



EMG Sinyallerinin Anlamlandırılması için Radyal Fonksiyonlu Yapay Sınır Ağı Tasarımı

Radial Functional Neural Network Design For Recognition Of EMG Signals

¹Beyda TAŞAR, ¹Alper Kadir TANYILDIZI, ¹Oğuz YAKUT, ²Arif GÜLTEN

¹Fırat Üniversitesi, Mekatronik Mühendisliği Bölümü, Elazığ, TÜRKİYE
²Fırat Üniversitesi, Elektrik-Elektronik Mühendisliği Bölümü, Elazığ, TÜRKİYE

Başvuru/Received: 20/03/2018

Kabul/Accepted: 17/06/2018

Son Versiyon/Final Version: 29/06/2018

Öz

Son yıllarda, insan ve protez cihazlar arasındaki bilişsel etkileşim oldukça popüler araştırma alanlarından biridir. Elektromiyografi (EMG) yöntemi, hareket örüntülerinin (pattern) anlamlandırılması için oldukça etkili bir yöntemdir. Kasların nöromasküler aktivitesi hakkında bilgiler taşıyan EMG sinyallerinin, kişilerin hareket isteğinin algılanmasında kullanımı etkin sonuçlar vermektedir. Bu makale kapsamında yüzey elektromiyografi yöntemi ile kişilerin ltı adet el hareket örüntülerinin anlamlandırılması işlemi gerçekleştirilmiştir. Her bir parmak aktivitesini ayrı ayrı ifade edecek şekilde biyoelektrik sinyaller dört kanallı EMG sensör vasıtası ile kaydedilmiştir. Kaydedilen biyoelektrik sinyaller bir dizi ön işleme tabi tutulmuş ve sinyallerin seçilen zaman domeni öznelikleri hesaplanmıştır. EMG özelliklerinin sınıflandırılması için Radyal Fonksiyonlu Yapay Sinir Ağı (RFYSA) ve İleri Yayılımlı Yapay Sinir Ağı (İYSA) algoritmaları kullanılmış ve sırası ile % 94.81, %94.05 başarı elde edilmiştir. Çalışmaya ait sonuçlar literatürde yer alan çalışmalar ile karşılaştırmalı olarak yorumlanmıştır.

Anahtar Kelimeler

“Yapay sinir ağları; EMG, el hareketlerinin anlamlandırılması,RFYSA,İYSA”

Abstract

In recent years, the cognitive interaction between human and prosthetic devices is one of the most popular research areas. Electromyography (EMG) method is a very effective method for recognition of motion patterns. EMG signals, which have information about the neuromuscular activity of the muscles, are very common in perceiving people's motion desire. In this article, the recognition of the hand patterns of the people was realized by the surface lectromyography method. The bioelectric signals were recorded with four-channel EMG sensor, which expresses each finger activity separately. The recorded bioelectrical signals were pre-processed and then the selected time domain attributes of the signals were calculated. Radial Functional Neural Network (RFNN) and Feed Forward Neural Network (FFNN) algorithms were used to classify the EMG features and 94.81% and 94.05% success rate respectively. The results of the study are interpreted comparatively with the studies in the literature.

Key Words

“Artificial neural network; EMG, motion recognition,RFNN,FFNN”

1. GİRİŞ

İnsanlar yaralanmalar, kazalar ve tıbbi durumlar nedeniyle uzuv kaybı yaşayabilirler. Ayrıca, kalıtsal bozukluklar nedeniyle bazı insanlar doğuştan eksik uzuv ile de doğabilirler. Kayıp uzvun şekil ve işlevleri yerine getirmek amacı ile tasarlanan cihazlar protez olarak isimlendirilir. Biyolojik elin yapısı ve işlevi yüksek serbestlik derecesine (bağımsız hareket eklemine) sahip olduğu için oldukça karmaşıktır. İnsan elinin hareketlerini taklit eden protezlerin de aynı yeteneklere sahip olması beklenir. Başarılı bir protez için dikkate alınması gereken ana faktörler;

- protezin fiziksel tasarımı,
- etkin konum ve kuvvet kontrolü ve
- başarılı bir kullanıcı-protez bilişsel etkileşim ağıdır.

Bununla birlikte, bir protez cihaz ne kadar iyi tasarlanmış, tasarlanmış olursa olsun, kullanıcı- protez cihaz arasındaki bilişsel etkileşim ağı etkin bir şekilde kurulamaz ise kişi protez elini başarılı bir şekilde kullanamaz. Bilişsel etkileşim ağının kurulmasında kullanılan en etkin yöntemlerden biri biyoelektrik sinyallerin kullanımıdır. EMG sinyalleri kasların nöromusküler hakkında bilgiler taşır ve protez cihazlarda kontrol sinyali olarak kullanmak için uygundur.

2. ÖNCEKİ ÇALIŞMALAR

EMG sinyalleri periyodik veya deterministik olmayan analog sinyallerdir (Rodriguez et al, 2016). EMG sinyalleri belli zaman aralıklarında tekrarlanmaz ve bir kayıt periyodu sırasında elde edilen EMG sinyallerini tek bir matematiksel ifade ile temsil edilemez (Raez et al, 2006). EMG sinyalleri durağan olmayan sinyallerdir (Konrad, 2005). EMG sinyalinin kaydedilmesi sırasında, ortamdaki ses, manyetik etkiler ve elektronik kayıt cihazındaki titreşim gürültü kaynağı oluşturur ve ham EMG sinyalinin karakteristiğini etkiler. EMG sinyallerinin anlamlandırılması için yüksek mertebeden istatistikler, spektral ve dalgacık analizi, vb. sinyal işleme teknikleri gereklidir (Dobrowolski et. al, 2010). EMG sinyallerinin anlamlandırılması işlemi temelde üç aşamada gerçekleştirilir . Bu aşamalar sırası ile ön-işleme, öznitelik çıkarımı ve sınıflandırmadır. Literatürde verilerin örnekleme, doğrultulması ve filtrelenmesini içeren ön işleme adımı, neredeyse tüm çalışmalarda oldukça benzerdir. Bununla birlikte, araştırmacılar tarafından öznitelik çıkarımı ve sınıflandırma adımlarında farklı yaklaşımlar ve yöntemler kullanılmıştır (Pagnagiotacopulos et. al, 1998).

Sınıflandırma algoritmasına ham EMG sinyali uygulandığında sınıflandırıcı performansı çok düşük olacağından, araştırmacılar, performansı artırmak adına sınıflandırıcıya EMG sinyalinin özniteliklerini girdi olarak vermişlerdir. (Zardoshti-Kermani et.al, 1995). EMG sinyalinin hesaplanan öznitelikleri üç grupta incelenmektedir. Bunlar zaman domeni öznitelikleri, frekans domeni öznitelikleri ve zaman-frekans domeni öznitelikleridir. yEMG'nin zaman domeni öznitelikleri Hudgins ve ark. tarafından tanımlanmıştır (1993). Hudgins ve ark bir biyoelektrik sinyali; sinyalin ortalama değeri, mutlak değeri, eğimi, eğimin işaretindeki değişim, dalga boyu ve sinyalin sıfır geçiş sayısına göre ifade etmişlerdir (Hudgins et. al, 1993; Englehart et.al, 2000; Englehart et.al, 2003). Bu öznitelikler "Hudgins öznitelikleri" olarak bilinir. Bu özellik kümesi sınıflandırıcıya girdi olarak verildiğinde, sınıflandırma başarısı ham sinyalden (İbrahimi et al, 2012; Rajesh et al, 2009) çok daha yüksektir. Englehart ve ark. (1999) EMG sinyallerinin sınıflandırması için zaman-frekans alanı özniteliklerini kullanmış ve Hudgins ve ark. (1993) tarafından önerilen zaman alanı öznitelikleri ile sonuçları karşılaştırmışlardır. Zaman-frekans alanı öznitelikleri biyoelektrik sinyallerinin sınıflandırılmasında etkili özellik kümeleridir. EMG sinyallerinin sınıflandırılmasında ortalama frekans, medyan frekans, ortalama pik frekansı, spektral momentler, frekans oranı, güç spektrumu oranı ve merkezi frekansın varyansı çok başarılı sonuçlar verir (Phinyomark, et. al, 2012). Ancak yüksek boyutları ve yüksek çözünürlükleri nedeniyle boyutun azaltılması gereklidir (Hargrove et. al, 2009). Bununla birlikte, zaman alanı, frekans alanı ve dalgacık katsayılarının kullanıldığı çalışmaların sınıflandırma performansları karşılaştırıldığında sonuçların zaman alanı için % 78.3, frekans alanı için % 62.5, ve dalgacık dönüşümü için % 66.2 olduğu ifade edilmiştir (Reaz et.al, 2006). Bu nedenle, bu çalışmada zaman alanı öznitelik çıkarım yöntemleri tercih edilmiştir (Hargrove et. al, 2009).

Bu alandaki çalışmalarda EMG sinyallerinin sınıflandırılması için yaygın olarak kullanılan sınıflandırıcı türleri Yapay Sinir Ağları (YSA) ve çeşitleri, Bulanık Sınıflandırıcı, Doğrusal Ayırt Etme Analizi (LDA), Kendiliğinden Düzenlenmiş Harita (SOM) ve Destek Vektör Makineleri (SVM)'dir (Phinyomark, et. al, 2012). Araştırmacılar SVM ve LDA sınıflandırıcılarını, basitlik ve eğitim kolaylığı nedeniyle protez cihazlarını kontrol etmek için tercih etmektedirler (Scheme et al, 2011; Jiang et al, 2012). EMG'nin gerçek zamanlı sınıflandırma uygulamaları için, Del ve Park, YSA'nin uygun bir teknik olduğunu belirtmiştir (Al-Mulla et.al, 2011). Bazı araştırmacılar kontrolsüz bir öğrenme tekniği ile çok katmanlı perceptron tipi yapay sinir ağları ile, ağa EMG verilerini öğretmeye ve daha sonra test verilerini otomatik olarak tanımaya çalıştılar (Boca et al, 1994). Tsuji ve ark., (1993) kaydedilmiş biyoelektrik işaretlerin entropisini kullanarak altı ön kol hareketinin sınıflandırılması için geri yayılım yapay bir sinir ağı modelini kullandılar. Bilek hareketlerini sınıflandırmak için Naik et. ark. dört yöntem (ICA, JADE-ICA, Infomax-ICA ve TDSEP) denediler ve sonuçlarını birbirleri ile karşılaştırdılar. Khezri ve ark. EMG sinyalleriyle el hareketlerini sınıflandırmak için sinir tabanlı bulanık mantık sınıflandırma algoritmasını kullandılar (Khezri et.al, 2011)

3. ÇALIŞMANIN KAPSAMI VE ÖZGÜN DEĞERİ

Şekil 1, çalışmaya ait blok diyagramı yer almakta. Kişilerin ön kol kaslarına bağlanan dört kanallı EMG kayıt cihazı ile kişiler altı el hareketini sırası ile gerçekleştirdikleri esnada dört parmağın hareketine ilişkin (baş parmak hariç diğerleri) biyoelektrik sinyaller eş zamanlı olarak kaydedilmiştir. EMG sinyalleri kişinin yaşına, kas durumuna, cinsiyetine göre farklılık gösteren

sinyaller olup kişinin fizyolojik özelliklerinin ölçüm sistemi parametreleri üzerindeki bağımlılığını ortadan kaldırmak için, ilk olarak sinyallere normalizasyon ve ön işlem adımları uygulanmıştır. Sonrasında sinyale ait seçilen zaman domeni öznelikleri hesaplanmış ve sinyaller ile el hareketleri arasındaki ilişkiler İYYSA ve RFYSA sınıflandırma algoritmaları kullanılarak anlamlandırılmıştır. Algoritmaların performans analizleri ise ROC analiz yöntemi ile gerçekleştirilmiş ve literatürdeki benzer çalışmalar ile kıyaslanmıştır.



Şekil 1. Çalışmanın adımları

Literatürde halihazırda var olan el kapanma ve açma hareketlerine ek olarak, dört parmağa ait aktivitenin ayrı ayrı kaydedilip anlamlandırılması ile Tablo 1'de yer alan yani parmak-ışaret parmağı teması, parmak-orta parmak teması, parmak-parmak parmak teması ve parmak-küçük parmak teması (dört hareket), biyo sinyal sinyaller vasıtası ile anlamlandırılmış ve ilgili çalışma alanına katkı sağlanmıştır. Bu elektrot yerleşim planı ve uygulanan sınıflandırma yöntemi sayesinde biyoelektriksel kontrollü protez el mekaniklerinin yapabildiği bağımsız hareket sayısı artırılabilir.

Tablo 1. EMG Sinyalleri Yardımı ile Anlamlandırılan El Hareketleri

| | <i>El Kapama</i> | <i>El Açma</i> | <i>Baş-İşaret Parmak Teması</i> | <i>Baş-Orta Parmak Teması</i> | <i>Baş-İşaret Parmak Teması</i> | <i>Baş-İşaret Parmak Teması</i> |
|---------------------|------------------|----------------|---------------------------------|-------------------------------|---------------------------------|---------------------------------|
| <i>El Desenleri</i> | | | | | | |

4. METODOLOJİ

Bu çalışmada ise zaman etki alan öznelikleri kullanılarak; altı adet el hareketinin sınıflandırılmasında İleri beslemeli sinir ağı ve radyal fonksiyonlu sinir ağı algoritmalarının sınıflandırma performansı analiz edilmeye çalışılmıştır.

a. EMG Sinyallerinin Kaydedilmesi

EMG sinyalleri, dört kanallı yüzey elektrot grubu vasıtasıyla altı el deseni için flexor pollicis longus, flexor carpi radialis, brachioradialis, extensor carpi radialis, extensor digiti minimi, ve extensor carpi ulnaris kaslarından kaydedilmiştir. Elektrotların yerleştirilmesi SENIAM protokolüne (2014) uygun olarak Şekil 2'de yer almaktadır.



Şekil 2. Elektrot yerleşim planı

b. EMG Sinyallerinin Ön İşlemden Geçirilmesi

EMG sinyali 0.001 saniye aralıklarla kaydedildi. Örneklenen sinyal bir bant geçiren filtreden (50-500 Hz) geçirildi. EMG sinyalleri, Englehart optimal çerçeveleme yöntemi kullanılarak çerçevelere ayrılmıştır. Englehart'ın çalışmasında [23,24] yer alan $R = 256$ ve $r = 32$ ms optimum çerçeve boyutunu belirlemede referans alınmıştır.

c. EMG Sinyallerinin Özniteliklerinin Çıkarılması

Bu çalışma kapsamında zaman alanı özniteliklerinden denklem (1-5)'de yer alan sinyalin enerji, maksimum değeri, ortalama değeri, RMS ve varyansı hesaplanmış ve sınıflandırma algoritmasına girdi olarak verilmiştir [7-9].

$$\text{Signalin Enerjisi: } E = \int_{t_i}^{t_j} |m(t)| dt \quad (1)$$

$$\text{Signal Ortalama: } AVR = \frac{1}{t_j - t_i} \int_{t_i}^{t_j} |m(t)| dt \quad (2)$$

$$\text{Signal Efektif değeri: } RMS = \left(\frac{1}{T} \int_0^T m^2(t) dt \right)^{1/2} \quad (3)$$

$$\text{Signal Varyansı: } VAR = \left(\frac{1}{T} \int_0^T (x - \text{ORT})^2 p(t) dt \right) \quad (4)$$

$$\text{Sinyalin maximum degeri: } MAX = \max(m(t)) \quad (5)$$

d. EMG Sinyallerinin Sınıflandırılması

İleri beslemeli YSA (İYSA) doğrusal olmayan modelleri herhangi bir sürekli fonksiyona veya türevlerine yakınlaştırma yeteneğine sahiptir ve tıbbi verilerin sınıflandırılmasına uygundur [25]. Tasarlanan YSA iki katmanlı olup her bir katmanında sırası ile 5 ve 6 nöron bulunmaktadır. Katmanın ağırlığı, üst simgesi sayısı, ağırlık matrisi ve aktivasyon fonksiyonu sırasıyla w , k , w_{ij} (k) ve g (1) ile ifade edilmiş olup iki katmanlı FFNN'nin çıkış eşitliği denklem (6)'da yer almaktadır. [25].

$$y_m = g^{(2)} \left(\sum_{q=0}^Q \omega_{mq}^{(2)} g^{(1)} \left(\sum_{i=0}^N \omega_{qi}^{(1)} x_i \right) \right) \quad (6)$$

Radial Fonksiyonlu Sinir Ağı (RFYSA), klasik istatistiksel yöntemlerden daha az varsayıma sahip olduğu için gerçek hayat problemlerini çözmek için oldukça uygundur. Ağ mimarisinin basitliği nedeniyle çok katmanlı YSA modellerine göre pek çok avantajı vardır. Bu avantajlar diğer YSA algoritmalarından daha hızlı eğitilmesine izin verir ve gizli katman aktivasyon fonksiyonları sigmoid ve S-tipi fonksiyonlar yerine radyal tabanlı fonksiyonlardır [25]. Bu özellik ile RFYSA, EMG'de olduğu gibi farklı bölgelerde farklı davranan girdi alanlarını incelerken etkili bir algoritma olarak öne çıkmaktadır. Sistemimiz için, $h(x)$ radyal temelli fonksiyondur ve $f(x)$ YSA çıktı ifadesi denklem (7-8)'da gösterildiği gibi yazılabilir [25].

$$f(x) = \sum_{j=1}^m w_j h_j(x) \quad (7)$$

$$h(x) = \exp\left(-\frac{(x-c)^2}{r^2}\right) \quad (8)$$

5. DENEYSSEL PROBLEM VE SONUÇLAR

a. Problemin Tanımlanması

Tablo 1'de gösterilen altı adet el hareketinin (başparmağı diğer dör parmak ile ayrı ayrı teması, al kapama ve el açma) EMG sinyalleri ile anamlandırılması işlemi gerçekleştirilmeye çalışılmıştır. Dataset her bir hareket için 20 adet olmak üzere toplamda 160 adet harekete ait sinyalleri içermektedir. Bu data setin 80 adedi eğitim datası diğer 90 adedi test datası olarak kullanılmıştır.

b. Parametre Tayini

İYSA, RFYSA algoritmalarının başarılı sonuçlar vermesi için deneysel olarak parametreler test edilmiş ve her bir algoritma için optimal parametreler seçilmeye çalışılmıştır. Sınıflandırma algoritmaları için kullanılan parametre değerleri Tablo 2-3'de yer almaktadır.

Tablo 2. YSA Parametreleri

| Parametre | Değeri |
|---------------------------------|---|
| Katman Sayısı | 2 |
| Katmanlardaki Nöron Sayısı | 5, 6 |
| Katmanların transfer fonksiyonu | {'tansig','purelin','purelin'},'trainbr |
| Performans fonksiyonu | MSE |

Tablo 3. RFYSA Parametreleri

| Parametre | Değeri |
|--|--------|
| Radyal tabanlı foksiyonun dağılıma “Spread” değeri | 5 |
| Maksimum nöron sayısı | 100 |

c. ROC Analizi Sınıflandırma Başarı Tayini

Kullanılan sınıflandırma algoritmalarının ayırt ediciliğini belirlemek amacıyla ROC (Alıcı işlem karakteristikleri, Receiver Operating Characteristic) Analizi yöntemi kullanılmıştır. Örneğin gerçekleştirilen bir harekete ait durumlar;

- (Doğru pozitif, A): Gerçekte x sınıfına ait olup, sınıflandırma sonucuna göre de x sınıfında belirlenmiş
- (Yanlış pozitif, B): Gerçekte x sınıfına ait olup algoritmanın hatalı olarak x sınıfına ait değil olarak belirlenmiş
- (Yanlış negatif, C) : Gerçekte x sınıfına ait olmadığı halde sınıflandırma sonucunda x sınıfında belirlenmiş
- (Doğru negatif, D): Gerçekte x sınıfına ait olmayıp, sınıflandırma sonucunda da x sınıfında olmayan prensibi ile gruplandırılarak ROC tabloları (Tablo 4-5) her bir sınıflandırıcı ve her bir hareket için oluşturulmuştur. Sınıflandırma doğruluğu ise denklem(11)’e göre hesaplanmıştır.

$$\text{Doğruluk (ACC)} = (A + D) / (A + B + C + D) \tag{9}$$

Tablo 4. İYSA için ROC Tablosu

Tablo 5. ROC

| Hareket 1 | | | Hareket 2 | | | Hareket 3 | | | Hareket 4 | | | |
|------------|----|----|------------|----|----|------------|----|----|------------|----|----|----|
| A | B | 15 | A | B | 15 | A | B | 15 | A | B | 15 | |
| 11 | 4 | | 9 | 6 | | 11 | 4 | | 13 | 2 | | |
| C | D | 75 | C | D | 75 | C | D | 75 | C | D | 45 | |
| 4 | 71 | | 5 | 70 | | 5 | 70 | | 2 | 73 | | |
| 15 | 75 | 90 | 14 | 76 | 90 | 16 | 74 | 90 | 17 | 80 | 90 | |
| ACC=0.9111 | | | ACC=0.8777 | | | ACC=0.9 | | | ACC=0.9555 | | | |
| Hareket 5 | | | Hareket 6 | | | | | | | | | |
| A | B | 15 | A | B | 15 | | | | | | | |
| 15 | 0 | | 15 | 0 | | | | | | | | |
| C | D | 75 | C | D | 45 | | | | | | | |
| 0 | 75 | | 0 | 75 | | | | | | | | |
| 15 | 75 | 90 | 15 | 75 | 90 | | | | | | | |
| ACC=1 | | | ACC=1 | | | | | | | | | |
| Hareket 1 | | | Hareket 2 | | | Hareket 3 | | | Hareket 4 | | | |
| A | B | 15 | A | B | 15 | A | B | 15 | A | B | 15 | |
| 12 | 3 | | 10 | 5 | | 11 | 4 | | 13 | 2 | | |
| C | D | 75 | C | D | 75 | C | D | 75 | C | D | 75 | |
| 5 | 70 | | 4 | 71 | | 4 | 71 | | 1 | 74 | | |
| 17 | 73 | 90 | 14 | 76 | 90 | 15 | 75 | 90 | 14 | 80 | 76 | 90 |
| ACC=0.9111 | | | ACC=0.9 | | | ACC=0.9111 | | | ACC=0.9666 | | | |
| Hareket 5 | | | Hareket 6 | | | | | | | | | |
| A | B | 15 | A | B | 15 | | | | | | | |
| 15 | 0 | | 15 | 0 | | | | | | | | |
| C | D | 75 | C | D | 75 | | | | | | | |
| 0 | 75 | | 0 | 75 | | | | | | | | |
| 15 | 75 | 90 | 15 | 75 | 90 | | | | | | | |
| ACC=1 | | | ACC=1 | | | | | | | | | |

RFYSA için Tablosu

6. SONUÇLAR VE YORUMLAR

EMG sinyali, kas ve sinir sistemi hakkında önemli bilgiler taşır. Protezin etkin bir şekilde kontrol edilmesi için kişinin hareket isteğinin doğru tespit edilebilmesi son derece önemlidir. Bu çalışma kapsamında alt kol kasınlarına ait biyoelektriksel sinyaller dört kanallı bir EMG kayıt cihazı ile alınmış, ön işleme tabi tutulmuş ve her bir kanal için beşer olmak üzere toplamda 20 adet öznelik hesaplanmıştır. Kullanılan iki ayrı algoritma ile de öznelikler anlamlandırılmaya çalışılmıştır.

Altı hareket için İYSA , RFYSA argoritmaları için sırası ile ortalama %94.81, %94.05 sınıflandırma başarısı elde edilmiştir. Sonuçlar göstermektedir ki iki sınıflandırma algoritmasının başarı oranı birbirine yakındır ve Tablo 6'da yer alan diğer araştırmacıların yaptıkları çalışmalar ile karşılaştırıldığında da başarı oranı tatmin edicidir.

Tablo 6. Karşılaştırma Tablosu

| Hareket Sayısı | Sınıflandırma Algoritması | Doğruluk Oranı % | Referans |
|-----------------|------------------------------|------------------|----------------------|
| Altı | İleri Yönlü YSA | % 94.05 | Bu Çalışmanın Sonucu |
| | RFYSA | % 94.81 | |
| Altı | Adaptif Neuro-fuzzy (ANFIS) | 92% | [21] |
| - | BPANN | 89.2% | [10] |
| Altı | Geri yayımlı YSA | 90% | [20] |
| Çince numaralar | k-NN, LDA and QDA algorithms | 91-97% | [26] |
| Dört | YSA | 83.5% | [27] |
| - | Fuzzy | 85% | [28] |

İlerki çalışmalarda yapılması hedeflenenler; anlamlandırılan el hareket sayısı (sınıf) artırılarak, RFYSA algoritmasının başarı oranı incelenmeye çalışılacaktır.

BİLGİLENDİRME

Bu çalışma konusu Beyda TAŞAR'ın doktora tezi olup; TUBITAK 2211 Öncelikli Alanlar için Yurtiçi Doktora Burs Programı kapsamında desteklenmiştir. Ayrıca çalışma, Doktora projesi kapsamında (Proje No: MF-14.25) Fırat Üniversitesi Bilimsel Araştırma Projelerini Destekleme Birimi (FUBAP) tarafından desteklenmiştir.

KAYNAKLAR

Al-Mulla, M.R.; Sepulveda, F.; Colley, M. (2011), A review of non-invasive techniques to detect and predict localised muscle fatigue, *Sensors*, 11, 3545–3594.

Boca, A.D.; Park, D.C. (1994). Myoelectric Signal Recognition Using Fuzzy Clustering and Artificial Neural Networks in Real Time. In *Proceedings of the IEEE International Conference on Neural Networks and IEEE World Congress on Computational Intelligence*, Orlando, FL, USA, 27 June–2 July 1994; pp. 3098–3103.

Demuth, H., Beale, M. (2014), *Neural Network Toolbox For Use with MATLAB®*, Issue-6, The MathWorks, Inc. 3 Apple Hill Drive Natick, MA 01760-2098

Dobrowolski, A. P., Wierzbowski, M., Tomczykiewicz, K., (2010). “Multiresolution MÜAPs decomposition and SVMbased analysis in the classification of neuromuscular disorders”, *Computer Methods and Programs in Biomedicine*, Elsevier,

Englehart, K.; Hudgins, B.; Parker, P. (2000). Multifunction Control of Prostheses Using the Myoelectric Signal. In *Intelligent Systems and Technologies in Rehabilitation Engineering*; Teodorescu, H.-N.L., Jain, L.C., Eds.; CRC Press: New York, NY, USA,

Englehart, K.; Hudgins, B. (2003). A robust, real-time control scheme for multifunction myoelectric control. *IEEE Trans. Biomed. Eng.*, 50, 848–854.

- Englehart, K.; Hudgins, B.; Parker, P.A.; Stevenson, M. (1999). Classification of the myoelectric signal using time-frequency based representations. *Med. Eng. Phys.* 21, 431–438.
- Englehart, K., Hudgins, B., Parker, P., Stevenson, M., (1998). Time-Frequency Representation for Classification of the Transient Myoelectric Signal, Proceedings of the 20th Annual International Conference on Engineering in Medicine and Biology Society. ICEMBS Press.
- Englehart, K., (1998). Signal Representation for Classification of the Transient Myoelectric Signal. Doctoral Thesis. University of New Brunswick, Fredericton, New Brunswick, Canada.
- Eldin Henry Shroffe D, P. Manimegalai, (2013). “Hand Gesture Recognition Based on EMG Signals Using ANN,” *International Journal of Computer Application Issue 3, Vol. 2.*
- Francis H. Y. Chan, Yong-Sheng Yang, F. K. Lam, Yuan-Ting Zhang, and Philip A. Parker, (2000). Fuzzy EMG Classification for Prosthesis Control, *IEEE Transactions On Rehabilitation Engineering*, vol. 8, no. 3.
- Hargrove, L.J.; Li, G.; Englehart, K.B.; Hudgins, B.S. (2009). Principal components analysis preprocessing for improved classification accuracies in pattern-recognition-based myoelectric control. *IEEE Trans. Biomed. Eng.* , 56, 1407–1414.
- Hudgins, B.; Parker, P.; Scott, R.N. (1993). A new strategy for multifunction myoelectric control. *IEEE Trans. Biomed. Eng.*, 40, 82–94.
- Ibrahimy, M.I.; Khalifa, O.O.; Ahsan, M.R., (2012), EMG Motion Pattern Classification through Design and Optimization of Neural Network. In Proceedings of the International Conference on Biomedical Engineering (ICoBE), Kuala Lumpur, Malaysia, 27–28 February 2012; pp. 175–179.
- Jiang, N.; Dosen, S.; Muller, K.-R.; Farina, D. (2012), Myoelectric control of artificial limbs—Is there a need to change focus?, *IEEE Signal Process. Mag.* , 29, 152–150.
- Khezri, M.; Jahed, M. (2011), A neuro–fuzzy inference system for semg-based identification of hand motion commands. *IEEE Trans. Ind. Electron.* 58, 1952–1960.
- Rodriguez, I., Malanda, A., Gila, L., (2006). Filter design for cancellation of baseline – fluctuation in needle EMG recordings, *Comput. Meth. and Prog. in Biomed.*, 81, 79-93,
- M.B.I. Raez, M.S. Hussain, 1 and F. Mohd-Yasin, (2006). Techniques of EMG signal analysis: detection, processing, classification and applications, *BiolProced Online*, 8: 11–35. Published online 2006 Mar 23. doi: 10.1251/bpo115
- Peter Konrad, (2005), ABC of EMG – A Practical Introduction to Kinesiological Electromyography, Version 1.0 April, download date: 07.06.2017, https://hermanwallace.com/download/The_ABC_of_EMG_by_Peter_Konrad.pdf
- Pagniotacopulos, N. D., Lae, J. S., Pope, M. H., (1998). “Evaluation of EMG signals from rehabilitated patients with low back pain using wavelets”, *J. Electromyography and Kinesiology* 8, 269 – 278.
- Phinyomark, A.; Phukpattaranont, P.; Limsakul, C. (2012), Feature reduction and selection for EMG signal classification. *Expert Syst. Appl.* 39, 7420–7431.
- Rajesh, V.; Kumar, P.R.; Reddy, D.V. (2009), SEMG Based Human Machine Interface for Controlling Wheel Chair by Using ANN. In Proceedings of the International Conference of Control, Automation, Communication and Energy Conservation, Perundurai, Tamilnadu, India, 4–6 June; pp. 1–6.
- Reaz, M. B. I. Hussain M. S. and Mohd-Yasin, F., (2006). Techniques of EMG signal analysis: detection, processing, classification and applications, *Biol. Proced.* 8(1): 11-35. doi:10.1251/bpo115, March 23, 2006
- Scheme, E.; Englehart, K. , (2011). Electromyogram pattern recognition for control of powered upper-limb prostheses: State of the art and challenges for clinical use. *J. Rehabil. Res. Dev.* 2011, 48, 643–659.
- SENIAM EMG protocol. Available from: <http://www.seniam.org/> (Download date: 22 21.03.2014)
- Tsuji, T.; Ichinobe, H.; Ito, K.; Nagamachi, M. (1993), Discrimination of forearm motions from EMG signals by error back propagation typed neural network using entropy. *Trans. Soc. Instrum. Control Eng.* 29, 1213–1220.
- Xun Chen, Z Jane Wang, (2013), Pattern recognition of number gestures based on a wireless surface EMG system, *Biomedical Signal Processing and Control*, Vol:8, Issue: 2, pages: 184-192
- Zardoshti-Kermani, M.; Wheeler, B.C.; Badie, K.; Hashemi, R.M. (1995), EMG feature evaluation for movement control of upper extremity prostheses. *IEEE Trans. Rehabil. Eng.* 3, 324–333.