

# Nöromuskuler Kas Aktivitelerinin Sınıflandırılmasında çapraz İlinti Kestirimleri

## Estimation of Cross Correlation in Classifying Neuromuscular Activities

Serap AYDIN<sup>1</sup>

<sup>1</sup>Biyomedikal Mühendisliği Bölümü, Mühendislik ve Doğa Bilimleri Fakültesi  
Bahçeşehir Üniversitesi

drserapaydin@hotmail.com , serap.aydin@eng.bau.edu.tr

### Özet

*Bu çalışmada; sırasıyla doğrusal, doğrusal olmayan ve istatistiksel yaklaşımlar kullanan Fourier Korelasyonu, Wavelet Korelasyonu (WK) ve Pearson Korelasyonu yöntemleri, iki simetrik kastan fiziksel hareketler sırasında ölçülen elektriksel kas aktiviteleri ilintilerin kestiriminde kullanılmış ve sınıflandırma performansı açısından kıyaslanmıştır. Uluslar-arası erişime açık UCI (Unv. of California Irvine) veri tabanından sağlanan deneysel veriler 4 bireyden 10 farklı fiziksel davranış sırasında 8 yüzey elektrotu ile ölçülen agresif ve normal kas aktivitelerini içermektedir. Üç yöntemle her iki simetrik kanal çifti için elde edilen özellikler Destek Vektör Makineler yardımıyla sınıflandırılmıştır. EMG sinyalleri durağan olmadığı için ve sağ-sol uzuv (kol, bacak) hareketlerinde aynı tip kasın ürettiği elektriksel aktivitelerin karakteristiği aynı olduğu için; fiziksel kas aktivasyonlarının sınıflandırılmasında en iyi performansı sağlayan yaklaşım WK yöntemidir. Normal fiziksel hareketlerde oluşan simetrik EMG sinyalleri arasındaki ilinti, agresif fiziksel hareketlerde oluşan ilintiden yüksektir.*

### Abstract

*In the present study, linear, non-linear and statistical approaches so named Fourier Correlation, Wavelet Correlation (WC) and Pearson Correlation, respectively have been used to estimate cross-correlations between electrical muscle activities collected from two symmetric muscles and the these methods have been compared to each other with respect to classification performance. Experimental data, provided by UCI (Unv. of California Irvine), including aggressive and normal measurements collected from 4 volunteers through eight surface electrodes during 10 different physical activities. The features, which are obtained by using those 3 methods for each electrode pair, are classified by using Support Vector Machines. Since, EMG series are nonstationary and the same muscle groups on right and left limbs (arm, leg) produce almost the same electrical activities, WC is found to be the best method in classifying physical muscle actions. The cross-correlation between EMG series from normal actions is much higher than that of aggressive muscle actions.*

### 1. Giriş

Electro-Myo-Graphy (EMG) sinyalleri, kasların yüzeyinden veya derinden ölçülebilen elektriksel sinyallerdir [1]. EMG ölçümleri; kas hastalıklarının tanı ve tedavi izleme aracı olarak uygulamalı bilimlerde [2,3], insan vücudunun sinir-kas sisteminin çalışma prensibinin anlaşılmasını sağlayan tamamlayıcı araç olarak temel bilimlerde araştırma konusudur [4,5].

EMG analizinde, genellikle sadece tek kanalın analizi bağımsız yapılır ve ilgili kayıt bölgesi hakkında yorum yapılır. EMG araştırmalarında iki simetrik uzvun aynı tip kasına ait eş-zamanlı EMG ölçümleri arasındaki korelasyonlar ise ilk kez bu çalışmada düzenlenmiştir. Sağlıklı bireyler için, tipik bir fiziksel aktivite sırasında aynı tipte ve simetrik olarak vücudun aynı bölgesinde yer alan kasların senkron sinyaller üretmesi gerektiği hipotezinden hareket edilmiştir ve sonuçlar bu hipotezi doğrulamıştır. Elektriksel kas aktivasyonları arasındaki ilintilerin kestiriminde kullanılan; doğrusal, doğrusal olmayan ve istatistiksel hesaba dayalı üç farklı yöntem izleyen bölümde tanımlanmıştır.

### 2. Yöntem

Bu çalışmada, iki sinyal arasındaki ortak davranış seviyesini ölçülebilen doğrusal, doğrusal olmayan ve istatistiksel hesaba dayalı, Fourier Korelasyon (FK), Wavelet Korelasyon (WK) ve Pearson Korelasyon yöntemleri, EMG sinyalleri arasındaki ilintinin kestirimi probleminde uyarlanarak kullanılmıştır. 8 ölçüm kanalının her bir simetrik yerleşik elektrot çifti (4 ayrı elektrot çifti) için hesaplanan ilinti değerlerine göre normal ve agresif fiziksel aksiyonlar, Destek Vektör Makineleri (DVM) yardımıyla sınıflandırılmıştır. Deneysel veriler ve kullanılan yöntemler izleyen bölümlerde tanımlanmıştır.

#### 2.1. Deneysel Veri

Bu çalışmada, uluslar-arası standartlara uygun kaydedilmiş ve erişime açık UCI (University of California, Irvine) veri tabanında yer alan fiziksel aktivasyon kas sinyalleri alınmıştır [6]. Bu sinyaller, yaşları 25 ile 30 arasında değişen 3 erkek ve 1 bayan gönüllüden, diz atma ve tokat atma gibi normal ve agresif kas aktiviteleri sırasında, sağ ve sol uzuvlardan (kol ve bacak kaslarından) toplanmıştır. Her bir EMG kayıt diliminin

süresi 10 saniyedir. Ölçümlerde 10 kHz örnekleme frekansı kullanılmıştır. 8-kanal EMG ölçüm elektrotlarından; 1.kanal (Ch.1) sağ üst kol kasına (biceps), 2.kanal (Ch.2) sağ arka kol kasına (triceps), 3.kanal (Ch.3) sol üst kol kasına (biceps) ve 4. kanal (Ch.4) sol arka kol kasına (triceps) yerleştirilmiştir. Diğer 4 kanal ise bacak kaslarına yerleştirilmiştir: 5.kanal (Ch.5) sağ uyluk (right thigh) kasına, 6.kanal (Ch.6) sağ diz arka kasına (right hamstring), 7.kanal (Ch.7) sol uyluk (left thigh) kasına ve 8.kanal (Ch.8) sol diz arkası kasına (left hamstring) yerleştirilmiştir.

### 2.1. Çapraz Korelasyon Kestirim Yöntemleri

Uzuvların (kol/bacak) aynı tip (biceps / triceps / thigh / hamstring) kaslarına simetrik olarak yerleştirilen EMG elektrotlarından toplanan iki zaman serisi,

$$x(t) = [x(1) \ x(2) \ \dots \ x(N)] \quad (1) \quad y(t) = [y(1) \ y(2) \ \dots \ y(N)] \quad (2)$$

sembolleri ile ifade edildiğinde, bu iki zaman serisinin istatistiksel olarak birbirini nasıl takip ettiği, Pearson Katsayısı (PK) kullanılarak hesaplanabilir. Eş-zamanlı ölçülmüş bu iki EMG sinyalinin istatistiksel korelasyonunun PK cinsinden ölçülmesinde izleyen eşitlik kullanılmalıdır:

$$PK_{x,y} = \frac{1}{N} \sum_{k=1}^N \frac{(x(k)-\mu_x)(y(k)-\mu_y)}{\sigma_x \sigma_y} \quad (3)$$

Burada, N sayısı bir kayıt diliminde yer alan örnek sayısını simgeler.  $\mu$  ve  $\sigma$  değişkenleri ise; zaman serilerinin ortalama değerini ve standart sapmasını sembolize etmektedir.

PK kestiriminin zaman düzleminden frekans düzlemine ( $f$ ) genişletilmiş versiyonu ise Fourier Korelasyonu (FK) olarak adlandırılabilir ve izleyen eşitlik kullanılarak hesaplanır:

$$FK_{x,y}(f) = \frac{|P_{xy}(f)|^2}{\sqrt{P_x(f)P_y(f)}} \quad (4)$$

Burada  $P_x(f)$  ve  $P_y(f)$ ,  $x(t)$  ve  $y(t)$  sinyallerinin güç dağılım yoğunluğunu,  $P_{xy}(f)$  ise  $x(t)$  ve  $y(t)$  sinyalleri arasındaki çapraz güç dağılım yoğunluğunu simgeler. Eğer  $x(t)$  ve  $y(t)$  sinyalleri ilintili değil ise;  $FK_{x,y}$  değeri sıfır olacaktır. Eğer  $x(t)$  ve  $y(t)$  sinyalleri birbiriyle ilintili ise;  $FK_{x,y}$  değeri 1 olacaktır. Uygulamalarda, güç dağılım yoğunlukları, 256-nokta FFT kullanılarak hesaplanmıştır.

Eğer,  $FK_{x,y}$  hesabında Fourier dönüşümü yerine Wavelet Dönüşümü (WD) kullanılırsa Wavelet Korelasyonu (WK) elde edilebilir. EMG sinyallerinin WD izleyen eşitliklerle tanımlanır;

$$W_x(\tau, s) = \frac{1}{\sqrt{s}} \int_{-\infty}^{+\infty} x(t) \psi^* \left( \frac{t-\tau}{s} \right) dt \quad (5)$$

$$W_y(\tau, s) = \frac{1}{\sqrt{s}} \int_{-\infty}^{+\infty} y(t) \psi^* \left( \frac{t-\tau}{s} \right) dt \quad (6)$$

WK kestirimi,

$$W_{xy}(\tau, s) = W_x(\tau, s)W_y(\tau, s)^* \quad (7)$$

eşitliği yardımıyla elde edilir. Burada  $\psi(t)$  sembolü ana wavelet fonksiyonunu temsil etmektedir. Bu çalışmada

$\psi(t) = \pi^{-1/4} e^{i\omega t} e^{-1/2t^2}$  ile tanımlanan karmaşık sinüsoidal wavelet fonksiyonu üretilmiştir. Eşitliklerde kullanılan;  $\tau$  ve  $s$  sembolleri, ölçek (scale) ve dönüşüm (translation) tanımlarını belirtmek için kullanılmıştır. İki sinyal arasındaki doğrusal olmayan WK kestirimi izleyen eşitlik kullanılarak elde edilebilir.

$$W_{xy}(\tau, s) = W_x(\tau, s)W_y(\tau, s)^* \quad (8)$$

Hesaplamalarda varyans normalizasyonu yöntemi uygulanmıştır.

### 2.2. DVM ve Sınıflandırma Performans Ölçütleri

DVM, fizyolojik sinyallerin sınıflandırılmasında kullanılan en popüler makine öğrenme algoritmasıdır [7-9]. İki katmanlı ve ileri beslemeli yapıdaki bu yapay sinir ağında kernel fonksiyon olarak bu çalışmadan Gaussian Radyal temel fonksiyonu kullanılmıştır. Öğrenme ve sınıflandırmada deneysel olarak seçilen kutu kısıtlaması ve ölçekleme faktörü (box constraint and scaling factor) parametreleri, 0.05 ve 1 dir. Performans ölçmek için tanımları gelenekselmiş olan Sınıflandırma Doğruluğu (SD), Sınıflandırma Hassasiyeti (SH) ve sınıflandırma Duyarlılığı (DY) kullanılmıştır.

### 3. Sonuçlar

4 kişiden kaydedilen 10 saniye uzunluğundaki EMG sinyallerinin her bir 1 saniyelik dilimine uygulanan ilinti kestirim yöntemleri yardımıyla 4 farklı elektrot çifti için elde edilen özellikler, durum sınıflandırma (classification of instances) prensibine dayalı olarak ve DVM kullanılarak sınıflandırılmıştır. DVM uygulamalarında 10-kat çapraz validasyon (10-fold cross validation) yapılmıştır. Hem agresif fiziksel hareketleri kapsayan hem de normal fiziksel hareketleri kapsayan olaylar, birbirine zıt hareket tanımına uymasına göre ikili olaylar gruplanmıştır. Sınıflandırılan normal kas olayları ve agresif kas olaylarına ilişkin sınıflandırma performans sonuçları sırasıyla Tablo-1 ve Tablo-2'de verilmiştir.

Çizelge-1. Normal kas hareketlerinin sınıflandırma performansları

	SD (%)	SH (%)	DY (%)
<b>Wavelet Korelasyonları</b>			
Running/Hugging	99.31	100.0	98.61
Handshaking/Clapping	90.97	93.06	88.89
Seating/Standing	71.53	91.67	51.39
<b>Fourier Korelasyonları</b>			
Running/Hugging	78.47	70.83	86.11
Handshaking/Clapping	74.31	77.78	70.83
Seating/Standing	57.64	47.22	68.06
<b>Pearson Korelasyonları</b>			
Running/Hugging	70.83	69.44	72.22
Handshaking/Clapping	68.06	73.61	62.50
Seating/Standing	72.22	55.56	88.89

Çizelge -1'den, %99.31 gibi yüksek bir doğrulukla Wavelet korelasyonlarının, iki zıt normal olayın (koşmak (running) ve kolları vücuda sarılı halde sabit durması (hugging) sınıflandırılma sağladığı gözüküyor. Oturma (Seating) ve ayakta durma (Standing) gibi daha statik fiziksel kas olaylarının çapraz EMG ilintisine göre sınıflandırılmasında ise %71.53 ile en düşük sınıflandırma başarısı elde edilmiştir.

Çizelge 2. Agresif kas hareketlerinin sınıflandırma performansları

	SD	SH	DY
<b>Wavelet Korelasyonları</b>			
Hammering / Headering	72.22	69.44	75.00
Slapping / Elbowing	88.19	90.28	86.11
Kneeing / Pulling	78.47	77.78	79.17
<b>Fourier Korelasyonları</b>			
Hammering / Headering	68.06	58.33	77.78
Slapping / Elbowing	67.36	68.06	66.67
Kneeing / Pulling	63.89	72.22	55.56
<b>Pearson Korelasyonları</b>			
Hammering / Headering	59.03	54.17	63.89
Slapping / Elbowing	61.81	50.00	73.61
Kneeing / Pulling	74.31	70.83	77.78

Çizelge-2'den, %88.19 oranında doğrulukla Wavelet korelasyonlarının, tokat atma (Slapping) ve Dirsek atma (Elbowing) olaylarının sınıflandırılma sağladığı gözüküyor. Çekiç tutma (Hammering) ve çekiç kaldırma (Headering) olaylarının sınıflandırılması ise ancak %72.22 doğrulukla en düşük performansla elde edilebilmiştir.

Her iki çizelge kıyaslandığında ise; en yüksek sınıflandırma başarısının normal kas olaylarında ve WK yöntemi kullanılarak elde edildiği görülüyor.

#### 4. Yorum

Bu çalışmada elde edilen sonuçlar, durağan olamayan fizyolojik bir sinyal olan EMG sinyallerinin analizinde doğrusal olmayan Wavelet korelasyon kestirim yönteminin elverişli yöntem olduğu gösterilmiştir. Normal fiziksel kas olaylarında kas hücrelerinin ürettiği elektriksel sinyallerinin agresif fiziksel hareketler sırasında aynı kas hücreleri tarafından üretilen elektriksel sinyallerden daha fonksiyonel olduğu ve sağlıklı bireylerin aynı tip ve simetrik uzuvlarında yerleşik (sağ ve sol kol ve bacak) kasların eş-zamanlı olarak aynı fiziksel olay karşısında benzer karakterde sinyal ürettiğini göstermektedir.

#### Kaynaklar

- [1] E.G. Saulnier, C. Auchincloss, L. McLean (2016) Electromyography, *The Overactive Pelvic Floor*, 175--203
- [2] P. Karthikeyan, M. Murugappan, S. Yaacob (2012) EMG Signal Based Human Stress Level Classification Using Wavelet Packet Transform, *Trends in Intelligent Robotics, Automation, and Manufacturing, Series Communications in Computer and Information Science* 330, 236--243
- [3] S. Parasuraman, Arif Wicaksono Oyong, Veronica Lestari Jauw (2010), Robot Assisted Stroke Rehabilitation: Joint Torque/Force Conversion from EMG Using SA Process, *Intelligent Robotics and Applications, Series Lecture Notes in Computer Science*, 6425, 612--623
- [4] D. Gradolewski, P.M. Tojza, J. Jaworski, et al. (2015) Arm EMG Wavelet-Based Denoising System, *Mechatronics - Ideas for Industrial Application, Vol. of*

*the series Advances in Intelligent Systems and Computing*, 317, 289--296

- [5] P.R. Pal, et al. (2011) Expert System Design Based on Wavelet Transform and Linear Feature Selection, *Computer Networks and Intelligent Computing, Series Communications in Computer and Information Science*, 157, 502-510
- [6] UCI Lichman, M. (2013). UCI Machine Learning Repository [http://archive.ics.uci.edu/ml]. Irvine, CA: University of California, School of Information and Computer Science.
- [7] Aydın S, Arica N, Ergül E, Tan O, (2015) "Classification of obsessive compulsive disorder by EEG complexity and hemispheric dependency measurements", *Int J. of Neural Systems*, 25(3):1550010
- [8] Y. Liu, W. Zhou, Q. Yuan, S. Chen (2012) Automatic Seizure Detection Using Wavelet Transform and SVM in Long-Term Intracranial EEG, *IEEE Trans on Neural Systems and Rehabilitation Eng.* 20(6), 749--755.
- [9] L. Guo, Y. Wu, L. Zhao, et al. (2011) Classification of Mental Task From EEG Signals Using Immune Feature Weighted Support Vector Machines, *IEEE Trans on Magnetism*, 47(5), 866-- 869