



EMG Sinyallerinde Kas Yorgunluğunun YSA ile Sınıflandırılması

Muscle Fatigue Classification with ANN in EMG signals

Güzin ÖZMEN¹

Yüksel ÖZBAY¹

Ahmet Hakan EKMEKÇİ²

¹Elektrik ve Elektronik Mühendisliği Bölümü, Mühendislik Fakültesi

Selçuk Üniversitesi

{gozmen,yozbay}@selcuk.edu.tr

²Nöroloji Anabilim Dalı, Tıp Fakültesi

Selçuk Üniversitesi

hekmekci@selcuk.edu.tr

Özetçe

Bu çalışmada, 10 sağlıklı 10 boyun fıtığı hastası denekten servikal bölgedeki trapezius ve sternocleidomastoid kaslarından elde edilen Elektromiyogram sinyalleri, dinlenme-çalışma-yorulma durumları için kaydedilmiştir. Elektromiyogram sinyallerinden; Kısa Zamanlı Fourier Dönüşümü, Ayırık Dalgacık Dönüşümü ve AR yöntemleri ile öz nitelikler çıkarılmış ve dinlenme-çalışma ve yorulma olarak yapay sinir ağları ile sınıflandırılmıştır. Kas yorgunluğu verilerinin sınıflandırılmasında en iyi sonucu %99,98 sınıflama doğruluğu ile Ayırık Dalgacık Dönüşümü vermiştir. Her iki kas için de en kısa sınıflama süresi AR yöntemi ile elde edilmiştir.

Anahtar Kelimeler: EMG, KZFD, Dalgacık Dönüşümü, AR, YSA

Abstract

In this study, EMG signals obtained from trapezius and sternocleidomastoid muscles in cervical region, from 10 healthy and 10 patient subject which is suffered from cervical disc hernia, are recorded for resting-working-fatigue conditions. Features extracted from electromyography signals by Short Time Fourier Transform, Discrete Wavelet Transform and AR methods and classified resting-working-and fatigue through the Artificial Neural Network. In the classification of muscle fatigue datas, Discrete Wavelet Transform gives the best result with the classification accuracy %99,98. The best classification time is obtained through the AR methods for both two muscles.

Keywords: EMG, STFT, Wavelet Transform, AR, ANN

1. Giriş

Elektromiyogram (EMG), kasların dinlenme ve kasılma durumlarında oluşan elektriksel aktivite olarak tanımlanır. Kaslardaki elektriksel sinyallerin kayıt edilmesi, hem kaslarda hem de motor sistemdeki anormalliklerin teşhisinde önemli bilgiler sağlar [1].

EMG işareti kasa iğne elektrot yerleştirilerek ya da kas üzerindeki deriye yüzey elektrot bağlanarak saptanabilir [2]. Yüzey elektrotlar ile elde edilen yüzey EMG kayıtları, kas enerjilerinin değerlendirilmesini sağlayan, güvenilir, kolay ve non-invasive bir yöntemdir [3].

Bölgesel kaslarda, kuvvet üretim kapasitesinin azalması ile kasta oluşan rahatsızlık ve ağrı gibi belirtiler bölgesel kas yorgunluğunu işaret etmektedir [4]. Kas yorgunluğu oluşmuş bir kastan alınan yüzey EMG sinyalleri ile o kastan yorgunluk yok iken alınan sinyaller arasında farklılıklar mevcuttur. En genel iki değişiklik, güç spektrumunda alçak frekanslara doğru sinyalin frekans bileşenindeki kayma ve genlikteki artmadır [5].

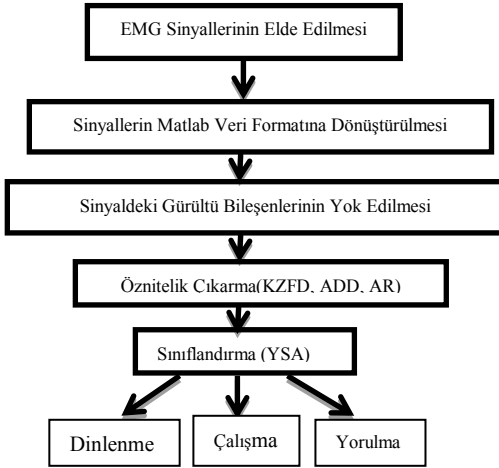
Boyun bölgesinde oluşan kas yorgunluğu istatistiksel yöntemlerle belirlenerek güç spektrumunun alçak frekanslara doğru kaydığı görülmektedir [6]. Bu çalışmada, dinlenme-çalışma-yorulma durumlarının sınıflandırılması Yapay Sinir Ağları (YSA) ile gerçekleştirilmiştir. Öz nitelik çıkarma yöntemi olarak kullanılan Kısa Zamanlı Fourier Dönüşümü (KZFD), Ayırık Dalgacık Dönüşümü (ADD) ve Oto-regresif (AR) yöntemlerinin aynı sınıflandırıcı mimarisi kullanılarak EMG sinyallerinden kas yorgunluğunun sınıflandırılmasındaki başarısı araştırılmıştır.

Sinyal İşleme 3

3. Gün 27 Eylül 2014 Cumartesi (11.45-13.00)

2. Yöntem


Bu çalışmaya ait blok diyagramı Şekil 1' de verilmiştir:



Şekil 1. Kas yorgunluğu sınıflandırma

Yüzeysel EMG kayıtları 10 normal; 10 hasta kişiden Selçuk Üniversitesi, Selçuklu Tıp Fakültesi Nöroloji Anabilim Dalında; hekim ve teknisyen kontrolünde, Neoropack Nihon Kohden marka EMG cihazı ile yüzeysel elektrotlar kullanarak elde edilmiştir. Çok kanallı EMG cihazının iki kanalı kullanılarak, tek bir kayıt pozisyonu için *trapezius* ve *sternocleidomastoid* (SCM) kaslarından eş zamanlı kayıt alınmıştır. Her bir kas için iki tane olmak üzere toplam dört adet Ag-AgCl yüzeysel elektrot, bir adet referans elektrot kullanılmış, referans elektrot gürültü problemini azaltması için sabit duran diğer bileğe yerleştirilmiştir.

Her bir katılımcıdan üç aşamada 10 khz' lik örnekleme frekansı ile yüzeysel EMG kayıtları alınmıştır. Dinlenme aşaması için; denekten dik oturma pozisyonunda kolunu hareket ettirmeden 20 sn beklemesi istenmiştir. Çalışma aşamasında deneye, dik oturma pozisyonunda, sağ kol yere paralel, sağ elindeki 1 kg' lık ağırlığı sağa-sola tam tur döndürürken, aynı zamanda boynuna, sol kolu yönünde sabit bir kuvvet uygulanmış ve boynunu sağ tarafına doğru 20 sn boyunca döndürmeye çalışması istenmiştir. Yorulma aşamasında, kişiden elindeki ağırlığı 20 sn boyunca, sağ kol yere paralel, hareket ettirmeden durması istenmiştir. EMG sinyal kayıt düzeneği Şekil 2' de görülmektedir.



Şekil 2. EMG sinyal kayıt düzeneği [7]

EMG sinyalleri, 2. Dereceden köşe frekansı 3-1000 Hz. olan butterworth band geçiren filtreye tabi tutulmuş ve dc bileşenleri yok edilmiştir.

Her bir EMG kaydı, öznitelik çıkarma aşamasında 395 adet 512 ayrı örnek içeren EMG segmentine dönüştürülmüştür. EMG segmentlerinden ise KZFD, ADD ve AR yöntemleri ile öznitelikler elde edilmiştir. EMG sinyallerinin öznitelikleri yapay sinir ağının girişlerini oluşturmuştur.

2.1. Öznitelik Çıkarma

Yüzeysel EMG sinyallerinden öznitelik çıkarmak için KZFD, ADD ve AR yöntemleri kullanılmıştır. KZFD sinyali pencereleme ile küçük segmentlere bölünmesi prensibine dayanır. Bu yöntem zamanla değişen sinyallerin analiz edilmesini sağlar; ancak analizin çözünürlüğü seçilen pencere boyu ile sınırlıdır [8]. Uzun pencere boyu seçildiğinde, frekans çözünürlüğü artar, zaman çözünürlüğü azalır. Pencere boyu kısa seçildiğinde zaman çözünürlüğü artarken, frekans çözünürlüğü azalır. Bunun yanında kullanılan pencere boyu sabit olmalıdır [9].

Zaman-frekans çözünürlüğündeki bu sorunun üstesinden gelmek için zaman-frekans ölçekli yöntemlerden ADD geliştirilmiştir. ADD, yüksek frekanslarda yüksek zaman çözünürlüğü ve düşük frekans çözünürlüğü, alçak frekanslarda ise yüksek frekans çözünürlüğü ve düşük zaman çözünürlüğünü sağlar [10]. KZFD ve ADD gibi klasik yaklaşımlarda, pencereleme dışında kalan veri sıfır kabul edilir. Böyle bir durum nadiren de gerçekleşse, bu varsayım spektral tahminde bir bozulmaya sebep olur [9].

Bu dezavantajı ortadan kaldırmak için kullanılan parametrik yöntemler ile daha iyi bir frekans çözünürlüğü elde edilir. AR, MA, ARMA gibi modern parametrik yöntemler, incelenecek sinyal için uygun bir model seçimine ve model parametrelerinin tahminine dayanır.



Sinyal İşleme 3

Sinyali modelleyen bu parametreler güç spektrumunun elde edilmesinde kullanılır. Sinyalin doğrudan kullanılmaması özellikle pencereleme işleminde pencere dışında kalan verinin sıfır kabul edilmesinden kaynaklanan kötü sonuçları ortadan kaldırır. AR metodu ile istatistiksel olarak daha kararlı (stabil) spektrumlar elde edilir [11].

Bu çalışmada KZFD için 512' lik uzunluğa sahip hamming pencere yapısı kullanılmıştır. Her pencerenin orijinal işaret üzerinde kaydırılma miktarını gösteren *noverlap* değeri %50 seçilmiştir. Öznitelik olarak güç spektral yoğunluğu seçilmiştir. Böylelikle her bir normal-hasta denek için ayrı ayrı elde edilen 512*395 EMG segmentinden 257*395'lik giriş verisi elde edilmiştir.

ADD ile her bir EMG segmenti D1-D6 ayrıntılı bandlarına ve A6 yaklaşık alt bandına ayrılmıştır. Bu çalışmada 2. seviye, 3. Seviye ve 4. Seviye Daubechies dalgacıkları kullanılarak, dalgacıkların sınıflandırma performansı üzerindeki etkisi gözlenmek istenmiştir.

Dalgacık frekans aralıklarına bakıldığında D1 ve D2 dalgacığında anlamlı EMG sinyali bulunmayacağından dolayı, ADD için öznitelik olarak, CA6, CD6, CD5, CD4, CD3 katsayıları seçilmiştir. DB2 kullanılarak her EMG segmenti için üçüncü, dördüncü, beşinci ve altıncı seviye detay dalgacık katsayıları (66+34+18+10 katsayı) ve altıncı seviye yaklaşım dalgacık katsayıları (10 katsayı) hesaplanarak toplam 138 dalgacık katsayısı elde edilmiştir. Aynı şekilde DB3 kullanılarak oluşturulan dalgacık katsayılarının toplamı (68+36+20+12+12 katsayı) 148 olarak hesaplanmıştır. DB4 kullanılarak oluşturulan dalgacık katsayılarının toplamı ise (70+38+22+14+14 katsayı) 158 olarak elde edilmiştir. Böylelikle her bir denek için, DB2 kullanılarak 138*395, DB3 kullanılarak 148*395 ve, DB4 kullanılarak 158*395 boyutunda giriş verisi elde edilmiştir [7].

Üçüncü öznitelik çıkarma yöntemi olarak kullanılan AR modelleme yönteminde 4. dereceden yule-walker, burg ve cov özbağlanım katsayıları öznitelik vektörleri, olarak seçilmiştir. Her bir normal-hasta denek için 5*395' lik giriş verisi elde edilmiştir.

2.2. Sınıflandırma

Bu çalışmada çok katmanlı yapay sinir ağı (ÇKA) kullanılmıştır. Çok katmanlı ağlar giriş katmanı, gizli katman ve çıkış katmanı olmak üzere üç katmandan oluşturulmuştur. Gizli katman aktivasyon fonksiyonu ve çıkış katman aktivasyon fonksiyonu 'logaritmik sigmoid' olarak seçilen bir ağ yapısı oluşturulmuştur. Bu ağ yapısı momentum ve adaptif öğrenme oranlı geriye yayılım algoritması (traingdx) ile eğitilmiştir. Sınıflandırma

3. Gün 27 Eylül 2014 Cumartesi (11.45-13.00)

sonunda eğitim hatası, test hatası, hassasiyet, seçicilik değerleri her bir yöntem için ayrı ayrı hesaplanarak birbirlerine göre üstünlükleri araştırılmıştır. Özniteliklere uygun sınıflayıcı modeli oluşturulurken sinir ağı eğitiminin daha verimli olması için oluşturulan giriş vektör setleri [0, 1.0] aralığında kalacak şekilde normalize edilmiştir.

3. Sonuçlar

Tablo 1' de Trapezius kasından, Tablo 2' de SCM kasından; KZFD, ADD ve AR ile elde edilen özniteliklere göre YSA sonuçları verilmektedir. Sınıflandırma sonuçlarında sınıflama doğruluğu, hassasiyet ve seçiciliğin belirlenmesi için karışıklık matrisi kullanılmıştır. Tablo 1' de karmaşıklık matrisi için gerekli bilgiler verilmiştir.

Tablo 1. Trapezius kası için Özniteliklere göre sınıflandırma sonuçları

	KZFD	Dalgacık-db2	Dalgacık-db3	Dalgacık-db4	AR-Yule	AR-Cov	f
Eğitime Hatası(%)	2.977	1.895	4.447	6.785	2.877	8.127	7.
Test hatası(%)	10.309	2.856	5.373	7.415	2.413	10.506	11
Süre (sn)	44.617	51.222	41.05	44.147	31.683	30.928	31
Hassasiyet(%)	82.3	92.3	74.2	58.48	91.179	34	6
Seçicilik-çalışma(%)	82.51	91.38	78.15	68.9	90.35	77.28	98
Seçicilik-dinlenme(%)	77.84	87.48	78.6	70.7	96.46	51.43	5.
Ortalama doğruluk(%)	80.88	90.39	77	65.72	92.66	54.2	7

Tablo 2. SCM kası için Özniteliklere göre sınıflandırma sonuçları

	KZFD	Dalgacık-db2	Dalgacık-db3	Dalgacık-db4	AR-Yule	AR-Cov	f
Eğitime Hatası(%)	2.151	0.916	1.7e-09	1e-10	11.099	0.196	4
Test hatası(%)	7.932	1.841	0.075	0.0097	12.275	0.110	5
Süre(sn)	56.425	50.353	44.178	41.129	30.542	29.609	33
Hassasiyet(%)	90.76	93.12	99.9	99.95	75.43	99.28	9
Seçicilik-çalışma(%)	75.28	90.71	99.79	100	53.33	100	6'
Seçicilik-dinlenme(%)	59.28	90.66	99.89	100	13.33	99.74	7.
Ortalama doğruluk(%)	75.11	91.50	99.88	99.98	46.37	99.67	7

Sınıflandırma sonuçlarında; ortalama sınıflama doğruluğu, hassasiyet ve seçiciliğin belirlenmesi için karışıklık matrisi kullanılmıştır. Tablo 3' de karışıklık matrisi için gerekli bilgiler verilmiştir.



Sinyal İşleme 3

3. Gün 27 Eylül 2014 Cumartesi (11.45-13.00)

Tablo 3. Karmaşıklık matrisi

	Negatif	Pozitif
Negatif	Doğru Negatif (DN)	Yanlış Pozitif (YP)
Pozitif	Yanlış Negatif (YN)	Doğru Pozitif (DP)

Buna göre sınıflama doğruluğu denklem (1) ile, hassasiyet (2) ile ve seçicilik (3) ile elde edilmiştir [12].

$$\text{Sınıflama doğruluğu (SD)} = \frac{DP+DN}{DP+DN+YP+YN} \times 100 \quad (1)$$

$$\text{Hassasiyet (H)} = \frac{DP}{DP+YN} \times 100 \quad (2)$$

$$\text{Seçicilik (S)} = \frac{DN}{YP+DN} \times 100 \quad (3)$$

Tablo 1' e göre gibi trapezius kasından dinlenme-çalışma-yorulma durumları için alınan EMG işaretlerini sınıflamada db2 ana dalgacığı kullanılan ADD ve yule-walker AR parametreleri, diğerlerine göre daha başarılıdır. En iyi sonucu % 92.66 sınıflama doğruluğu ile yule-walker katsayıları vermektedir. En kısa sınıflama süresi ise kovaryans metodu ile elde edilmiştir. Tablo 2' ye göre SCM kasından dinlenme-çalışma-yorulma durumları için alınan EMG işaretlerini sınıflamada db3 ve db4 ana dalgacığı kullanılan dalgacık dönüşümü diğerlerine göre daha başarılıdır. En iyi sonucu % 99.98 sınıflama doğruluğu ile db4-Dalgacık katsayıları vermektedir. En kısa sınıflama süresi ise kovaryans metodu ile elde edilmiştir. Sonuçlardan görüldüğü gibi; trapezius kası için en iyi sonuçları AR yöntemi, SCM kası için en iyi sonuçları ADD yöntemleri vermektedir. Bu çalışma ile aynı YSA mimarisinde farklı öznelik çıkarma yöntemlerinin performansları karşılaştırılmıştır. Yapılan kaynak araştırmasında KZFD' nin zaman ve frekans çözünürlüğü arasında bulunan dengesizliğinden dolayı durağan olmayan sinyallerde tercih edilmediği, onun yerine zaman ölçekli bir yöntem olan ADD' nin tercih edildiği görülmüştür.

Bu çalışmada, sınıflandırma performanslarına bakıldığında, KZFD' nin diğer yöntemlerden daha başarısız olduğu görülmektedir. AR ve ADD yöntemleri ise EMG gibi durağan olmayan işaretlerden zaman-frekans bilgisi elde etmek için daha etkili araçlardır.

4. Kaynaklar

- [1] Bronzino, J.D., "The biomedical engineering handbook", Second edition, CRC PresLLC, Boca Raton: FL, 2000.
- [2] Kimura, J. , "Electrodiagnosis in disease of nerve and muscle: principles and practice", Philadelphia, 1983.
- [3] Criswell,E., "Cram's introduction to surface electromyography" Jones & Bartlett Publishers, 2010.
- [4] Biedermann, H., Shanks, G. and Forrest, W., Inglis, J., "Power spectrum analyses of electromyographic activity: Discriminators in the differential assessment of patients with chronic low-back pain", *Spine*, 16, 1179-1184,1991.
- [5] Moussavi, K. , Cooper, J. E. and Shweddyk, E., "Fatigue Pattern Of Trapezius Muscle In Relation To Its Functional Role", *18th Annual International Conference of the IEEE*, 1996.
- [6] Özmen, G., Özbay,Y. ve Ekmekçi,A.H., "Servikal bölgede frekans özelliklerini kullanarak kas yorgunluğu değerlendirilmesi", *SIU2014*, Trabzon, 2014.
- [7] Özmen, G. "Servikal bölgede oluşan kas yorgunluğunun yüzey elektromiyogram bilgileri ile değerlendirilmesi", Selçuk Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 2013.
- [8] Miner, N., "An Introduction to Wavelet Theory and Analysis", *Sandia National Laboratories*, 1998.
- [9] Semmlow, J.L., " Biosignal and Bimedical Image Processing Matlab-Based Applications", *Marcel Dekker ,Inc*,2004.
- [10] Koçyiğit, Y. ve Korürek M., "EMG işaretlerini dalgacık dönüşümü ve bulanık mantık sınıflayıcı kullanarak sınıflama", *İtÜdergisi/d mühendislik* Cilt:4, Sayı:3, 2005.
- [11] Güler, İ., Kıymık, M. K., Akın, M. and Alkan, A., "AR spectral analysis of EEG signals by using maximum likelihood estimation", *Computers in Biology and Medicine*, 31, 441-450, 2001.
- [12] Polat, K., Kar,a S., Latifoğlu, F. and Güneş, S.,2007, Pattern detection of atherosclerosis from carotid artery doppler signals using fuzzy weighted pre-processing and least square support vector machine (LSSVM), *Annals of Biomedical ENgineering*, Vol.35, No.5, pp. 774-732