

Spektral Yöntemler ve DVM Sınıflandırıcı ile EMG İşaretlerinin Tasnifi

Mücahid GÜNAY, Ahmet ALKAN*

Kahramanmaraş Sütçü İmam Üniversitesi, Mühendislik-Mimarlık Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü, Kahramanmaraş/Türkiye

Özet: Bu çalışmada kas liflerinin kasılması neticesinde deri yüzeyinden algılanan elektromiyografi (EMG) işaretleri sınıflandırılmıştır. Çalışılan EMG işareti dört farklı harekete ait toplam 400 farklı örüntüden oluşmaktadır. Her bir örüntü bir harekete ait iki farklı kasta eş zamanlı olarak kaydedilen EMG işaretinin art arda eklenmesiyle elde edilmiştir. Bu örüntülerin sınıflandırılması için danışmanlı bir yöntem olan Destek Vektör Makinesi (DVM) sınıflandırıcı kullanılmıştır. Fakat DVM sınıflandırıcı kullanılmadan önce işaretin bir ön işlemeden geçmesi gerekmektedir. Bu amaçla da spektral yöntemlere başvurulmuştur. Böylece işlenmemiş veriden daha anlamlı ve katsayılarından oluşan özellik vektörleri elde edilmiştir. Ön işleme için dört farklı yöntem kullanılmış, elde edilen özellik vektörleri de DVM sınıflandırıcı ile sınıflara ayrılmıştır. Kullanılan veri seti için DVM sınıflandırıcının başarısı ölçülmüş ve ön işleme metodlarının performansı kıyaslanmıştır. En yüksek başarı oranı %94,25'tir.

Anahtar Sözcükler: EMG; Spektral Yöntemler; Özbağlanım (AR); DVM Sınıflandırıcı

Classification of EMG Signals by Spectral Methods and SVM Classifier

Abstract: In this study, EMG signals taken from the skin surface as a result of muscles' contraction are classified. Studied EMG signals include 400 different patterns relating to four different movements. Each pattern is obtained by adding EMG signals one after another, which are recorded synchronously from two different muscles relating to one movement. Support Vector Machine (SVM) classifier, a supervised method, is used to classify these patterns. But signals need to be preprocessed before being used in SVM classifier. To this end, spectral methods are consulted. In this way, feature vectors which are more significant than raw data and are composed of coefficients are achieved. Four different methods are used for preprocessing and feature vectors obtained are classified by SVM. Success of SVM classifier is tested and performances of preprocessing methods are compared. Best achievement is 94.25%.

Keywords: EMG; Spectral Methods; Autoregressive (AR); SVM Classifier

1. GİRİŞ

EMG işaretleri kasların kasılması sonucu oluşan elektrokimyasal olayların sonucunda, iğne veya yüzey elektrotlarıyla elde edilen bir biyoelektrik işarettir. Bu işaretlerin doğru sınıflandırılması protezler, klinik teşhis ve tanı açısından büyük önem arz etmektedir. Bu amaçla EMG işaretlerinin gruplanması için sezgisel yaklaşım, belirgin yaklaşım, istatistiksel yaklaşım, yapay sinir ağları yaklaşımı ve bulanık yaklaşım [18] gibi birçok hesaplama yöntemi kullanılmış, bu algoritmaların başarısını artırmak için yardımcı ön işleme yöntemleri uygulanmıştır. Zaman domenli öznitelikleri [10,13], özbağlanım (AR) katsayıları [5,8,11,15,16], cepstral katsayılar [14] bunlardan bazılarıdır.

Subasi ve ark. (2006), "Dalgacık sinir ağı kullanarak EMG işaretlerinin sınıflandırılması" adlı çalışmalarında, EMG işaretinin sınıflandırılması için ileri beslemeli hata geri yayımlı yapay sinir ağları (FEBANN) ve dalgacık sinir ağları (WNN) temelli sınıflandırıcılar geliştirmiş ve karşılaştırmışlardır. Nörolojik hastalığa sahip 13 denek, miyopati hastası 7 denek ve sağlıklı 7 denekten elde edilen 1200 MUP (motor unit potential) analiz edilmiş, WNN tekniğinden en başarılı %90,7, FEBANN tekniğinden en başarılı %88 sonuç elde edilmiştir ve WNN temelli

sınıflandırıcıların FEBANN temelli sınıflandırıcılara karşı daha iyi sınıflandırma yaptığı gösterilmiştir [24].

Lucas ve ark. (2008), "SVM ve işaret temelli dalgacık optimizasyonu kullanarak çok kanallı EMG sınıflandırması" adlı çalışmalarında, miyoelektrik protezleri kontrol amacı ile çok kanallı EMG işaretlerinin danışmanlı sınıflandırılması için bir yöntem önermektedir. Çözüm kümesi, ana dalgacığın serbest parametrelendirilmesi kullanılarak her bir kaydedilen EMG işaretinin ayrı dalgacık dönüşümünün üzerine temellendirilmiştir. Çok kanallı çözüm kümesinde SVM yaklaşımıyla sınıflandırma gerçekleşir. Kolun üzerindeki 8 bölgeden kaydedilen EMG ile 6 el hareketinin sınıflandırılmasında bu metod uygulanmıştır [19].

Huang ve ark. (2003), "Sinir Ağları ve SOM'un kademelenirilmiş mimarisini kullanarak kavrama durumları için EMG sınıflandırması" adlı çalışmalarında sekiz ayrı ön kol kavrama hareketinin sınıflandırılmasında yüksek sınıflandırma oranını ve kısa öğrenim zamanı için sınıflandırıcı geliştirilmiştir. Bu amaç için Özellik haritalı sinir ağının basamaklı mimarisi (CANFM - Cascaded Architecture of Neural Networks with Feature Map) ele alınmış ve bu mimarinin iki ögesi olan, danışmansız öğrenmeye sahip SOM ve danışmanlı öğrenmeye sahip 'çok katmanlı ileri beslemeli sinir ağı' ayrıntılı olarak açıklanmıştır. Bu mimarinin k-en yakın komşu, bulanık k-en yakın komşu

ve geri yayımlı sinir ağından daha iyi bir sınıflandırma yaptığından bahsetmektedir [12].

Chan ve ark. (2000), "Protez kontrolü için bulanık EMG sınıflandırması" adlı çalışmalarında protez kontrolü için EMG sinyallerinin sınıflandırılması amaçlanmıştır. Sınıflandırmanın kontrolü konusunun önemine vurgu yapılmıştır. Bahsedilen sistemde; EMG işaretleri, kabul edilebilir bir hız ve gerçekçi bulanık sistem yapısı elde etmek için çalıştırma safhasının başında denetleme olmadan Basic Iso-Data algoritmasını kullanarak kümelenir ve kümeleme sonuçları bulanık sistem parametrelerini başlatmak için kullanılır. Daha sonra, sistemdeki bulanık kurallar geri yayılım algoritması ile çalıştırılır. Bulanık yaklaşım Yapay Sinir Ağları ile dört örnekte karşılaştırılır ve çok benzer sınıflandırma sonuçları elde edilir. Öncekilere göre en az üç noktada üstündür: yüksek doğrulama oranı; aşırı çalıştırmaya duyarsızlık ve daha tutarlı çıktılar, böylece daha yüksek güvenilirlik sağlar. Bulanık yaklaşımın YSA (Yapay Sinir Ağları) yaklaşımına göre potansiyel avantajları da tartışılmıştır [7].

Ahmad ve Chappell (2007), "Değişen yaklaşık entropi kullanılarak yüzey EMG sınıflandırması" adlı çalışmalarında, 20 denek bilek hareketleri yaparken izometrik kasılma ve karşı kasılma EMG sinyalleri yüzey elektrotlarla kaydedilmiş ve bu datalar sınıflandırılmıştır [1].

Oskoei ve Hu (2007), "Miyoelektrik kontrol sistemleri" adlı çalışmalarında örüntü tanıma temelli ve örüntü tanıma temelli olmayan miyoelektrik kontrol üzerinde son zamanlarda yapılan araştırma ve geliştirmeleri gözden geçirerek tiplerine, yapılarına ve mevcut uygulamalara bağlı en son başarıları sunmaktadır [20].

Oskoei ve Hu (2008), "Support Vector Machine-Based Classification Scheme for Myoelectric Control Applied to Upper Limb" adlı çalışmalarında miyoelektrik işaretler kullanarak üst bacak hareketlerine DVM uygulanmasını önermiş ve değerlendirmişlerdir. Data bölümlenme tekniği, özellik kümesi, DVM için model seçim yaklaşımı ve son işleme metotlarının avantajları sunularak DVM temelli miyoelektrik kontrolün en iyi şeklini incelemişlerdir. Bu çalışma

kontrolör performansını artırmak için kullanılan, çakışık bölümlenme ve çoğunlukla seçim gibi iki tekniği ve sınıflandırmadan önce DVM parametrelerinin ayarlanması konularını sunar. Miyoelektrik kontrolün sınıflandırılmasında temel olan DVM, çok katmanlı perseptron sinir ağları ve lineer diskriminant analiz karşılaştırılmıştır. Bu karşılaştırma DVM'nin olağan üstü doğruluğunu, güçlü performansını ve düşük hesaplama yükünü göstermiştir [21].


Khezri ve ark. (2007), "Çok fonksiyonlu el protezi kontrolü için nöro-bulanık yüzey EMG örüntü tanıma" adlı çalışmalarında el protezinin hareketlerinin modelini tanımlamak için yüzeysel EMG sinyallerinden yararlanılmıştır. Protez bir elin kontrolü için de hareket komutlarını belirlemeyi amaçlayan uyarlanabilir bir bulanık mantık çıkarım sisteminin (ANFIS) kullanılması önerilmiştir. Sınıflandırmada kullanılan miyoelektrik sinyaller, altı el hareketinden oluşmaktadır. Bu çalışmada tasarlanan ve kullanılan bulanık-mantık sistemleri, bağımsız olarak ve hem zaman hem de zaman-frekans özellikleri için karma bir biçimde test edilmiştir. Bu birleşik yaklaşım için sistemin ortalama hassasiyetinin %96 olduğu bildirilmiştir [17].

Kocuyigit ve Korurek (2005), "EMG işaretlerini dalgacık dönüşümü ve bulanık mantık sınıflayıcı kullanarak sınıflama" adlı çalışmalarında öznelik çıkartma yöntemi olarak zaman-frekans domeni analiz yöntemlerini kullanarak protez koluna ait dört farklı hareket için EMG işaretlerini daha iyi sınıflandırılması hedef olarak belirlenmiştir. Bunun için boyut azaltma ve bulanık sınıflama yöntemleri de incelenmiştir. Sınıflama problemi öznelik çıkartma, boyut azaltma ve örüntü sınıflama aşamalarına ayrılmıştır. Dalgacık dönüşümü öznelik çıkartma yöntemi olarak büyük üstünlük sağladığı bildirilmiştir. Özneliklerin çıkartma aşamasında yüksek boyuta sahip olmalarından dolayı sınıflama başarısı, Ana Bileşenler Analizi (ABA) ve Bağımsız Bileşenler Analizi (BBA) gibi uygun boyut azaltma yöntemleriyle gerçekleştirilmiştir [18].

Bu çalışmada dört farklı kol hareketini sınıflandırmak için Destek Vektör Makinesi, ön işleme için de özbağlanım katsayıları kullanılmıştır.

2. MATERYAL VE METOT

2.1. Kullanılan Veri



Şekil 1. Ham EMG İşareti (a) Dirsek açma (b) Dirsek kapama (c) Ön kolu içe döndürme (d) Ön kolu dışa döndürme.

Çalışmada 400 adet örüntü kullanılmıştır. Dirsek açma, dirsek kapama, ön kolu içe döndürme, ön kolu dışa döndürme olmak üzere dört farklı harekete ait 100'er adet veri mevcuttur. Her bir örüntü 512 örnekten

oluşmuştur. Bunlardan ilk 256 adedi biceps, kalan 256 ededi ise triceps kaslarından iki kanallı olarak elde edilmiştir. Her iki kanal için de örnekleme frekansı 1000 Hz'dir [9,18].



Şekil 2. Örnek EMG İşaretin Toplanması.

2.2. Yöntem

2.2.1. Ön İşleme Yöntemleri

2.2.1.1. Burg Yöntemi

Burg tarafından 1975 yılında öne sürülen bu metod, AR model parametrelerinin kestiriminde ileri-geri yöndeki tahmin hatalarının en aza indirilmesi ve yansıma katsayısı kestirimini kullanır. Diğer AR metodlarının aksine özilişki fonksiyonu hesaplaması yapılmaz. Bunun yerine doğrudan yansıma katsayısı kestirimi yapılır. Burg metodu parametrelerin kestiriminde işlemsel olarak verimli bir metottur. Yaygın kullanıma sahip Burg yöntemi ile ilgili ayrıntılar literatürde incelenebilir [4,22].

2.2.1.2. Yule-Walker Yöntemi

Bir p dizisinin AR modelinde var olan çıkışı, önceki p çıkışlarıyla beyaz gürültü girişinin toplamının lineer kombinasyonudur. Önceki p çıkışları üzerindeki ağırlık, özbağlanımın karelerinin ortalamasının kestirim hatasını minimize eder. Eğer $x[n]$ ve $y[n]$ çıkışının varolan değeri de sıfır ortalamalı bir beyaz gürültü girişi ise, AR(p) modeli şöyle olacaktır: [22]

$$\sum_{k=0}^p a[k]y[n-k] = x[n] \quad (1)$$

2.2.1.3. Kovaryans Yöntemi

Bu metotta bütün veri noktalarının hata tahmin güç kestiriminin hesaplanması şarttır. Özbağlanımlı parametre kestirimleri kullanılarak güç spektral yoğunluğu(PSD) aşağıdaki gibi hesaplanır [3, 6, 22, 26].

$$\hat{P}_{cov}(f) = \frac{\hat{\sigma}^2}{\left| 1 + \sum_{k=1}^p \hat{a}(k) \exp(-j2\pi fk) \right|^2}$$

2.2.1.4. Değiştirilmiş Kovaryans Yöntemi

Değiştirilmiş kovaryans da diğerleri gibi AR parametrelerinin hesabında kullanılan bir yöntemdir. Giriş bilgilerini AR modeline uydurmak için kullanılır. [25] Kovaryans yöntemi sadece önemsiz sonraki kestirim hatalarını en aza indirmede kullanılırken değiştirilmiş kovaryans yöntemi önemsiz önceki ve sonraki tahmin hatalarını en aza indirmede kullanılır.

2.2.2. DVM Sınıflandırıcı

Vapnik, yeni bir hesaplama metodu olarak destek vektör makinesini ileri sürmüştür [27]. Teorisi, 1995'ten 1998'e kadar geliştirilmiştir [23].

DVM, girilen veriyi (n) boyutlu bir özellik uzayı olarak kabul eder. ($n-1$) boyutlu bir hiper düzlem oluşturur ve bu düzlem özellik uzayını ikiye ayırır. n -boyutlu giriş dizisi x_i ($i=1,2,\dots,l$) ikiye ayırmak istendiğinde sınıf etiketlerinin tutulduğu y_i matrisi tarafından ilk sınıf için $y_i = 1$ ve ikinci sınıf için $y_i = -1$ olarak işaretlenir. Lineer olarak ayrılabilen veri setleri için hiper düzlem şöyle tanımlanır:

$$f(x) = \omega \cdot x + b = \sum_{i=1}^n \omega_i x_i + b = 0 \quad (2)$$

Burada ω , n -boyutlu bir vektör, b skaler bir değerdir. ω ve b hiper düzlemin konumu belirler. Hiper düzlem ayırma işlemini yaparken bazı sınırlara uymak zorundadır.

$$y_i(x_i \cdot \omega + b) - 1 \geq 0 \Leftrightarrow \begin{cases} f(x_i) = x_i \cdot \omega + b \geq 1 & y_i = +1 \\ f(x_i) = x_i \cdot \omega + b \leq -1 & y_i = -1 \end{cases} \quad (3)$$

Eğer hiper düzlem maksimum sınırları oluşturuyorsa buna optimal hiper düzlem denir. Aşağıda ξ_i bağımsız değişkeni ve C hata cezasını gösterir. Sadeleştirilmiş optimal hiper düzlemin çözümü şöyledir:

$$\phi(\omega, \xi) = 1/2(\omega \cdot \omega) + C \left(\sum_{i=1}^l \xi_i \right) \quad (4)$$

Şu koşula bağlı olarak:

$$y_i(x_i \cdot \omega + b) \geq 1 - \xi_i, \quad i=1,2,\dots,l \quad (5)$$

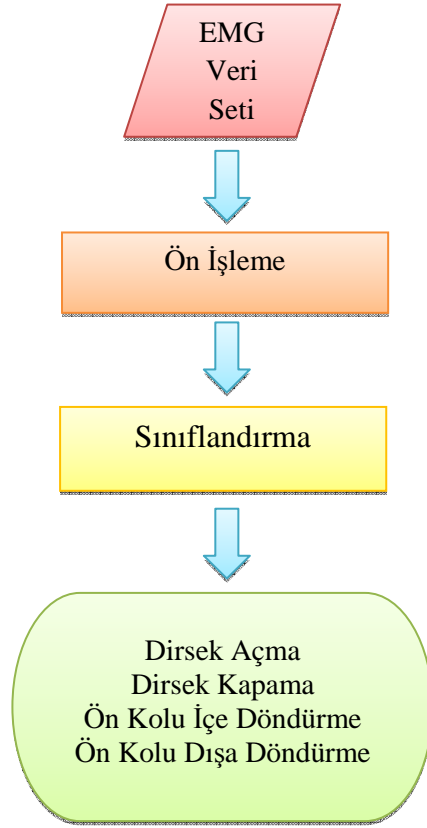
ξ_i sınır ile sınırın diğer tarafındaki x_i arasındaki uzaklığı hesaplar. Bu hesaplama şu şekilde minimize edilebilir.

$$V(\alpha) = \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i,j=1}^l \alpha_i \alpha_j y_i y_j K(x_i, x_j) \quad (6)$$

Şu koşula bağlı olarak:

$$\sum_{i=1}^l y_i \alpha_i = 0, \quad C \geq \alpha \geq 0, \quad i=1,2,\dots,l \quad (7)$$

$K(x_i, x_j)$ fonksiyonu kernel fonksiyonu olarak adlandırılır ve asıl veri noktalarının özellik uzayı haritalarının bire bir çarpımını verir. Bu sebepten dolayı veri kümesinin bütün elemanları eğitim için kullanılmalıdır. Böylece elle seçimlere göre daha doğru hata oranı elde edilir. Ama rastgele seçimden dolayı hata oranları arasında çok küçük farklılıklar oluşabilir[2]. Çalışmada MATLAB'in ilgili araç kutularına ait rutinler kullanılmıştır.



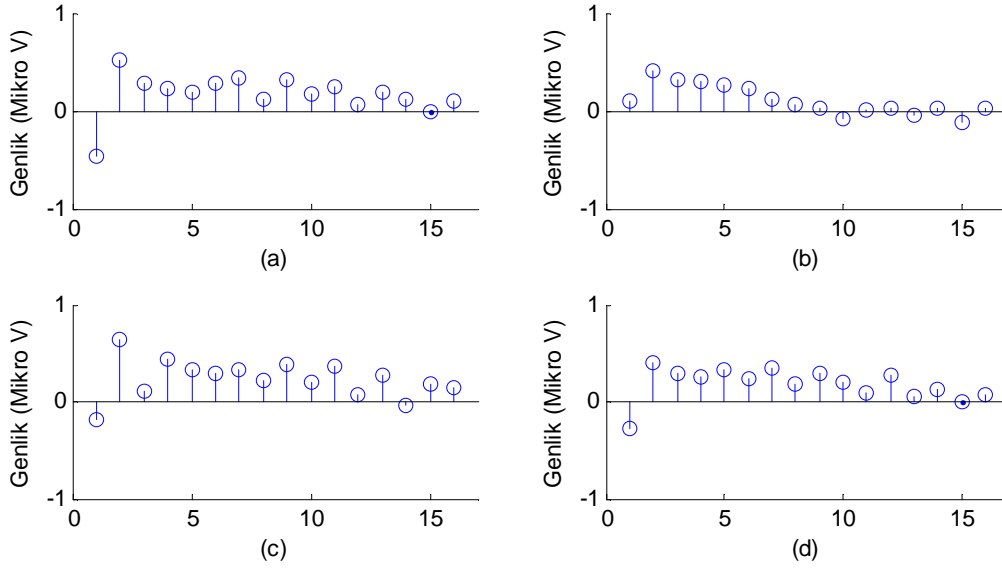
Şekil 3. Sınıflandırma için İzlenen Yol

3. BULGULAR VE TARTIŞMA

Birçok biyolojik işarette olduğu gibi EMG işaretlerinin ham olarak kullanımı sınırlıdır. Bu işaretleri sınıflandırmaya uygun hale getirmek için birçok ön işleme yöntemi kullanılabilir. Bu çalışmada ön işleme yöntemi olarak özbağlanım (AR) metotları kullanılmıştır. AR metotlarının uygulanmasında parametre seçimi sınıflandırma başarısı açısından önem taşımaktadır. Çalışmalar neticesinde veri setine ve DVM sınıflandırıcıya en uygun parametreler belirlenmiş, dört AR yöntemi için de aynı parametreler

kullanılmıştır. Örnek olarak dört AR yönteminden elde edilen özellik vektörlerinin 16 katsayıdan oluşması istenmiştir. Şekil 4'te bu özellik vektörleri gösterilmektedir. Böylece aynı parametreler için dört AR metodunun başarıları karşılaştırılmıştır.

Ön işleme sonucu elde edilen özellik vektörlerini sınıflandırmak için kullanılan DVM danışmanlı bir yöntemdir. Veri setinin yarısı öğrenme kalan yarısı da test için iki alt kümeye ayrılmıştır. Bu iki alt kümenin elemanları veri setinden rastgele seçilerek daha gerçekçi bir başarı hedeflenmiştir.



Şekil 4. Burg Özbağlanım uygulanmış EMG İşareti (a) Dirsek açma (b) Dirsek kapama (c) Ön kolu içe döndürme (d) Ön kolu dışa döndürme.

4. SONUÇ

DVM sınıflandırıcıdan elde edilen sonuç kümesi (her bir işaretin hesaplanarak hangi kümeyle ait olduğu gösteren küme) ile referans küme (işaretlerin hangi kümeyle ait olmasını gerektiğini gösteren küme)

karşılaştırılarak başarı oranları hesaplanmıştır. Tablo 1'den de anlaşılacağı gibi AR yöntemleri çeşitlerinin sınıflandırıcının başarısında küçük etkileri olmuştur. Bununla beraber AR yöntemleri ve DVM sınıflandırıcı ikilisi %94 gibi bir sınıflandırma başarısı elde etmiştir.

Çizelge 1. Sınıflandırma Sonuçları

		DVM Sınıflandırıcı
Ön İşleme	Burg Özbağlanım	%94,13
	Yule-Walker Özbağlanım	%92,88
	Kovaryans Özbağlanım	%94,25
	Değiştirilmiş Kovaryans Özbağlanım	%92,63

5. TEŞEKKÜR

Bu çalışma KSÜ Bilimsel Araştırma Projeleri Yönetim Birimi tarafından desteklenen 2010/5-8 YLS no'lu "Protez Kollar için EMG İşaretlerinin Sınıflandırılması ve Tanımlanması" adlı Yüksek Lisans Projesince desteklenmiştir.

6. KAYNAKLAR

- Ahmad S.A., Chappell P.H. 2007., Surface EMG Classification Using Moving Approximate Entropy. International Conference on Intelligent and Advanced Systems 2007, 1163-1167.
- Alkan A., Gunay M. 2010., Identification of EMG signals using discriminant analysis and SVM classifier, ISCSE 2010, Aydın/Kuşadası.
- Alkan A., Kıymık M.K. 2006., Comparison of AR and Welch Methods in Epileptic Seizure Detection J

Med Syst 30:413-419, DOI 10.1007/s10916-005-9001-0.

- Alkan A., Subaşı A., Kıymık M.K. 2005., Epilepsi Tanısında MUSIC ve AR Yöntemlerinin Karşılaştırılması, IEEE 13. Sinyal İşleme ve İletişim Uygulamaları Kurultayı (SİU'05) Kayseri, Türkiye.
- Asres A., Dou H., Zhou Z., Zhang Y. and Zhu S., "A combination of AR and neural network technique for EMG pattern identification.", 18th Annual International Conference of the IEEE Engineering in Medicine And Biology Society, 1996, Amsterdam, 1464-1465.
- Bronzino J. D. 1996., The Biomedical Engineering handbook, IEEE Pres, 3rd edition.
- Chan F.H.Y., Yang Y.S.Y., Lam F.K., Zhang Y.T., Parker P.A. 2000., Fuzzy EMG Classification for

Prosthesis Control. IEEE Transactions On Rehabilitation Engineering, 8(3):305-311.

8. Doerschuk P.C., Gustafson D.E. and Willisky A.S. 1983, Upper extremity limb function discrimination using EMG signal analysis, IEEE Transactions on Biomedical Engineering, 30, 1,18-29.

9. Englehart K., Hudgins B., Parker P.A. 1999., Stevenson M., Classification of the myoelectric signal using time-frequency based representations. Med Eng Phys., 21:431–438.

10. Fidan, C.B. 2001. Dirsek Üstü Kol Protezinin YSA Kullanılarak DSP Tabanlı Bir Devre ile Gerçek Zamanda Kontrolü. Yıldız Teknik Üniversitesi, Fen Bil. Enstitüsü Doktora Tezi.

11. Graupe D., Salahi, J. and Zhang, D. 1985., Stochastic analysis of myoelectric temporal signatures for multifunction single-site activation of prostheses and orthoses, Journal of Biomedical Engineering., 7, 1, 18-29, 1985.

12. Huang H.P., Liu Y.H., Liu L.W., Wong C.S. 2003., EMG Classification for Prehensile Postures Using Cascaded Architecture of Neural Networks with Self-organizing Maps. International Conference on Robotics & Automation, 1497-1502.

13. Hudgins B., Parker P.A. and Scott R.N. 1993., A new strategy for multifunction myoelectric control, IEEE Transactions on Biomedical Engineering, 40, 1, 82-94.

14. Kang W., Shiu J., Cheng C., Lai L., Tsao H. and Kuo T. 1995., The application of cepstral coefficients and maximum likelihood method in EMG pattern recognition, IEEE Transactions on Biomedical Engineering, 42, 777-785.

15. Karlık B., Tokhi O., Alcı M. A. 2003., Fuzzy Clustering Neural Network Architecture for Multi-Function Upper-Limb Prosthesis, IEEE Transactions on Biomedical Engineering, 50, 11, 1255-1261.

16. Karlık, B. 1994., Çok Fonksiyonlu Protezler İçin Yapay Sinir Ağları Kullanılarak Miyoelektrik Kontrol. Yıldız Teknik Üniversitesi, Fen Bil. Enstitüsü Doktora Tezi.

17. Khezri M., Jahed M., Sadati N. 2007., Neuro-Fuzzy Surface EMG Pattern Recognition for Multifunctional Hand Prosthesis Control. IEEE, 269-274.

18. Kocyiğit Y., Korürek M. 2005., EMG İşaretlerini Dalgacık Dönüşümü ve Bulanık Mantık Sınıflayıcı Kullanarak Sınıflama. Itüdergisi/d Mühendislik, 4(3):25-31.

19. Lucas M.F., Gaufriau A., Pascual S., Doncarli C., Farina D. 2008., Multi-Channel Surface EMG Classification Using Support Vector Machines and Signal-Based Wavelet Optimization Machines and Signal-Based Wavelet Optimization. Biomedical Signal Processing and Control, 3:169-174.

20. Oskoei M.A., Hu H. 2007., Myoelectric Control Systems. Biomedical Signal Processing and Control, 2:275-294.

21. Oskoei M.A., Hu H. 2008., Support Vector Machine-Based Classification Scheme for Myoelectric Control Applied to Upper Limb, IEEE Transactions on Biomedical Engineering, Vol. 55, No. 8

22. Proakis J.G., Manolakis D.G. 1996., Digital Signal Processing Principles, Algorithms, and Applications. Prentice-Hall, New Jersey.

23. Qian H., Mao Y., Xiang W., Wang Z. 2010., Recognition of human activities using SVM multi-class classifier, Pattern Recognition Letters, 31, 100–111.

24. Subasi A., Yilmaz M., Ozcalik H.R. 2006., Classification of EMG Signals Using Wavelet Neural Network. Journal of Neuroscience Methods, 156:360-367.

25. Şeker M., Tokmakçı M., Asyalı M.H., Seğmen H. 2010., Gebelik Sürecindeki Migrenli Hastalarda EEG Sinyallerinin Parametrik ve Parametrik Olmayan Spektral Analiz yöntemleri ile İncelenmesi, Biyomut 2010, Antalya, Turkey.

26. Ubeyli E. D., Guler I. 2004., Selection of optimal AR spectral estimation method for internal carotid arterial Doppler signals using Cramer-Rao bound. Comput. Electr. Eng. 30:491–508.

27. Wang A., Yuan W., Liu J., Yu Z., Li H. 2009., A novel pattern recognition algorithm: Combining ART network with SVM to reconstruct a multi-class classifier, Computers and Mathematics with Applications ,57 ,1908-1914.