir. YSA sınıflandırıcısı sekiz gizli nörona sahip olup, geri-yayılma algoritması ile eğitilmiştir ve bulanık sınıflandırıcının eğitimi için temel eş veri (isodata) algoritması kullanılmıştır. Bulanık tabanlı sınıflandırıcının; tanıma, düşük eğitim süresi ve daha yüksek hassasiyet ölçütleri açısından YSA sınıflandırıcısına göre üstünlükleri olduğunu göstermişlerdir.

Wojtczak vd. çalışmalarında, çok işlevli protezde parmak kontrolü için yüzey EMG işaretlerini doğrusal ağ yapıları ile sınıflandırmışlardır [4]. Diğer bir çalışmada, parmakların kontrolü için sekiz denekten alınan yüzey EMG işaretleri kullanılmıştır. Çıkarılan birçok öznitelik içinde etkin olanlar seçilmiş ve iki tip sınıflandırıcı ile harekete karar verilmiştir [5].

Kontrolörden kısa tepki süresi almak için bazı araştırmacılar [6] üst koldan alınan EMG'den bir grup öznitelik çıkartmış ve bunları k-en yakın komşu sınıflandırıcısı ile değerlendirmişlerdir. Bu öznitelikler; mutlak değer integrali, varyans, sıfır geçiş oranı ve öz-yinelemeli model parametreleridir. Diğer bir çalışmada [7]; YSA ve doğrusal ayırma analizi yöntemlerini, verimlilik ve sınıf ayrılabilirliğini artırmak için kullanılmıştır. Chu vd. çalışmalarında [8], 4 kanaldan alınan EMG işaretleri ile gerçek zamanlı ve çok-işlevli el kontrolü gerçekleştirmişlerdir. Dalgacık paket dönüşümü kullanılarak çıkarılan özniteliklerde Temel Bileşenler Analizi ve kendinden-organize öznitelik haritası ile özniteliklerin boyutu düşürüldükten sonra YSA ile sınıflandırmışlardır. Sanal el kontrolü denemeleri sonucunda gerçek zamanlı el kontrolünde de kullanılabilceği sonucuna varmışlardır. Diğer bir çalışmada ise yine çok-işlevli elin gerçek zamanlı miyoelektrik kontrolü için dalgacık paket dönüşümündeki düğümlerin enerjileri öznitelik olarak kullanılmıştır [9]. Daha sonra yüksek boyutlu öznitelikleri düşürmek için yeni bir yinelemeli algoritma kullanılmıştır. Son olarak da, Destek Vektör Makinaları ile sınıflandırma yapılmıştır.

Birçok sınıflandırma sistemi çok başarılı olmasına karşın, birden fazla işlevin (el açık, el kapalı, bilek bükme, bilek uzatma, dirsek sapma ve açılma sapma) kontrolü için yeterli bilgi edinilmesi hala zor bir sorundur. Önerilen herhangi bir sistem ile farklı hareket sınıflarını ayırabilmek için en az sayıda EMG özniteliği ile en fazla sınıflandırma doğruluğunun elde

edilmesi beklenmektedir. Önkol hareketlerinin sınıflandırılmasındaki başka bir sorun ise uyarlanan algoritmanın karmaşıklığına bağlı gerçek zamanlı uygulamalarda yaşanabilen zorluklardır.

Bu çalışmada, altı önkol hareketi için en fazla sınıflandırma doğruluğunu sağlayan ve gerçek zamana uygulanabilecek bir sınıflandırıcı bulma amacı ile Şekil 1'deki sistem tasarlanmıştır. Örüntü tanıma yapabilmek için dört EMG tabanlı öznelik (etkin değer, varyans, dalgacık tabanlı entropi ve sıfır geçiş oranı) kullanmıştır. Önerilen özneliklerin seçimindeki temel ölçüt ise bu özneliklerin EMG işaretlerinin zaman-frekans özelliklerini içermesidir. Bu amaçla, üç zaman ortamı tabanlı öznelik (etkin değer, varyans, sıfır geçiş oranı) ve bir zaman-frekans tabanlı öznelik (dalgacık tabanlı entropi) kullanılmıştır. El hareketlerinde en fazla sınıflandırma başarısını elde etmek amacı ile istatistiksel tabanlı sınıflandırıcıların performansları karşılaştırılmıştır. Sonuç olarak, doğrusal ayırma analizi sınıflandırıcısı tüm denekler ve hareketler için en fazla doğruluk göstermiştir.



Şekil 1. Tasarlanan sistemin blok diyagramı

## 2. MATERYAL VE YÖNTEM

### 2.1. Veri Toplama ve İşleme

EMG işaretleri, yüzey elektrotlar ile iki farklı önkol kaslarından alınmıştır (Şekil 2). EMG işaretleri, Analog Sayısal Dönüştürücü Birimi ve "Daisy Lab" yazılımı kullanılarak kaydedilmiştir. Kayıttan önce, analog işaretler 10 - 500 Hz bant genişliğine sahip bir bant-geçiren süzgeçten geçirilmiş olup, örnekleme hızı 1024 Hz'dir. EMG frekans içeriği 0 - 1000 Hz arasında olmasına karşın, baskın enerji 20 - 500 Hz aralığında bulunmaktadır ve genlik 0 - 10 mV ile sınırlıdır. Analog işleme ve kayıt sistemi Şekil 3'de görülmektedir.



(a)



(b)


Şekil 2. İki önkol kası için elektrotların bağlantısı: (a) doğrultucu kas (extensor digitorum superficialis), (b) bükülme kası (flexor digitorum superficialis)

Deneyler, Ege Üniversitesi Tıp Fakültesi Biyofizik Bölümü Laboratuvarında yapılmıştır. Denek grubu, yaşları 27 ile 32 ( $29,6 \pm 1,77$ ) arasında değişen sekiz normal bireyden (iki bayan

ve altı erkek) oluşmaktadır. Denekler, deneysel bir platformda oturtulmuş ve Şekil 4'te gösterilen hareketleri gerçekleştirmişlerdir.



Şekil 3. Analog işleme ve kayıt sistemi



(a)



(b)




(c)



(d)




(e)



(f)

Şekil 4. El hareketlerin görüntüleri: (a) El açık (hareket-1), (b) El kapalı (hareket-2), (c) Bilek bükme (hareket-3), (d) Bilek uzatma (hareket-4), (e) Açısal sapma (hareket-5), (f) Dirsek sapma (hareket-6)

Her bir el hareketi için kaydedilen EMG işaretinin toplam süresi yaklaşık olarak 30 saniyedir ve gevşeme ve statik kasılmaları kapsamaktadır. El açık hareketi için doğrultucu kasındaki EMG işareti ve EMG işaretinin güç izgesel yoğunluğu Şekil 5’de verilmektedir. Kaydedilen işaretlerden ortalama değer atıldıktan sonra Hamming pencere ile 0,5 sn’lik bölütlere ayrılmış olup, örtüşme miktarı %50 seçilmiştir. Elektrotlar arasındaki etkileşimi önlemek için, aralarındaki mesafe 2 cm’ye ayarlanmıştır.



Şekil 5. Doğrultucu kasındaki el açık hareketi için: (a) EMG işareti, (b) EMG işaretinin güç izgesel yoğunluğu

## 2.2. Öznitelik Çıkartımı

Sınıflandırıcıları eğitmek ve test etmek için gerekli olan zaman veya zaman-frekans tabanlı öznitelikler (etkin değer, varyans, sıfır geçiş oranı ve dalgacık tabanlı entropi) her kasa ait bölütlere için çıkartılmıştır. Böylece sınıflandırıcıda kullanılmak üzere her bölüttten sekiz öznitelik çıkartılmıştır.

### 2.2.1. Etkin Değer

Etkin değer, deterministik ve stokastik işaretlerde güç tabanlı bir öznitelik olarak kullanılabilir [10].

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

$x_i$ , EMG işaretin ilgili bölütün  $i$ . örneği ve  $N$ 'de bölütteki örnek sayısıdır. Bölütteki etkin değerlerin kestirimi, zamanın bir işlevi olarak EMG işaretinin ortalama gücünün kullanışlı bir göstergesidir [11].

### 2.2.2. Varyans

Varyans, rastgele değişkenin istatistiksel ortalamasıdır ve işaretin gücünün bir ölçütüdür. Ergodiklik koşulu altında iken varyans, örnek ortalaması (veya zaman ortalaması) olarak hesaplanabilir [12].

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

### 2.2.3. Sıfır Geçiş Oran (SGO)

İşaretin, ilgili periyottaki veya bölütteki, dinamik değişimleri gösteren bir ölçüttür. Bu öznelik, işaretin sıfır genlik ekseninden geçiş sayısıdır [12]. EMG işareti, kas fiberlerinden meydana gelen biyopotansiyellerin değerine bağlı olarak, eksi ve artı genlik değerleri arasında sürekli olarak değişir.

$$SGO = \sum_{i=1}^N sign(-x_i x_{i+1}) \quad sign(x) = \begin{cases} 1 & x > 0 \\ 0 & \text{diğer} \end{cases} \quad (3)$$

SGO'yu kolaylıkla düşük frekans bozucu etkiler, DC kutuplamayı (bias) ve zaman-tabanlı çalkantısını (base-time wander) etkilediği için ilgilenilen işaretin türevi üzerinden hesaplanması tavsiye edilmektedir. Basitliğinden dolayı, EMG işaretinin analizi için pratik uygulamalarında kullanılmaktadır.

### 2.2.4. Dalgacık Dönüşümü Tabanlı Entropi

Birçok biyomedikal işaret durağan olmayan (non-stationary) davranışa sahip olduğu için bu işaretlerin dinamik örüntülerini çıkartmakta zaman – frekans gösterilimi gerekmektedir [13]. EMG ve EEG (ElektroEnsefaloGrafı) gibi doğrusal olmayan işaretler için dalgacık dönüşümü, zaman – frekans dağılımını göstermek için en iyi adaydır. Bu dönüşüm, uygun ölçek ve kayma ile işaretin zaman – ölçek boyutunda işlenmesidir [14]. Dalgacık Dönüşümünde, Sürekli ve Ayrık olmak üzere iki çeşidi olup, Ayrık Dalgacık Dönüşümü (ADD) aşağıdaki eşitlikle tanımlanmaktadır [15].

$$W[m, n] = 2^{-m/2} \sum_{i=1}^{M-1} \tau(i) \psi(2^{-m} i - n) \quad (4)$$

$m$ ; ölçek ve  $n$ ; dönüşüm değişkeni olup, pozitif tamsayılardır.  $\tau(i)$  ayrık-zaman dizisi,  $M$ ; işarettaki toplam örnek sayısını ve  $\psi$  ana dalgacık işlevini göstermektedir. Bu çalışmada, işaret Daubechies-3 ana dalgacık işlevi ile 4 ölçek açılmıştır.

Haberleşme teorisinde, bir mesajın içerdiği bilgi miktarı oluşma olasılığı ile gösterilmektedir [15] ve entropi ortalama bilgi olarak tanımlanabilir. İşaret işleme ise olasılık dağılımının karşılaştırılması ile işaretin düzen veya düzensizliğini değerlendirmek için kullanışlı bir ölçüttür [16].



Entropi ölçütü, zaman – frekans ortamında tanımlanabilmektedir ve bunun için ADD uygun ve kullanışlı bir gösterimdir. Çok düzenli bir işaret, tek frekanslı periyodik bir işaret olarak düşünüldüğünde (dar bantlı bir işaret), işaretin dalgalık gösterimi, bir alt bant ile büyük bir oranda sağlanır ve entropisi sifıra yakın bir değer olacaktır. Tamamen rastlantısal bir işaret ise çok düzensiz bir yapı olarak görülür ve birçok alt bantta bileşen bulunur ve entropisi düzensizliğin miktarına göre büyük değer alır.

ADD tabanlı entropi hesaplanması için gerekli olan olasılık dağılımı:

$$p_j = \frac{E_j}{E_{top}} \quad (5)$$

$E_j$ ; ilgili ölçekteki ayrıntı katsayılarının sahip olduğu enerji ve  $E_{Top}$ ; tüm ölçeklerdeki ayrıntı katsayılarının sahip olduğu enerjilerin toplamıdır. Bu eşitlik ile hesaplanan bağıl enerjiler, ölçeklerdeki olasılık dağılımlarını temsil etmektedir ve aşağıdaki eşitlik ile de Shannon entropisi hesaplanmıştır.

$$H = -\sum_j p_j \ln p_j \quad (6)$$

### 2.3 Örüntü Tanıma

Birçok örüntü tanıma yönteminde olasılık yoğunluk kestirimi önemli bir sorundur. Olasılık yoğunluk kestirimi için parametrik ve parametrik olmayan yöntemler bulunmaktadır. Parametrik olmayan yöntemlerden biri de k-en yakın komşuluğudur. Bu yöntemde, eğitim örnekleri üzerinden olasılık yoğunluğunu kestirmektir. Bu kestirimi yapabilmek için veri grubunun merkezinde bir hücre oluşturulur ve  $k_n$  örneklerini yakalayınca kadar büyütülür.

Sınıflandırma amacı ile kullanıldığında, en-yakın komşuların ait olduğu gruplar arasında oylama yapılır ve bu komşuların en çok ait olduğu grup, verinin grubu olarak atanır. Bu sınıflandırıcı kolay uygulanabilir, ancak tembel öğrenmeli bir sınıflandırıcıdır. Eğitim işleminin, işlem yükü düşük olmasına karşın test işlem yükü yüksektir. Ayrıca, verinin yerel yapısına olan duyarlılığı ve yüksek hafıza gerektirmesi zayıflığıdır. Kestirimin kalitesi, seçilen komşu eleman sayısına bağlıdır [17]. Bu çalışmada, bu değer 3 olarak seçilmiş ve uzaklık ölçütü olarak Euclidean kullanılmıştır.

Diğer yandan en yakın komşu sınıflandırıcısında,  $x$ 'i sınıflandırmak için en-yakın komşu kuralı ile ilişkili  $\tilde{x}$ 'a etiket atanmalıdır. Eğer iki farklı kümeye ait iki test noktaları birbirine çok yakın ise bu kümeler bağlanabilir [18]. En yakın komşu, Vornoi düzeni ile oluşturulabilir. Bu düzende,  $x$  ve küme merkezi arasındaki mesafe gösterilir ve mesafe için Euclidean uzaklığı kullanılmıştır. k-ortalamları yöntemi, en eski kümeleme yöntemlerinden biridir ve hesaplamayı basitleştirmek ve yakınsamayı hızlandırmak için kullanılabilir. Bu algoritmada, yinelemeli uygulama ile ortalama vektörleri,  $\hat{\mu}_1 \dots \hat{\mu}_c$ , bulunur. Eğer başka bir bilgi yok ise küme sayısını,  $c$ , tahmin etmek gerekir. Buradaki amaç, işlem sonunda elde edilen kümelerin, küme içi benzerliklerinin en büyük ve kümeler arası benzerliklerinin en küçük olmasını sağlamaktır. Küme benzerliği, kümenin ağırlık merkezi olarak kabul edilen bir nesne ile kümedeki diğer nesnelere arasındaki uzaklıkların ortalama değeri ile ölçülmektedir. Çeşitli uzaklık ölçütleri bulunmakta olup, bu çalışmada karesel Euclidean uzaklığı kullanılmıştır ve k-değeri 6 olarak seçilmiştir.

İstatistiksel sınıflandırıcılar, karar/ayırım işlevleri ile öznitelik vektörü üzerinde işlem yaparlar. Bunlarda sınıflandırmalar aşağıdaki ayırım işlevleri ile yapılır [19].

$$d_i(\beta) > d_j(\beta) \quad j \neq i \quad (7)$$

$i$  ve  $j$  küme sınıflarını temsil etmektedir. Çeşitli sınıflar iyi kümelenmiş ve ayrılmış olduğu durumda, sınıflandırma bir uzaklık ölçütü ile yapılabilir. Doğrusal Ayırım Analizinde (DAA), sınıfı bilinmeyen işarete ait öznitelik vektörü,  $\beta$ , ile ilgili kümelerin eğitim verilerinden elde edilen merkezleri,  $m_i$ , arasındaki Mahalanobis mesafesi hesaplanmış ve en yakın olduğu merkeze ait sınıfa ait olduğuna karar verilmiştir.

$$D_i^2 = (\beta - m_i)^T \Sigma^{-1} (\beta - m_i) \quad (8)$$

$\Sigma$ ; kovaryans matrisidir.

Önerilen sınıflandırıcıların başarısını kestirmek için, doğruluk oranı hesaplanmıştır. Doğruluk Oranı (DO); doğru algılanan el hareketi (veya sınıf) sayısının (Doğru Pozitif: DP), DP ve YN'nin (Yanlış Negatif: diğer el hareketleri veya sınıfları olarak algılananların sayısı) toplamına bölünerek hesaplanır.

$$DO(\%) = \frac{DP}{DP + YN} \times 100 \quad (9)$$

### 3. SONUÇLAR

Bu çalışmada, altı önkol hareketi için dört sınıflandırıcı test edildi. Sınıflandırıcıların eğitimi ve testinde, iki kas grubuna ait dörder öznitelik kullanılmıştır. Her hareket için özniteliklerin ortalama değerleri Çizelge 1'de görülmektedir. Doğrultucu kasındaki bilek uzatma hareketi için ortalama etkin değer (OED) ve varyans değerleri en büyük çıkmıştır. Bu değerler sırası ile  $(38,8 \pm 25,7) \cdot 10^{-3}$  ve  $(2,17 \pm 3,4) \cdot 10^{-3}$  olarak bulunmuştur. Ayrıca, bükülme kasındaki açısız sapma hareketi için de benzer sonuçlar elde edilmiştir. Bu durum için değerler sırası ile  $(34,9 \pm 17,5) \cdot 10^{-3}$  ve  $(1,53 \pm 1,5) \cdot 10^{-3}$ 'dir.

**Çizelge 1.** Her hareket için iki farklı kol kasin özniteliklerinin ortalama değerleri: (a) doğrultucu kas, (b) bükülme kası

Hareket No	OED	Entropi	Varyans	SGO
1	15,2 ± 6,1	682,1 ± 14,9	0,27 ± 0,2	159,3 ± 39,4
2	19,4 ± 7,9	675,7 ± 21,0	0,44 ± 0,4	149,4 ± 33,4
3	38,8 ± 25,7	674,9 ± 19,7	2,17 ± 3,4	169,9 ± 43,5
4	16,3 ± 8,6	682,9 ± 14,5	0,34 ± 0,3	177,7 ± 39,5
5	15,1 ± 7,0	681,8 ± 14,0	0,28 ± 0,2	165,6 ± 33,4
6	30,3 ± 11,7	677,1 ± 18,9	1,05 ± 0,9	149,8 ± 32,1

(a)

Hareket No	OED	Entropi	Varyans	SGO
1	15,0 ± 14,5	675,2 ± 18,6	0,44 ± 0,7	158,8 ± 27,5
2	10,8 ± 9,9	671,5 ± 24,6	0,21 ± 0,4	135,6 ± 29,6
3	18,6 ± 13,6	667,5 ± 29,2	0,53 ± 0,7	145,7 ± 30,4
4	19,9 ± 16,5	668,6 ± 30,9	0,67 ± 0,9	167,9 ± 27,3
5	34,9 ± 17,5	667,2 ± 29,0	1,53 ± 1,5	166,4 ± 25,6
6	5,0 ± 1,4	678,6 ± 11,8	0,03 ± 0,01	156,9 ± 23,3

(b)

\* OED, Entropi ve Varyans değerleri,  $10^{-3}$  ile çarpılmalıdır.



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. Sınıflandırıcıların her hareket için ortalama DO değerleri Çizelge 2'de verilmektedir. Bu çizelgeden görüldüğü üzere DAA sınıflandırıcısı en büyük ortalama değere (%94,68) ve en küçük standart sapmaya (%3,58) sahiptir. Bu sonuçlar ışığında, DAA sınıflandırıcısının diğer sınıflandırıcılardan daha iyi başarımlar gösterdiği görülmektedir. Ayrıca bu sınıflandırıcı, bilek uzatma (%100) ve açısal sapma (%96,99) hareketleri için en yüksek DO değeri göstermektedir.

Çizelge 2. Her hareket için sınıflandırıcıların ortalama DO değerleri

Hareket No	DAA	k-en yakın	En yakın	k-ortalama
1	93,75	53,24	58,33	47,92
2	89,58	67,36	60,87	52,31
3	100	77,54	78,01	62,03
4	94,90	63,65	70,60	49,53
5	96,99	62,96	58,79	51,15
6	92,82	65,05	52,77	64,01
<b>Ortalama</b>	<b>94,68</b>	64,97	63,23	54,49
<b>Standart Sapma</b>	<b>3,58</b>	7,84	9,30	6,80

Denek dağılımına göre sınıflandırıcı başarımlarını karşılaştırmak için Çizelge 3 oluşturulmuştur. Bu çizelgede, DAA sınıflandırıcısının başarımlarının diğer sınıflandırıcılardan yüksek olduğu görülmektedir.

Çizelge 3. Her denek için sınıflandırıcıların ortalama DO değerleri

Denek No	DAA	k-en yakın	En yakın	k-ortalama
1	97,22	66,05	66,65	66,35
2	96,60	64,81	70,37	66,50
3	88,27	54,63	55,87	53,40
4	97,23	66,66	64,50	51,85
5	89,20	62,04	54,32	41,36
6	94,75	51,85	45,37	46,91
7	99,38	75,93	75,00	60,65
8	94,75	77,78	73,76	48,92
<b>Ortalama</b>	<b>94,68</b>	64,97	63,23	54,49
<b>Standart Sapma</b>	<b>3,96</b>	9,07	10,46	9,20

#### 4. TARTIŞMA

Kas tipi seçiminin tüm sınıflandırıcılar için elde edilen doğruluk oranı değerlerini etkileyebileceği söylenebilir. Çizelge 1'e göre en yüksek temsilcisi rakamlar, doğrultucu kasında bilek uzatma hareketi ve bükülme kası için de açısal sapma hareketi içindir. 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 edici 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 başarımlarını arttıracaktır. Birbirinden çok farklı hareketlerin gerçekleştirilmesi isteniyorsa

ikiden fazla kanala sahip (ikiden fazla kas grubu) EMG kaydı ile sınıflandırma başarımları arttırılabilir. 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, işlemsel yükü az olan istatistiksel sınıflandırıcılar ile denenmiş ve önerilen EMG öznitelikleri ve kullanılan sınıflandırıcıların, kas hareketlerinin sınıflandırılmasında yeterli başarımlar göstermiştir. Sonuç olarakta, doğrusal ayırım analiz tabanlı sınıflandırma sisteminin potansiyel olarak protez el kontrolü için kullanılabilceği görülmüştür. Gerçek zamanlı uygulamalar gerçekleştirmek için, ileriki çalışmalarda gömülü sistem tabanlı bir sınıflandırıcı tasarlanabilir.

## TEŞEKKÜR

EMG verilerin toplanmasındaki katkılarından dolayı Prof. Dr. Gürbüz Çelebi, Özlem Çakır, Dr. Fisun Ersan'a teşekkür ederiz.

## KAYNAKLAR

- [1] Chereon G, Draye JP, Bourgeois M, Libert G. "A Dynamic Neural Identification of Electromyogram and Arm Trajectory Relationship During Complex Movements", *IEEE Transactions on Biomedical Engineering*, Cilt 43, s. 552-558, 1996.
- [2] Englehart K, Hudgins B, Parker PA. "A Wavelet-based Continuous Classification Scheme for Multifunction Myoelectric Control", *IEEE Transactions on Biomedical Engineering*, Cilt 48, s. 302-311, 2001.
- [3] Chan FHY, Yang YS, Lam FK, Zhang YT, Parker PA. "Fuzzy EMG Classification for Prosthesis Control", *IEEE Transactions on Rehabilitation Engineering*, Cilt 8, s. 305-311, 2000.
- [4] Wojtczak P, Amaral TG, Dias OP, Wolczowski A, Kurzynski M. "Hand movement recognition based on biosignal analysis", *Engineering Applications of Artificial Intelligence*, Cilt 22, s. 608-615, 2009.
- [5] Khushaba RN, Kodagoda S, Takruri M, Dissanayake G. "Toward improved control of prosthetic fingers using surface electromyogram (EMG) signals", *Expert Systems with Applications*, Cilt 39, s. 10731-10738, 2012.
- [6] Zardoshti-Kermani M, Wheeler BC, Badie K, Hashemi RM. "EMG Feature Evaluation for Movement Control of Upper Extremity Prosthesis", *IEEE Transactions on Rehabilitation Engineering*, Cilt 3, s. 324-333, 1995.
- [7] Englehart K, Hudgins B, Parker PA, Stevenson M. "Classification of the Myoelectric Signal Using Time-frequency Based Representations", *Medical Engineering & Physics*, Cilt 21, s. 431-438, 1999.
- [8] Chu JU, Maon I, Muu MS. "A Real-time EMG Pattern Recognition System Based on Linear and Non-linear Feature Projection for a Multifunction Myoelectric Hand", *IEEE Transactions on Biomedical Engineering*, Cilt 53, s. 2232-2239, 2006.
- [9] Xing K, Yang P, Huang J, Wang Y, Zhu Q. "A real-time EMG pattern recognition method for virtual myoelectric hand control", *Neurocomputing*, Cilt 136, s. 345-355, 2014.
- [10] Hoehn L, Niven I. "Averages on the Move", *Math. Mag.*, Cilt 58, s. 151-156, 1985.
- [11] Rangayyan RM. *Biomedical Signal Analysis: A Case-Study Approach*, IEEE Press, NJ, 2004.

- [12] Boostani R, Moradi MH. "Evaluation of the Forearm EMG Signal Features for the Control of a Prosthetic Hand", *Physiological Measurement*, Cilt 24, s. 309-319, 2003.
- [13] Engin M. "ECG Beat Classification Using Neuro-fuzzy Network", *Pattern Recognition Letters*, Cilt 25, s. 1715-1722, 2004.
- [14] Thakor NV. "Multiresolution Wavelet Analysis of Evoked Potentials", *IEEE Transactions on Biomedical Engineering*, Cilt 40, s. 1085-1093, 1993.
- [15] Al-Nashash HA, Thakor NV. "Monitoring of Global Cerebral Ischemia Using Wavelet Entropy Rate of Change", *IEEE Transactions on Biomedical Engineering*, Cilt 52, s. 2119-2122, 2005.
- [16] Yordano J, Kolev V, Rosso OA, Schürmann M, Sakowitz OW, Özgören M, Basar E. "Wavelet Entropy Analysis of Event-related Potentials Indicates Modality-independent Theta Dominance", *Journal of Neuroscience Methods*, Cilt 117, s. 99-109, 2002.
- [17] Ong S, Sridharan S, Yang CH, Moody MP. "Comparison of Four Distance Measures for Long Time Text-independent Speaker Identification", *International Symposium on Signal Processing and Its Applications – ISSPA*, s. 369-372, 1996.
- [18] Schaal S, Atkeson C. *From Isolation to Cooperation: An Alternative View of a System of Experts* In: D.S. Touretzky, M.C. Mozer, M.E. Hasselmo, eds., *Advances in Neural Information Processing Systems*, Cambridge: MIT Press, 1996.
- [19] Duda RO, Hart PE, Stork DG. *Pattern Classification*, John Wiley & Sons Inc., 2001.

**Erkan Zeki ENGİN; Yrd. Doç. Dr.**

Lisans derecesini 2000'de İzmir, Ege Üniversitesi Elektrik – Elektronik Mühendisliği Bölümü'nden, Yüksek Lisans derecesini 2003'de İzmir, Ege Üniversitesi Elektrik – Elektronik Mühendisliği Bölümü'nden, Doktora derecesini 2010 yılında İzmir, Ege Üniversitesi Elektrik – Elektronik Mühendisliği Bölümü'nden aldı. Şu anda, İzmir, Ege Üniversitesi Elektrik – Elektronik Mühendisliği Bölümü'nde Yardımcı Doçent olarak çalışmaktadır. Temel çalışma alanları Biyomedikal İşaret ve Görüntü İşleme, Tıbbi Sistem Tasarımı, Ses / Konuşma İşleme / Analizi üzerinedir.

*He got his bachelors' degree in the Electrical and Electronics Engineering Department at Ege University, Izmir/Turkey in 2000, his master degree in the Electrical and Electronics Engineering Department at Ege University, Izmir/Turkey in 2003, PhD degree in the Electrical and Electronics Engineering Department at Ege University, Izmir/Turkey in 2010. He is currently Assistant Professor at Electrical & Electronics Engineering Department of Ege University. His major areas of interests are: Biomedical Signal and Image Processing, Medical System Design, Voice / Speech Processing / Analysis.*

**Deniz TAŞAN; MSc**

Lisans derecesini 2002'de Kütahya, Dumlupınar Üniversitesi Elektrik – Elektronik Mühendisliği Bölümü'nden, Yüksek Lisans derecesini 2008'de İzmir, Ege Üniversitesi Elektrik – Elektronik Mühendisliği Bölümü'nden aldı. Şu anda, özel bir şirkette Kontrol Mühendisi olarak çalışmaktadır. Temel çalışma alanları Biyomedikal İşaret İşleme üzerinedir.

*He got his bachelors' degree in the Electrical and Electronics Engineering Department at Dumlupınar University, Kutahya/Turkey in 2002, his master degree in the Electrical and Electronics Engineering Department at Ege University, Izmir/Turkey in 2008. He is currently working as a control engineer in a private company. His major areas of interests are: Biomedical Signal Processing.*

**Mehmet ENGİN; Doç. Dr.**

Yüksek Lisans derecesini 1988'de İstanbul, Marmara Üniversitesi Elektronik Mühendisliği Bölümü'nden, Doktora derecesini 1996 yılında Kocaeli, Kocaeli Üniversitesi Elektronik Mühendisliği Bölümü'nden aldı. 1996 – 1999 yılları arasında Kocaeli, Kocaeli Üniversitesi Elektronik ve Bilgisayar Eğitimi Bölümü'nde Yardımcı Doçent olarak çalışmıştır. Şu anda, İzmir, Ege Üniversitesi Elektrik – Elektronik Mühendisliği Bölümü'nde Doçent olarak çalışmaktadır. Temel çalışma alanları Biyomedikal Optik Görüntüleme, Biyomedikal İşaret ve Görüntü İşleme, Tıbbi Sistem Tasarımı üzerinedir.

*He got his master degree in the Electronics Engineering Department at Kocaeli University, Kocaeli/Turkey in 1988, PhD degree in the Electronics Engineering Department at Kocaeli University, Kocaeli/Turkey in 1996. From 1996 to 1999, he was Assistant Professor at Electronic and Computer Education Department of Kocaeli University He is currently Associate Professor at Electrical & Electronics Engineering Department of Ege University. His major areas of interests are: Biomedical Optic Imaging, Biomedical Signal and Image Processing, Medical System Design.*