



Avuç açma/kapama hareketine dayalı EMG işaretlerin dalgacık dönüşümü tabanlı sınıflandırılması

Necmettin SEZGİN*,¹

¹ Batman Üniversitesi, Elektrik Elektronik Mühendisliği Bölümü, Batman
necmettin.sezgin@batman.edu.tr, ORCID: 0000-0002-4893-6014, Tel: (488) 217 41 41

Geliş: 06.04.2018, Kabul Tarihi: 30.04.2018

Öz

Bu çalışmada, elektromiyogram (EMG) işaretleri kullanılarak avuç açma/kapama hareketinin sınıflandırılması ile birlikte extensör ve flexör tendonların sınıflandırmadaki etkileri araştırılmıştır. Gelişen teknoloji ile birlikte, akıllı protez el ihtiyacı hızla artmaktadır. Bu amaçla ön kolun ön ve arka kısımlarından yüzey elektrotlarla toplam 32 kişiden ölçülen EMG işaretleri zaman frekans teknikleri ile analiz edilerek avuç aç/kapa hareketinin sınıflandırılması farklı sınıflandırıcılar ile gerçekleştirilmiştir. Ayrıca her bir kanaldan ve eş zamanlı elde edilen EMG işaretlerin sınıflandırma üzerindeki başarımları gösterilerek karşılaştırılmıştır.

Kısa süreli Fourier dönüşümünün yetersiz kaldığı EMG gibi durağan olmayan işaretlerin analizi için ayrık dalgacık dönüşümünün (ADD) kullanılması iyi bir çözümdür. ADD ile alt bantlarına ayrıştırılan işaretler yüksek frekanslarda yüksek zaman çözünürlüğü, düşük frekans çözünürlüğü ve düşük frekanslarda yüksek frekans çözünürlüğü, düşük zaman çözünürlüğü sağlar. ADD analizi sonucu öznelikler elde edilerek bu özellikler farklı sınıflandırıcıların eğitim ve testi için kullanıldı. Bütün veriler 10 kat çapraz doğrulama tekniği ile sınıflandırıcıların hem eğitim hem de test aşamalarında kullanılmıştır. Kullanılan sınıflandırıcılardan en iyi sonuç aşırı öğrenme makineleri (ELM) ile %97.25 olarak elde edildi.

Yapılan bu çalışma ile biyomedikal alanında yükselen teknoloji ile birlikte akıllı protez el yapımının geliştirilmesine katkı sağlanacağı düşünülmektedir.

Anahtar Kelimeler: EMG; Ayrık dalgacık dönüşümü; Aşırı öğrenme makinesi; Sınıflandırma

* Yazışmaların yapılacağı yazar

Giriş

Son yıllarda akıllı sistemlerin gelişimi, beraberinde bu sistemlerin biyomedikal mühendisliği alanında kullanma ihtiyacını getirmiştir. Akıllı yapay organlar, otomatik teşhis sistemleri bu alanda en çok gelişmeye ihtiyaç duyulan araştırma alanları olmuştur. Bu çalışmada, sağlıklı yetişkinlerden kayıt edilen kas işaretleri (Electromyogram-EMG) kullanılarak avuç açma/kapama hareketleri sınıflandırılmıştır. Ayrıca avuç açma/kapama esnasında extensör ve flexör kas demetlerinin sınıflandırma üzerindeki etkileri de incelenmiştir. Bu amaçla, 32 bireyden alınan iki kanal EMG işaretleri çalışmada kullanılmıştır. Elde edilen EMG işaretleri 500 Hz frekansa kadar işaret bileşenleri barındırmaktadır.

EMG işareti çok fonksiyonlu protezler, tekerlekli sandalye navigasyonu, yürüyüş oluşturma, kavrama kontrolü, sanal klavyeler ve hareket tabanlı ara yüzler gibi uygulamalar için bir kontrol işareti olarak kullanılmaktadır (Oskoei ve Hu, 2007).

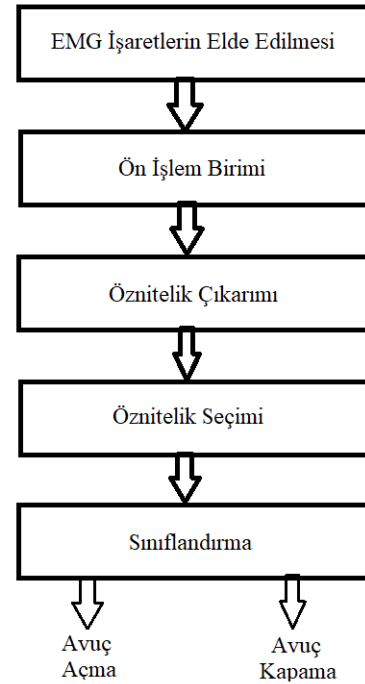
Literatüre bakıldığında el/bilek işlevleri ile bağımsız parmak hareketleri arasındaki ayırımı yapmak için sınıflandırma doğruluğu %95'e kadar ulaşmıştır (Hudgins vd., 1993; Englehart vd., 2001; Karlik vd., 2003).

Yapılan bazı çalışmalara bakıldığında el hareketlerinin kontrolü amaç edilerek kas işaretleri sınıflandırılmıştır. Bunlardan Mahdi ve Mehran (2007) bulanık çıkarım sistemi ile %95 oranında el hareketlerini EMG işaretini kullanarak sınıflandırmışlardır. Zihzeng ve arkadaşları (2004) yüzey elektrotlarla ön koldan alınan EMG işaretlerinin güç spektrumu katsayılarını ve Bayes istatistiksel algoritmasını kullanarak sınıflandırma işlemi yapmışlar ve %84 oranında başarı elde etmişlerdir. Engin ve arkadaşları (2015) 6 farklı el hareketini EMG işaretlerini kullanarak doğrusal ayırma analizi sınıflandırıcısı ile %94,68±3,58 doğrulukta başarı elde etmişlerdir.

Diğer taraftan Zeghib ve arkadaşları (2005) başparmak, işaret parmak ve orta parmak

hareketlerini ön koldan kayıt edilen EMG işaretlerini kullanarak bulanık sistem sınıflandırıcısı ile %92,16 doğrulukta sınıflandırmayı başarmışlardır. EMG işareti kullanılarak yapılan parmak hareketi sınıflandırmasında %94.6 başarı gösterilmiştir (Sezgin vd. 2017).

Yapılan çalışmalardan farklı olarak bu çalışmada, ham olarak BIOPAC MP150 kayıt cihazı ile kayıt edilen EMG işaretleri ön işlemden geçirildikten sonra öznelikleri oluşturulmuştur. Elde edilen öznelikler aşırı öğrenme makinesi ile eğitilip test edilmiştir. Bu yöntemle elde edilen başarı oranı en yüksek %97.25 ile her iki kanala ait özelliklerin kullanılmasıyla gerçekleşmiştir. Ayrıca her bir kanal için ayrı ayrı sınıflandırma başarı oranları gösterilerek extensör ve flexör tendonların bulunduğu deri üzerinden kayıt edilen EMG işaretleri ile de sınıflandırıcı performansı üzerindeki etkileri gösterilmiştir. Her iki kanal EMG işaretleri için sınıflandırıcı başarıları karşılaştırıldığında avuç kapatmada flexör işaretleri daha etkili iken avuç açmada ise extensör işaretlerin daha etkili olduğu görülmüştür. Çalışmanın genel blok diyagramı Şekil 1 de gösterilmiştir.



Şekil 1. Önerilen modelin blok diyagramı.

Blok diyagramda gösterilen her aşama aşağıda açıklanmıştır.

EMG işaretlerin elde edilmesi: Burada toplam 32 yetişkin bireyden ve iki kanaldan yüzey EMG işaretleri saniyede 1000 örnek alınarak kayıt edilmiştir.

Ön işlem birimi: Bu bölümde ham EMG işaretleri 1 saniyelik pencereler ile bölütlere ayrıştırılmıştır. Böylece bütün denekler için her iki kanala ait EMG işaretleri bölütlere ayrıştırılmıştır.

Öznitelik Çıkarımı: Çalışmanın bu bölümünde 8 seviyeli ADD sonucu oluşan alt bantlardaki bazı istatistiksel değerler hesaplanarak öznitelikler oluşturuldu.

Öznitelik seçimi: Elde edilen özniteliklerden sınıflandırmada en fazla etki değerine sahip özellikler ELM yöntemi ile seçildi. ELM ile öznitelik seçimi metodu (Sezgin, 2017) çalışmasında detaylı bir şekilde açıklanmıştır.


Sınıflandırma: Bu son aşamada seçilen özellikler matrisi sınıflandırıcıların eğitim ve test aşamalarında kullanılmıştır. Bütün veriler için seçilen özellikler hem eğitim hem de test aşamalarında 10 kat çapraz doğrulama yöntemine göre kullanılmıştır.

Materyal ve Yöntem

Veri Toplama


Bu çalışmada kullanılan veriler Batman Üniversitesi Elektrik Elektronik Mühendisliği Bölümü, Biyomedikal Araştırma Laboratuvarında kayıt edilmiştir. Kayıt için BIOPAC marka MP150 model cihaz ile eş zamanlı iki kanaldan yüzey EMG işaretleri saniyede 1000 örnek alınarak sayısallaştırılmıştır. Önkolun arka kısmında bulunan ve radyal sinir tarafından kontrol edilen kaslar extensör niteliktedir. Önkolun ön

kısımında bulunan kaslar ise medyan sinir ve ulnar sinirce kontrol edilir ve flexor niteliktedir. Veri kayıt sistemi Şekil 2’de gösterilmiştir. Şekil 2’de gösterilen kayıt grafiğinde kanal 1 için extensör ve kanal 2 için de flexor nitelikteki kas aktivitelerine dayalı EMG işaretleri ölçülmüştür. EMG işaretlerini kuvvetlendirmek için MP150 veri kayıt sistemi ile birlikte 2000 kazançla ayarlanmış enstrümantasyon kuvvetlendiricisi kullanılmıştır. Çalışmada kullanılmak üzere yaş ortalamaları 22 olan 18 erkek ve 14 kadın olmak üzere toplam 32 kişiden ve her bir kişiden yaklaşık 10’ar saniyelik 5’er örnek alınmıştır.




Şekil 2. Yüzey EMG veri kayıt sistemi

MP150 kayıt sisteminin el açma/kapama esnasında EMG işaretlerin kanal 1 ve kanal 2’den kayıt edilmesi Şekil 3’te gösterilmiştir.



Şekil 3. EMG işaretlerinin kayıt edilmesi esnasında MP150 cihazının ara yüzü.

Kayıt edilen ham veriler el aç/kapa hareketinin en az bir tam periyodunu barındıran 1'er saniyelik bölütler halinde eş zamanlı kayıt edilen her iki kanal için ayrıştırılmıştır. Bu şekilde her bir deneğe ait 100 (2 kanala ait 5'er örnek ölçüm ve her örnek için 10'ar saniyelik ölçümler) örnek oluşturulmuştur. Kanal 2'den ölçülen flexör tendon üzerinden yapılan bir kayıt için elektrot bağlantısı Şekil 4'te gösterilmektedir.



Şekil 4. Flexör tendon üzerinden EMG ölçümü gösterimi.

Ayrık dalgacık dönüşümü

Kısa süreli Fourier dönüşümünden (KSFD) farklı olarak dalgacık dönüşümü durağan olmayan işaretlere başarılı bir şekilde uygulanabilmektedir. Dalgacık dönüşümü ile yüksek frekanslarda yüksek zaman çözünürlüğü, düşük frekans çözünürlüğü ve düşük frekanslarda ise düşük zaman çözünürlüğü ile yüksek frekans çözünürlüğü sağlanır. Ayrık dalgacık dönüşümü (ADD) dalgacık dönüşümünün özel bir durumu olup aşağıdaki ifade ile tanımlanır (Koçyiğit ve Korurek, 2005),

$$W(j, k) = \sum_j \sum_k x(k) 2^{-j/2} \psi(2^{-j}n - k) \quad (1)$$

Burada x ayrık işareti ve ψ ana dalgacığı ifade etmektedir. ADD Mallat algoritması mantığı ile çalışarak işareti, yaklaşıklık ve ayrıntı katsayılarına ayrıştırarak işaretin farklı frekans bantlarında farklı çözünürlükler sağlar (Mallat, 1989).

ADD ile zamandaki bir işaret yüksek ve alçak frekans geçiren filtreler ile iki frekans bandına ayrıştırılır. Bu şekilde her alt bant içinde filtreler kullanılarak istenilen bantlardaki frekans bileşenleri elde edilir. Her bir seviye için ayrıştırma işlemi aşağıda verilen iki denklem ile gerçekleştirilmektedir (Koçyiğit ve Korurek, 2005).

$$Y_H[k] = \sum_n x[n]g[2k - n] \quad (2)$$

$$Y_L[k] = \sum_n x[n]h[2k - n] \quad (3)$$

Burada Y_H ve Y_L , 2 ile alt örnekleme sonrası sırasıyla yüksek geçiren (g) ve alçak geçiren (h) filtre çıkışlarıdır.

Literatürde farklı dalgacık çeşitleri mevcuttur. Bunlardan bazıları, Daubechies, Symlet, Coiflet, Biortogonal dalgacıklarıdır. EMG işaretinin yapısı ve şekli itibari ile daha uygun olan Daubechies ana dalgacığı bu çalışmada kullanılmıştır.

ADD özniteliklerinde 1 saniyelik pencerelerin dalgacık dönüşümü hesaplanmış ve öznitelikler elde edilmiştir. Öznitelik çıkarımında, ADD katsayıları, seçilen ana dalgacık Db4 kullanılarak her bölüt için hesaplanmıştır. Bu şekilde işaretler, 8 ayrıntı ve 1 yaklaşıklık katsayısı oluşturacak şekilde 8 seviyeye kadar indirilmiştir. 8 seviyeli ADD sonucu oluşan bu katsayıların ortalama, varyans, standart sapma, etkin değer, entropi, maksimum, minimum gibi istatistiksel değerleri kullanılarak elde edilen öznitelik vektörünün uzunluğu $9 \times 7 = 63$ ' dir. ADD ile EMG işaretleri en düşük alt bant frekanslarına ayrıştırılmış ve bütün olasılıklar için özellikler çıkarılarak test edilmiştir ve en iyi sonucun 8. seviye ADD alt banlarındaki dalgacık

katsayılarına ait özelliklerin kullanılması ile elde edildiği görülmüştür.

Aşırı öğrenme makineleri

Aşırı öğrenme makineleri (ELM) Huang ve arkadaşları (2006) tarafından ortaya konulan tek gizli katmanlı, ileri beslemeli yapay sinir ağıdır (YSA). ELM ağında giriş katmanı ile gizli katman arasındaki ağırlıklar rastgele üretilirken, gizli katman ile çıkış katman arasındaki ağırlıklar analitiksel olarak hesaplanmaktadır. ELM ağında hücreleri aktivite etmek için Sigmoid, Sine, Gaussian ve Hard-limit gibi aktivasyon fonksiyonları kullanılmaktadır (Huang vd., 2006). ELM'de başarılı bir performans elde etmek için ağı yüksek öğrenme oranı ile arzu edilen en az hataya yakınsaması gerekir. İleri beslemeli ağı yakınsaması, seçilen öğrenme oranına ve momentuma bağlıdır. ELM'nin diğer algoritmalara göre en büyük avantajı yerel minimumlara yakınsamamasıdır (Huang vd., 2006).

Bir $X = \{\mathbf{x}_j\}$ veri seti için ağı çıkışı $Y = \{\mathbf{y}_j\}$ olsun. Ağı gerçek çıkışı ise $O = \{\mathbf{o}_j\}$ şeklinde ve $j \in [1, N]$ giriş/çıkış vektör sayısını göstermektedir. Bu durumda gizli katmanda M hücre bulunan ağı matematiksel ifadesi şu şekilde olur (Rong vd., 2008),

$$\sum_{i=1}^M \beta_i g(\mathbf{w}_i \mathbf{x}_j + b_i) = \mathbf{o}_j \quad ; \quad j = 1, 2, 3, \dots, N \quad (4)$$

Burada $\mathbf{x}_j = [x_{j1}, x_{j2}, x_{j3}, \dots, x_{jn}]^T$ ve $\mathbf{o}_j = [o_{j1}, o_{j2}, o_{j3}, \dots, o_{jm}]^T$ sırasıyla i . döngüdeki giriş ve çıkış vektörleri ve b_i bias değeri ifade etmektedir. $\mathbf{w}_i = [w_{i1}, w_{i2}, w_{i3}, \dots, w_{in}]$ giriş katmanı ile gizli katman arasındaki ağırlıklardır. β_i değerleri de gizli katman ile çıkış katmanı arasında hesaplanan ağırlıklardır. Denklemdaki bu değerler $\mathbf{x}_j \in \mathbb{R}^n$; $\mathbf{o}_j \in \mathbb{R}^m$; $\mathbf{w}_i \in \mathbb{R}^n$ ve ağırlık matrisi $\mathbf{w} \in \mathbb{R}^m \times \mathbb{R}^n$ şeklinde tanımlıdır ve $i \in [1, m]$, $j \in [1, n]$ değerlerini alır. Denklemdaki $g(\cdot)$ aktivasyon fonksiyonudur. Ağı modelinde amaç maliyet fonksiyonunu en aza indirmek

olduğundan β değerleri bunun için ayarlanmaktadır. Bu durumda ağı çıkışındaki toplam hataların karesi şu şekilde ifade edilir,

$$\sum_{j=1}^N (o_j - y_j)^2 \quad (5)$$

ELM ağı için çıkışı veren denklem aşağıdaki gibi de ifade edilebilir (Huang vd., 2006),

$$\mathbf{H}\beta = \mathbf{Y} \quad (6)$$

Burada \mathbf{H} , β and \mathbf{Y} (Rong vd., 2008) de tanımlandığı gibi sırasıyla gizli katman çıkış matrisi, gizli katman ile çıkış katmanı arasındaki ağırlıklar ve çıkış değerleridir. Denklemi tekrar ifade etmek gerekirse,

$$\hat{\beta} = \mathbf{H}^+ \mathbf{Y} \quad (7)$$

burada \mathbf{H}^+ , \mathbf{H} matrisinin genelleştirilmiş tersidir ve *Moore–Penrose* matrisi olarak tanımlanmaktadır (Serre, 2002; Rao ve Mitra, 1971). ELM üç adımda özetlenebilir (Huang vd., 2006; Liang vd., 2006),

1. Giriş katmanı ile gizli katman arasındaki ağırlıklar $\mathbf{w}_i = [w_{i1}, w_{i2}, w_{i3}, \dots, w_{in}]$ ve b_i değeri rastgele seçilir.
2. Gizli katman hücrelerine ait çıkış matrisi \mathbf{H} ve onun tersi \mathbf{H}^+ matrisi bulunur.
3. Gizli katman ile çıkış arasındaki ağırlıklar $\hat{\beta} = \mathbf{H}^+ \mathbf{Y}$ ifadesi ile hesaplanır.

Deneysel çalışma ve başarımlar

Bu çalışmada önerilen yöntemle avuç açma/kapama hareketi ile EMG işaretleri iki gruba ayrıştırılmıştır. Bunun için sınıflandırma aşamaları sırasıyla şu işlemlerden geçmiştir: İlk olarak, bütün denekler için kayıt edilen EMG işaretleri 1 saniyelik epoklara bölünmüştür. İkinci olarak, bölütlenmiş EMG işaretleri ADD ile frekans alt bantlarına ayrıştırılmıştır. Daha sonra her alt banttaki dalgacık katsayılarına ait bazı istatistiksel veriler hesaplanarak özellik matrisi oluşturuldu. Son aşamada ise, elde edilen


özellik matrisi sınıflandırıcıların girişine verilerek avuç açma/kapama'ya dayalı olarak sınıflandırma gerçekleştirilmiştir. Çalışmada, alt bant frekanslardaki dalgacık katsayılarına ait ortalama, varyans, standart sapma, etkin değer, entropi, maksimum ve minimum değerleri bulunarak özellik matrisi elde edildi. Her bir istatistiksel özellik EMG işaretine ait kendine özgü frekans ve faz bilgisine sahiptir. Bu şekilde her bir denek için 100x63 boyutunda özellik matrisleri oluşturulmuştur. Tablo 1'de her bir özelliğin sınıflandırmadaki etkisi gösterilmiştir. Kullanılan özelliklerden varyansın hem avuç açmada hem de kapatmada en yüksek etki

değerine sahip olduğu görülmüştür. Düşük etki değerlerine sahip olmaları ve elde edilen en iyi özelliklerin seçimi dolayısıyla maksimum ve minimum özellikler ağ eğitim ve testlerinde kullanılmamıştır. Dolayısıyla elde edilen özellik matrisleri her bir denek için 100x45 boyutuna indirilmiştir.

Örnek gösterim amaçlı, bir deneğe ait avuç açma/kapama esnasında extensör ve flexör tendonları üzerinden ölçülen EMG işaretleri Şekil 5'te gösterilmiştir.

Tablo 1. Avuç açma/kapama için elde edilen özelliklerin etki değeri.


Özellik	Avuç açma	Avuç kapama
Ortalama	3.55	3.62
Varyans	7.45	6.84
Standart sapma	3.86	3.99
Etkin değer	4.25	3.86
Entropi	0.82	0.88
Maksimum	0.45	0.68
Minimum	0.41	0.23




Şekil 5. Avuç aç/kapa esnasında (a) extensör ve (b) flexör tendonlarına ait EMG işaretleri.

Şekil 5'teki işarete ait ADD sonucu elde edilen zaman frekans gösterimi her bir EMG kanalı için

şirısıyla Şekil 6 (extensör) ve Şekil 7'de (flexör) gösterilmiştir.



Şekil 6. Kanal_1 (extensör) zaman-frekans gösterimi



Şekil 7. Kanal_2 (flexör) zaman-frekans gösterimi

Şekil 6 ve 7 karşılaştırıldığında eş zamanlı kayıt edilen kanal 1 ve kanal 2'ye ait EMG

işaretlerinin zamandaki frekans dağılımları farklılık göstermektedir. Kanal 2'de dalgacık katsayıları daha yüksek frekanslarda ve daha geniş bir bant aralığına dağılırken, kanal 1'de alçak düşük frekanslarda daha dar bir bant aralığında fakat daha yüksek değerlerde dalgacık katsayıları kendini göstermiştir. Bu durum her iki kanalın avuç açma/kapama ayırımında farklı etkilere sahip olduğunun bir göstergesidir.

Karşılaştırma amaçlı ELM'de kullanılan özelliklerin tamamı SVM ile de eğitildi ve test edildi. ELM ve SVM sınıflandırıcıları sırasıyla Tablo 2 ve 3'te verilen parametreler ile eğitildi ve test edildi. EMG işaretlerin işlenmesi ve sınıflandırıcıların eğitim ve testleri MATLAB programı kullanılarak Windows 7, Core i7 CPU, 2.50 GHz ve 16 GB RAM özelliklerine sahip bilgisayarda gerçekleştirildi.

Tablo 2. ELM eğitim parametreleri

Ağ Parametreleri	Değer
Gizli katman hücre sayısı	120
Aktivasyon fonksiyonu	Log-sigmoid
Eğitim süresi	0.015sn

Tablo 3. SVM eğitim parametreleri

Ağ Parametreleri	Değer
Destek vektör sayısı	110
Aktivasyon fonksiyonu	Gaussian
Çekirdek yayılım sabiti	3.0
Eğitim süresi	2.33sn

ELM ağı birçok aktivasyon fonksiyonu kullanılarak test edildi. Kullanılan aktivasyon fonksiyonlarından en iyi başarımın Sigmoid fonksiyonu (Mitchell, 1997) ile elde edildiği

görüldü. Kullanılan bütün aktivasyon fonksiyonlarına ait ELM'deki başarım oranları Tablo 4'te gösterilmiştir.

Table 4. Farklı aktivasyon fonksiyonları için ELM başarımları oranları.

Aktivasyon fonksiyonu	Performans (%)	Test işlem süresi (sn)
Sigmoid	97.25	<0.00001
Sine	93.75	<0.00001
Hardlim	96.44	<0.00001
Triangular Basis	89.06	<0.00001
Radial basis	93.75	<0.00001

Sınıflandırıcıların başarımları duyarlılık, özgüllük ve doğruluk yönünden test edilerek gösterilmiştir. Bu parametreler aşağıdaki denklemler ile ölçülmektedir.

$$Duyarluluk = \frac{TP}{TP+FN} \quad (14)$$

$$Özgüllük = \frac{TN}{TN+FP} \quad (15)$$

$$Doğruluk = \frac{TP+TN}{TP+FP+TN+FN} \quad (16)$$

Burada, *TP* doğru pozitif, *TN* doğru negatif, *FP* yanlış pozitif ve *FN* yanlış negatif ifade etmektedir.

Her iki sınıflandırıcı için de 10 kat çapraz doğrulama yöntemine göre test sonuçları Tablo

5'te gösterilmiştir. Tablo 5'te hem kanal 1 (extensör) hem kanal 2 (flexör) hem de her iki kanal ile birlikte ölçülen EMG işaretleri değerlendirilerek sınıflandırma başarımları ölçüleri gösterilmiştir. Sonuçlara bakıldığında her iki kanalın birlikte değerlendirilmesi ile en yüksek başarımları ELM ile %97.25 olarak elde edildiği görülmektedir. Diğer taraftan yine ELM ile hem kanal 1 için hem de kanal 2 için SVM'ye göre daha yüksek başarımları elde edilmiştir. Fakat kanalların ayrı değerlendirilmesi ile elde edilen başarımları sonuçları, kanalların birlikte değerlendirilmeleri sonucu elde edilen başarımları sonucundan daha düşük çıktığı görülmüştür. Kanal 1 ve kanal 2 için en iyi sınıflandırma başarımları ELM ile sırasıyla %95.12 ve %94.66 olarak bulunmuştur.

Tablo 5. ELM ve SVM için 10 kat çapraz doğrulamaya göre test sonuçları

Ağ Parametreleri	Her iki kanal birlikte		Kanal 1 (Extensör)		Kanal 2 (Flexör)	
	ELM	SVM	ELM	SVM	ELM	SVM
Duyarluluk (%)	99.10	98.25	98.99	98.10	98.87	97.33
Özgüllük (%)	98.84	96.09	98.76	95.56	97.25	96.74
Doğruluk (%)	97.25	94.55	95.12	92.01	94.66	92.34

Sonuçlar ve tartışma

Yapılan bu çalışmada insan avucunu açık kapatarak kayıt edilen EMG işaretlerin sınıflandırılması gerçekleştirilmiştir. Toplam 32 denekten alınan kayıtlar değerlendirilerek ELM ve SVM sınıflandırıcıları eğitilip test edilmiştir.

Bütün test sonuçları Tablo 5'te gösterilmektedir. Test sonuçlarına göre en iyi başarımları ELM algoritması ile her iki kanal EMG işaretin beraber kullanıldığı durumda %97.25 olarak gerçekleştirildiği görüldü. Karşılaştırma amaçlı

olarak SVM ile de veriler test edildi. SVM ile ağın eğitimi ve test süreleri ELM'ye göre daha kısa sürmesine rağmen test başarı oranı daha düşük çıkmıştır. Bu durum ile EMG gibi karmaşık işaretlerden elde edilen özelliklerin kullanılmasıyla ELM algoritmasının SVM'ye göre daha iyi doğruluk sonuçları verdiği sonucuna varılmıştır. Ayrıca her bir kanaldan kayıt edilen EMG işaretlerine ait özellikler de ayrı ayrı sınıflandırıcılarda eğitilip test edildi. Kanalların bağımsız olarak kullanılmasıyla ağ üzerindeki başarı oranları, her iki kanalın birlikte kullanılmasıyla elde edilen başarı oranlarına göre daha düşük çıkmıştır. Bu da hem extensör hem de flexör tendonların birlikte değerlendirilmesi ile avuç açma/kapama sınıflandırması üzerinde daha etkili olduğunu göstermiştir. Gerçekleştirilen bu çalışma ile elini kaybetmiş kişiler için akıllı protez el yapımında kullanılacak bir çalışma olacağı düşünülmektedir. İleriki çalışmalarda daha fazla kanal ile EMG ölçümü yapılarak verilerden farklı özellikler de seçilip, elin 360 derece içerisinde farklı pozisyonlara hareketinin sınıflandırılması hedeflenmektedir.

Kaynaklar

- Engin, E.Z., Taşan, D., Engin, M., (2015) Çok İşlevli Protez El Kontrolü İçin Önkol Elektromiyografi İşaretlerinin Sınıflandırılması, *Dokuz Eylül Üniversitesi Fen ve Mühendislik Dergisi*, vol.17(1), sayı:49, sayfa:35-46.
- Englehart, K., Hudgins, B. and Parker, P. A., (2001) A Wavelet-Based Continuous Classification Scheme for Multifunction Myoelectric Control, *IEEE Trans. Biomed. Eng.*, vol. 48, pp. 302-311,
- Huang, G.B., Zhu, Q.Y., Siew, C.K., (2006) Extreme learning machine: theory and applications. *Neurocomputing*, vol.70 (1-3) pp. 489-501.
- Hudgins, B., Parker, P. A. and Scott, R. N., (1993) A New Strategy for Multifunction Myoelectric Control, *IEEE Trnas. Biomed. Eng.*, vol. 40, pp. 82-94.
- Karlık, B., Tokhi, M. O. and Alci, M., (2003) A Fuzzy Clustering Neural Network Architecture for Multifunction Upper-Limb Prostheses, *IEEE Trans. Biomed. Eng.*, vol. 50, pp. 1255-1261.
- Koçyiğit, Y., Korurek, M., (2005) EMG işaretlerini dalgacık dönüşümü ve bulanık mantık sınıflayıcı kullanarak sınıflama, *İTÜ Mühendislik Dergisi*, vol. 4, no. 3 pp.25-31.
- Liang, N.Y., Saratchandran, P., Huang, G.P., Sundararajan, N., (2006) Classification of mental tasks from EEG signals using extreme learning machine, *Int. J. Neural Systems*. Vol.16 (1), pp. 29-38.
- Mahdi, K. and Mehran, J., (2007), A novel approach to recognize hand movements via sEMG patterns, Engineering in Medicine and Biology Society, 29th Annual International Conference of the IEEE.
- Mallat, S. (1989), A theory for multiresolution signal decomposition: the wavelet representation, *IEEE Pattern Anal. and Machine Intell.*, vol. 11, no. 7, pp. 674-693.
- Mitchell, T., (1997) Machine Learning, McGraw-Hill.
- Oskoei, M. A. and Hu, H., (2007) Myoelectric control systems - a survey, *Elsevier - Biomedical Signal Processing and Control*, vol. 2, no. 4, pp. 275-294.
- Rao, C.R., Mitra, S.K., (1971) Generalized Inverse of Matrices and its Applications, Wiley, New York.
- Rong, H.J., Ong, Y.S., Tan, A.H., Zhu, Z., (2008) A fast pruned-extreme learning machine for classification problem. *Neurocomputing*, vol.72, pp.359-366.
- Serre, D., (2002) Matrices: Theory and Applications, Springer, New York.
- Sezgin, N., Ertuğrul, Ö.F., Tekin, R., Tağluk, M.E., (2017) Classification of hand opening/closing and fingers by using two channel surface EMG signal, *International Artificial Intelligence and Data Processing Symposium (IDAP)*, 16-17 Sept., Malatya, Turkey.
- Sezgin, N. (2017) A new hand finger movements' classification system based on bicoherence analysis of two-channel surface EMG signals, *Neural Comput & Applic*, <https://doi.org/10.1007/s00521-017-3286-z>
- Zeghib, A., Palis, F., Ben-Ouedzou, F., (2005) EMG-based Finger Movement Classification Using Transparent Fuzzy System, *EUSFLAT-LFA*, pp.816-821.
- Zhizeng, L., Xiaoliang, R., Yutao Z., (2004) Multi-pattern recognition of the forearm movement based on SEMG, *International Conference on Information Acquisition*, IEEE.

Classification of hand opening/closing based discrete wavelet transform by using EMG

Extended abstract

In this study, the classification of hand opening / closing movement as well as the effects of extensor and flexor tendons on the classification were investigated using electromyogram (EMG) signal. With the evolving technology, the need for intelligent prosthetic hand is rapidly increasing. For this purpose EMG signals measured from front and back parts of frontal arm with 2 electrodes were analyzed with time frequency techniques and classification of hand open/close movement was performed with different classifiers. It was also compared against each channel and concurrently showing achievement on the classification of EMG signals. All EMG signals used in this study were obtained from biomedical research laboratory at Batman University. 32 subjects were used in the consideration. For each subject 5 samples which were about 10 seconds long each of the EMG signal were recorded by using BIOPAC MP150 device. All data were recorded with ethical standards. The EMG data were recorded by a sample frequency of 1000 which satisfy Nyquist criteria.

It is a good solution to use discrete wavelet transform (DWT) for the analysis of non-stationary signals such as EMG where short-time Fourier transform (STFT) is insufficient. By using wavelet transform, a high time resolution as well as low frequency resolution are provided at high frequencies and a high frequency resolution as well as low time resolution are provided at low frequencies. With advantages of DWT, in this study, segmented 1-second EMG samples were separated to its frequency sub bands for a level of 8. So, 8 sub bands for detailed and 1 band for approximation were obtained after application of DWT. By this technique 9 sub bands DWT coefficients were determined. Then, the features such as mean, variance, standard deviation, RMS, entropy, maximum and

minimum of sub bands' wavelet coefficients were determined for all samples and feature matrix were constructed.

The obtained features, then, fed to the input of the classifiers in order to classify hand opening/closing. Also the effect of each channel on the classification results were obtained by using extensor and flexor tendon's EMG, separately. All features were used both in the training and testing phases of the networks by using 10-fold cross validation method. Two classification methods namely extreme learning machines (ELM) and support vector machines (SVM) were used to classify hand opening/closing. The ELM has an advantage over some other machine learning methods. ELM has single hidden layer. So, an ELM network may be constructed more easily. The weights between input layer and hidden layer are chosen randomly while the weights between hidden layer and output layer are determined analytically. The best accuracy was obtained 97.25% by using ELM network. The accuracy result for the SVM was obtained as 94.55%. Different activation functions were used in the ELM network and the best result was obtained by using sigmoid activation function. The effect of the extracted features on the accuracy results were also determined by ELM and it was shown that the variance has higher effect on the classification results.

The results obtained from this study may be used to improve intelligent prosthesis hand.

Keywords: *EMG, Discrete wavelet transform, Extreme learning machines, Classification.*