

Normal ve Agresif Kas hareketlerinin Elektrofizyolojik Entropiler Cinsinden Sınıflandırılmasında Destek vektör Makineleri

Support Vector Machines in Classifying Normal and Aggressive Muscle Actions of Electrophysiological Entropies

Serap AYDIN¹, Süreyya AKYÜZ²

^{1,2}Biyomedikal Mühendisliği Bölümü, Mühendislik ve Doğa Bilimleri Fakültesi
Bahçeşehir Üniversitesi, Beşiktaş, İstanbul
drserapaydin@hotmail.com¹, serap.aydin@eng.bau.edu.tr¹, sureyya.akyuz@eng.bau.edu.tr²

Özet

Bu çalışmada; sağlıklı gönüllülerden normal ve agresif fiziksel hareketler esnasında kol ve bacak kaslarından kaydedilmiş 8-kanal yüzey EMG kayıtlarının altı farklı yöntem kullanılarak (Lempel-Ziv Entropi, Shannon Entropi (ShanEn), Logaritmik Enerji Entropi, Yaklaşık Entropi, Örnek Entropi, Permütasyon Entropi (PermEn)) karmaşıklık seviyeleri hesaplanmış ve üç farklı özellik grubuna göre (tüm kanallar, sadece kollar, sadece bacaklar) sınıflandırılmıştır. Sınıflandırmada; doğrusal olmayan Destek Vektör Makineleri, 5-katlı çapraz validasyon tekniği ile kullanılmıştır. Sonuçlar; kas hücrelerinin uyarılmasını sağlayan uyarıcı parametrelerinin EMG sinyallerinin karmaşıklık seviyesini etkilediğini göstermiştir. En iyi sınıflandırma performansını sağlayan kestirimler ShanEn ve PermEn yaklaşımlarıdır. Her iki yöntemin performansı birbirine zıt fiziksel kas hareketlerin sınıflandırılmasında marjinal fonksiyon ile Topluluk Öğrenmesi yöntemi kullanıldığında artmıştır. EMG analizlerinde ölçümler bölütlenmelidir.

Abstract

In the present study, entropy values of EMG series, collected from arms and legs of healthy volunteers by using 8 recording channels in both normal and aggressive actions, by using six different methods (Lempel-Ziv Entropy, Shannon Entropy (ShanEn), Logarithmic Energy Entropy, Approximate Entropy, Sample Entropy, Permutation Entropy (PermEn)) have been classified with respect to three feature sets (all channels, only arms, only legs). In classification step; non-linear Support Vector Machines with 5-fold cross validation was examined. The results show that stimulus parameters that stimulate muscle cells affect the level of complexity of EMG series. ShanEn and PermEn provide the best performance in classifying physical actions by means of EMG. The performance of both approaches have been improved by using Ensemble Learning with marginal function in classifying contrast physical actions. Measurements must be segmented to analyze EMG series.

1. Giriş

Entropi durağan olmayan zaman serilerinin taşıdığı bilgiyi ölçmek amacıyla kullanılan bir sayısal ölçüttür. Bilgi Kuramı (information theory) göre; bir sayısal sinyalin olasılıksal yoğunluk fonksiyonu biliniyorsa, o sinyalin taşıdığı bilgi entropi değeri cinsinden hesaplanabilir. EEG ve EMG gibi elektrofizyolojik sinyaller, durağan olmayan rastgele zaman serileri olduğu için, birinci ve ikinci dereceden istatistiksel bilgileri ve entropi kestirimleri araştırma konularıdır [1]. Uyarılabilir hücre tipi olan kas hücrelerinin ürettiği aksiyon potansiyellerinin toplamı olarak kaydedilen EMG ölçümleri, hem tanı amaçlı uygulamalı araştırmalarda [2,3], hem de var olan kas sisteminin ve fonksiyonlarının anlaşılması amaçlı temel bilim araştırmalarında [4,5] kullanılmaktadır.

Bu çalışmada altı farklı entropi yaklaşımı, ilk kez fiziksel kas aksiyonlarının sınıflandırılması için ve EMG amacıyla uygulanmıştır. EMG karakterizasyon yeteneği açısından yöntemlerin başarısını ölçmek için doğrusal olmayan DVM ve fonksiyonel marjin ile Topluluk Öğrenmesi (TÖ) kullanılmıştır. Deneysel veri ve uygulanan yöntemler izleyen bölümlerde tanıtılmıştır.

2. Yöntem

2.1. Deneysel Ölçümler ve Veri Toplama

Bu çalışmada analiz edilen ve uluslararası ölçüm standartlarına uygun 8-kanal EMG veri seti, UCI (University of California, Irvine) veri tabanından yüklenmiştir [6]. Gönüllü katılımcılar; yaşları 25 ile 30 arasında değişen sağlıklı yetişkinlerden (3 erkek ve 1 bayan) oluşmaktadır. 10 kHz örnekleme frekansına göre kaydedilen EMG sinyallerinin kayıt süresi 10 saniyedir. Aşağıda listelenen ve birbirine zıt normal ve agresif fiziksel kas hareketleri esnasında EMG ölçümleri için 8 yüzey elektrotu kol ve bacakların ön (Ch.1 ve Ch.3: sağ ve sol üst kol kasları (biceps), Ch.5 ve Ch.7: sağ ve sol uyluk (right and left thigh)) ve arka (Ch.2 ve Ch.4: sağ ve sol arka kol kasları (triceps), Ch.6 ve Ch.8: sağ ve sol diz arkası kasları (right and left hamstring)) yerleştirilmiştir. Normal Aksiyonlar (NA) ve Agresif Aksiyonlar (AA) izleyen isimlerle gruplandırılmıştır: NA-1: Running/Hugging, NA-2: Handshaking/Clapping,, NA-3: Seating/Standing,, AA-1:

Hammering/Headering, AA-2: Slapping / Elbowing, AA-3: Kneeing / Pulling.

Tek-kanal entropi kestirimlerinden oluşturulan özellik setleri izleyen biçimde isimlendirilmiştir: Birinci Özellik Seti (ÖS-1) tüm yüzel kanallarının entropilerini içerir, İkinci Özellik Seti (ÖS-2) kol kaslarına ait entropileri içerir, Üçüncü Özellik Seti (ÖS-3) bacak kaslarına ait entropileri içerir.

2.2. Entropi Kestirim Yöntemleri

Bilgi teoreminde entropi kestirimi amacıyla önerilen en eski yöntem Lempel-Ziv Entropi (LzEn) yaklaşımıdır ve izleyen eşitlikle tanımlanır;

$$H_{LzEn} = - \sum_{i=0}^{N-1} p_i(x) \log_2(p_i(x))$$

Burada, $p_i(x)$ olasılıksal dağılım fonksiyonunu simgeler ve i indisi ayrı zaman indisidir. Daha hassas entropi hesabı için Shannon Entropi (ShanEn) ve Logaritmik Enerji Entropi (LogEn) izleyen eşitliklerle tanımlanmıştır;

$$H_{ShanEn} = - \sum_{i=0}^{N-1} (p_i(x))^2 (\log_2(p_i(x)))^2$$

$$H_{LogEn} = - \sum_{i=0}^{N-1} (\log_2(p_i(x)))^2$$

Analiz edilen zaman serisinin rastgele olması ve kısa zaman dilimleri içinde karmaşıklık seviyesinin nasıl değiştiğini ölçmek amacıyla zaman serilerinin kayar pencere ile bölütlenmesi Approximate Entropi (ApEn) yöntemi ile önerilmiştir.

$$H_{ApEn} = \frac{1}{N-m+1} \sum_{i=1}^{N-m+1} \frac{\# \text{ of } |x_m(i), x_m(i+1)| \leq r}{N-m+1}$$

Burada m indisi segmentasyon sayısını ve x_m simgesi ise segmente edilmiş zaman serisi bölütünü simgeler. İki kayar pencere ile bölütlenmiş ve aynı boyuta sahip iki alt vektör arasındaki benzerlik toleransı r ile simgelenmiştir. ApEn yönteminin geliştirilmiş biçimi ise Sample Entropi (SampEn) olarak isimlendirilir ve izleyen eşitlikle tanımlanır;

$$H_{SampEn} = \frac{\sum_{i=1}^{N-m+1} \# \text{ of } |x_m(i), x_m(i+1)| \leq r}{\sum_{i=1}^{N-m+1} \# \text{ of } |x_{m+1}(i), x_{m+1}(i+1)| \leq r}$$

Bu yaklaşımlardan tamamen farklı olarak gömülü boyut (segmentasyon boyutu) oranında permütasyon hesabının bilgi teoremine dahil edildiği PermEn yöntemidir ve,

$$H_{PermEn} = - \sum_{i=1}^N p_i(x_m) \frac{\ln(p_i(x_m))}{\ln(m!)}$$

eşitliği ile tanımlanır [7,8].

2.3. Doğrusal Olmayan DVM ve Kernel Seçimi

Güçlü bir algoritmik alt yapıya sahip olduğu için, bu çalışmada elektrofizyolojik kas aksiyonlarının entropi kestirimleri cinsinden sınıflandırılmasında DVM kullanılmıştır. Küçük eğitim verisiyle öğrenme adımını tamamlayarak genel optimuma ulaşabilen DVM, yüksek boyutlu az sayıda veri içeren eğitim kümelerinde de başarılıdır [9]. DVM sınıflandırma probleminin en temeli, doğrusal olarak ayrılabilir durumudur. Temel mantığı, girdi uzayı üzerinde doğrusal olarak ayrılabilir veriler için en iyi hiper

düzlemin belirlenmesidir. Doğrusal olarak ayrılabilir durumlarda bu veriler hiper düzlem denilen bir düzlemlerle doğrudan ayrılabilirler. Diğer bir durum ise doğrusal olarak ayrılabilir durumudur. Bu durumda DVM, kernel fonksiyonları yardımıyla daha yüksek boyutlu bir uzaya taşınır ve özellik öznitelik uzayında doğrusal ayrılabilir duruma gelir. Gerçek hayat problemlerinde veri her zaman doğrusal ayrılabilir olmadığı için bu çalışmada doğrusal olmayan DVM kullanılmıştır.

DVM, girdileri doğru sınıflandırabilmek için eğitim kümesi (x_i, y_i) ($i = 1, 2, \dots, N$) kullanarak model oluşturmaktadır. N adet veri vektörü ve n - boyutlu uzayda $x_i \in R^n$ ($i = 1, 2, \dots, N$) olmak üzere, veri vektörlerine karşılık gelen sınıf etiketi $y_i \in \{-1, 1\}$ olsun. Bu çalışmada sınıf etiketleri kas hareketlerini temsil etmektedir, örneğin +1 etiketi ikili kas aktivasyonunun ilkini, -1 etiketi ise ikinci kas aktivasyonunu simgelemiştir. Sınıfları ayıracak olan hiper düzlem, $w \in R^n$ ağırlık vektörü (hiper düzlemin normali), $b \in R$ sapma terimi (*bias*) olmak üzere izleyen denklem ile tanımlanır.

$$f(x) = \langle w, x \rangle + b = \sum_{i=1}^N w_i x_i + b$$


İle tanımlanır. İki sınıftan oluşan veri kümesindeki veriler, iki sınıflı sınıflandırma probleminde bu denklem ile ayrılmakta ve hiper düzlem üzerindeki bütün noktalar aynı denklemi sağlamaktadır. Doğrusal sınıflandırma için karar fonksiyonu, $f: R^n \rightarrow R$ olmak üzere, iki sınıf arasındaki uzaklığı maksimize ederek ayırıcı hiper düzlemi bulan optimizasyon modeli aşağıdaki *Özgün (Primal) Problem* ile tanımlanmıştır;

$$\min_{w, b, \xi} \frac{1}{2} \|w\|^2 + C \sum_{i=1}^N \xi_i$$

kısıtlar $y_i(\langle w, x_i \rangle + b) \geq 1 - \xi_i$, $\xi_i \geq 0$, ($i = 1, \dots, N$)

P_{SMP} probleminin ilk terimi doğrusal ayrılabilir DVM problemi ile aynıdır. Yanı sıra; ikinci terim hatalı sınıflandırma noktasını kontrol eder. Lagrange çarpanlarının alabilecekleri maksimum değer C parametresi ile simgelenmiştir ve $0 \leq \alpha_i \leq C$ aralığında değer alır. Bu modelde Lagrange denklemi ve KKT optimalite koşulları ortak çözüldüğünde izleyen dual problem elde edilir:

$\max_{\alpha} \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j \langle x_i, x_j \rangle$ öyle ki $\sum_{i=1}^N \alpha_i y_i = 0$. Örnekler doğrusal olarak ayrılabilir durumda; doğrusal olmayan $\Phi(x)$ fonksiyonu ile ayrılabilirlik için; kernel fonksiyonları aracılığıyla daha yüksek boyutlu başka bir uzaya taşınır (Şekil-1).



Şekil-1. Girdi uzayından öznitelik uzayına dönüşüm [10].

Doğrusal olmayan $\Phi : X \rightarrow F$ ile tanımlanır. Yüksek boyutta oluşturulan öznitelik uzayını F ile gösterelim. Öyle ki, $F = \{ \Phi(\mathbf{x}) | \mathbf{x} \in X \}$ olsun. Artık $\mathbf{x}_i$ noktaları yerine öznitelik uzayından alınacak olan $\Phi(\mathbf{x})$ noktaları vardır. Dolayısıyla karar fonksiyonu öznitelik uzayında yazılırsa,

$$f(\mathbf{x}) = \text{sgn} \left(\sum_{i=1}^N \mathbf{w}_i \Phi_i(\mathbf{x}) + b \right)$$

şeklinde bir fonksiyon oluşacaktır. Denklem-4 ile bulunan karar fonksiyonu, öznitelik uzayına taşınan $\mathbf{x}$ vektörünü $\Phi(\mathbf{x})$ olarak ve iç çarpım şeklinde aşağıdaki gibi yazılabilir:

$$f(\mathbf{x}) = \text{sgn} \left(\sum_{i=1}^N \alpha_i y_i \langle \Phi(\mathbf{x}_i) \cdot \Phi(\mathbf{x}) \rangle + b \right)$$

$f(\mathbf{x}) = \text{sgn} \left(\sum_{i=1}^N \alpha_i y_i K(\mathbf{x}_i, \mathbf{x}) + b \right)$ elde edilir. Öyle ki, $K(\mathbf{x}_i, \mathbf{x}_j) = \langle \Phi(\mathbf{x}_i) \cdot \Phi(\mathbf{x}_j) \rangle$ fonksiyonuna Kernel fonksiyonu adı verilir. Bu fonksiyon Mercer koşullarını sağlar ve simetrik kesin pozitifdir [11]. $\Phi(\cdot)$ fonksiyonunu hesaplama gerekliliğini ortadan kaldıran Kernel fonksiyonunun probleme uygun seçilmesi gerekir. Uygulamalarda en yaygın kullanılan Kernel fonksiyonları üç grupta özetlenebilir:

1. Doğrusal kernel fonksiyonu: $K(\mathbf{x}_i, \mathbf{x}_j) = (\mathbf{x}_i^T \mathbf{x}_j)$,
2. Polinom kernel fonksiyonu: $K(\mathbf{x}_i, \mathbf{x}_j) = (\gamma \mathbf{x}_i^T \mathbf{x}_j)^d$,
3. Radyal tabanlı (RBF) kernel fonksiyonu (Gauss

$$\text{Kerneli}): K(\mathbf{x}_i, \mathbf{x}_j) = \exp \left(- \frac{\|\mathbf{x}_i - \mathbf{x}_j\|^2}{2\sigma^2} \right).$$

Bu çalışmada; EMG sinyalleri durağan olmayan rastgele sinyaller olduğu için, radyal tabanlı Gauss Kerneli seçilmiştir. DVM amaç fonksiyonunda yer alan hata katsayısı C ve Gauss Kerneli parametresi σ , Çapraz Geçerlilik (Cross Validation, CV) yöntemi ile eğitim kümesi üzerinde doğrulanarak en uygun değerler seçilmiş ve test verisi üzerinde hata analizleri yapılmıştır. CV yöntemi istatistiksel öğrenme alanında parametre seçiminde sık kullanılan yöntemlerden biridir. Bu çalışmada veri kümesi rastgele seçilmiş 5 alt kümeye ayrılarak 5-katlı CV yöntemi uygulanmıştır. 5 alt kümeden 1 tanesi doğrulamak için ayrılmış, 4'ü eğitim için bırakılmıştır. Bu seçimin şansa dair olmasını engellemek için 4 eğitim kümesi içerisinde de 5 katlı CV uygulanmış ve bu işlem 5 kere tekrarlanmıştır. Seçilen hata katsayıları C ve Kernel parametre aralıkları:

$$C = [2^{-5}, 2^{-3}, 2^{-1}, 2, 2^3, 2^5, 2^7, 2^9, 2^{11}, 2^{13}, 2^{15}]$$

$$\sigma = [2^{-15}, 2^{-13}, 2^{-11}, 2^{-9}, 2^{-7}, 2^{-5}, 2^{-3}, 2^{-1}, 2, 2^3]$$

olarak seçilmiştir. Bu değerlerden en uygun olanı 5 katlı CV ile seçilmiştir. Her bir tekrardan çıkan hata yüzdelерinin ortalama değerleri sınıflandırma doğruluk yüzdeleri olarak anılmıştır.

2.4. Fonksiyonel Marjin ile Topluluk Öğrenimi Yöntemi

Çoklu öğrenme ya da Topluluk Öğrenmesi (TÖ) ile bir sınıflandırma probleminin performansının tek bir karar vericinin çözümünden daha tutarlı ve doğru olduğu literatürde yapılan pek çok çalışmada ve farklı alanlarda da gösterilmiştir [12, 13]. Bu çalışmada daha önce geliştirilen [14] Maximum Marjin prensibini temel alan, eğitim kümesi üzerinde DVM yönteminin çeşitli parametreleri ile türetilmiş sınıflandırıcıların fonksiyonel marjin $f(x)$ değerlerinden oluşturulan uylaşım (konsensus) fonksiyonu sonsuz norm olarak tanımlanmış ve sınıflandırma problemi bu ortak kararı

nitelendiren fonksiyon ile çözülmüştür. Burada l , eğitim kümesi üzerinde DVM ile türetilen farklı sınıflandırıcıların toplam sayısıdır. Bir tane test noktası için l tane sınıflandırıcı farklı kararlar verebilir, Bu l tane sınıflandırıcı fonksiyonun ortak kararı tanımlanan F_α fonksiyonu ile alınmıştır. Bu yöntemin literatürdeki DVM yönteminden iki tane farklı avantajı vardır: 1) DVM kullanılırken eğitim kümesi üzerinde minimum hatayı veren optimum parametreler CV yönteminde ile seçilerek tek bir sınıflandırıcı yani karar verici kullanılır. Oysaki yukarıda önerilen yöntem ile CV kullanılmaksızın, tüm sınıflandırıcıların test noktası üzerindeki fikirleri ortak bir fonksiyonun kararı doğrultusunda gerçekleşir. 2) CV kullanılırken eğitim kümesinde optimum parametreyi bulmak için CV'nun kaç kata ayrılmış ise o sayı kadar DVM optimizasyon problemi çalışır bu da programı koşturma zamanını artırmaktadır. Diğer taraftan önerilen yöntem parametre seçiminden bağımsız olması nedeni ile zamandan kazanç sağlamaktadır. Sonuçlar kısmında iki yöntemin bu çalışmadaki problem üzerinde verdiği doğruluk yüzdeleri ve dakika cinsinden koşturma zaman dilimleri karşılaştırılmıştır.

3. Sonuçlar

Entropi kestirim yöntemleri, 10 saniye uzunluğundaki her bir EMG ölçümleri 1 saniyelik pencelerle bölümlendikten sonra uygulanmış ve her bir kas aktivasyonu için (4 kişi x 8 kanal x 10 bölüt x 12 (6 normal + 6 agresif) farklı aksiyon) kullanılmış ve oluşturulan özellik setleri sınıflandırılmış ve sınıflandırma doğruluk yüzdeleri Çizelge-1'de özetlenmiştir. Sınıflandırması yapılan 3 normal, 3 agresif grup, ayrıca doğrusal olmayan DVM uygulamasına ek olarak fonksiyonel marjin ile TÖ yöntemi kullanılarak da sınıflandırılmış ve elde edilen sınıflandırma performansı % doğruluk cinsinden Tablo-2'de özetlenmiştir.

Çizelge-1. Doğrusal olmayan DVM sınıflandırma performansı

	N-1	N-2	N-3	A-1	A-2	A-3
LzEn						
ÖS-1	84.08	94.38	91.65	86.87	78.42	75.71
ÖS-2	94.43	95.14	63.25	77.78	73.00	77.14
ÖS-3	92.38	77.80	76.99	70.81	64.53	66.65
ShanEn						
ÖS-1	78.42	85.46	84.75	82.63	75.71	79.85
ÖS-2	90.24	93.02	61.72	87.43	79.13	81.28
ÖS-3	100	79.18	81.18	75.00	79.13	87.51
LogEn						
ÖS-1	70.78	83.91	80.54	71.57	68.79	73.67
ÖS-2	89.55	88.94	70.78	68.76	64.55	70.81
ÖS-3	96.55	61.84	79.06	68.70	64.53	65.91
ApEn						
ÖS-1	87.95	79.01	84.41	81.18	63.23	59.75
ÖS-2	96.55	90.32	63.10	76.40	70.17	60.36
ÖS-3	88.10	68.76	70.83	63.94	61.08	58.32
SampEn						
ÖS-1	77.93	87.43	84.03	76.42	61.82	67.38
ÖS-2	95.86	94.48	68.69	69.45	61.20	65.98
ÖS-3	67.36	78.42	74.23	54.77	64.63	69.43
PermEn						
ÖS-1	86.84	99.31	88.20	80.61	70.83	78.44
ÖS-2	83.34	98.59	68.81	70.07	73.67	72.24
ÖS-3	94.43	82.74	74.26	75.59	56.30	69.28

Çizelge 2. TÖ ile sınıflandırma performansı

	N-1	N-2	N-3	A-1	A-2	A-3
LzEn						
ÖS-1	96.53	96.55	85.39	80.62	73.65	73.67
ÖS-2	97.24	98.62	67.41	69.53	61.26	62.59
ÖS-3	95.15	75.64	68.10	66.60	57.71	70.89
ShanEn						
ÖS-1	100	93.08	86.82	90.91	89.53	83.33
ÖS-2	86.82	93.05	77.04	91.01	90.99	81.31
ÖS-3	100	74.63	71.55	74.95	79.24	75.12
LogEn						
ÖS-1	97.93	95.84	73.62	84.75	93.72	79.19
ÖS-2	94.48	95.07	69.48	85.42	86.85	68.82
ÖS-3	97.93	59.75	68.13	63.84	52.68	63.82
ApEn						
ÖS-1	95.84	93.77	82.61	77.86	89.53	83.33
ÖS-2	94.46	92.36	67.34	75.71	90.99	81.31
ÖS-3	84.75	68.77	70.12	56.28	79.24	75.12
SampEn						
ÖS-1	92.34	93.74	84.01	72.91	75.71	74.31
ÖS-2	93.05	95.15	65.32	71.27	73.67	65.99
ÖS-3	93.77	77.04	69.41	61.06	66.70	67.36
PermEn						
ÖS-1	97.93	91.63	77.78	77.07	63.89	75.59
ÖS-2	81.33	86.06	55.54	70.22	61.92	67.32
ÖS-3	95.10	73.62	66.01	73.67	53.52	69.48

Çizelge-1'den, normal kas hareketlerinin sınıflandırılmasında, %100 gibi en yüksek sınıflandırma doğruluğu, koşmak (running) ve sabit durmak (hugging) gibi iki zıt ve normal kas aktivasyonunun, ShanEn yöntemi ile elde edilen özelliklerinden üçüncü set sınıflandırıldığında elde edilmiştir. Agresif kas hareketlerinin sınıflandırılmasında ise; en iyi performans % 87.51 doğruluk oranıyla, ShanEn kullanılarak elde edilen ÖS-2 seçildiğinde ve AA-1 aksiyonları sınıflandırıldığında elde edilmiştir. Yani sıra; NA-2 grupları, PermEn yaklaşımı ile elde edilen tüm ÖS için (%99,31, %98.59, %82.74) en yüksek doğruluk yüzdeleri ile sınıflandırılmıştır. AA-1 için ise; tüm özellik setleri ile (%82.63, %87.43, %75.00) en yüksek sınıflandırma performansı ShanEn yöntemi ile elde edilmiştir.

Çizelge-2'den, N1 ve A3 gruplarının sınıflandırılmasında tüm entropi kestirimlerinde fonksiyonel marjin ile TÖ yönteminin performansını arttırdığı görülmektedir. EMG özellikleri, ShanEn yaklaşımı ile elde edildiğinde birinci normal ve birinci agresif sınıflandırma işlemi sonucunda doğrusal olmayan DVM ile elde edilen %78.42 ve % 82.63 oranlarının, TÖ kullanıldığında %100 ve %90.91 gibi çok başarılı oranlara ulaştığını görmekteyiz. Yani sıra; Çizelge-1'e göre; N2 grubu için 1., 2. ve 3. ÖS'te göre sırasıyla %99,31, %98.59, %82.74 oranlarını sağlayan PermEn yaklaşımının, TÖ kullanıldığında aynı sınıflandırmalar için sağladığı doğruluk oranları %91.63, %86.06 ve %73.62 olarak elde edilmiştir.

4. Yorum

Bu çalışmada elde edilen sonuçlar; fiziksel kas aksiyonları sırasında oluşan aksiyon potansiyellerinin oluşum ve kas hücreleri arasında yayılma özelliklerinin EMG sinyallerinin karmaşıklık seviyesine bağlı olduğunu ve entropi ölçütleri ile bu bağlılığın ölçülebileceğini göstermektedir. Ayrıca; kaslarda gerginlik yaratan fiziksel hareketlerin kas hücrelerini ard arda ve uzun süre uyardığı için EMG analizlerinde normal

aksiyonların tercih edilmesi gerektiğini göstermektedir. EMG sinyallerinin karakterize edilmesinde en iyi sonucu veren entropi kestirim yöntemleri ShanEn ve PermEn yaklaşımlarıdır. Her iki yöntemin sağladığı sınıflandırma başarısı; birbirine tamamen zıt olan fiziksel hareketlerin ürettiği EMG sinyallerinin entropi cinsinden sınıflandırılmasında, fonksiyonel marjin ile TÖ yönteminin kullanılması performansı arttırmaktadır. Yani sıra; kaslara uygulanan kuvvet ve oluşan gerilme durumunu açısından benzer olan normal ve agresif kas hareketlerinin doğrusal olmayan DVM ile sınıflandırılması daha elverişli sonuçlar vermektedir.

Kaynaklar

- [1] Aydın S, Arica N, Ergul E, Tan O, (2015) "Classification of obsessive compulsive disorder by EEG complexity and hemispheric dependency measurements", *Int J. of Neural Systems*, 25(3):1550010
- [2] D. Zhang, Y. Wang, X. Chen, F. Xu, (2011) "EMG Classification for Application in Hierarchical FES System for Lower Limb Movement Control", *Intelligent Robotics and Applications in Series Lecture Notes in Computer Science*, 7101, 162--171
- [3] S. Parasuraman, A.W. Oyong, V.L. Jauw (2010) "Robot Assisted Stroke Rehabilitation: Joint Torque/Force Conversion from EMG Using SA Process", *Intelligent Robotics and App., Series Lecture Notes in Computer Science*, 6425, 612--623
- [4] H.L. Choi, H.J. Byun, et all. (2000) "On pattern classification of EMG signals for walking motions", *Artificial Life and Robotics*, 4(4), 193--197
- [5] 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 in Series Comm. in Comp. and Inf. Science*, 330, 236--243
- [6] UCI Lichman, M. (2013). UCI Machine Learning Repository [http://archive.ics.uci.edu/ml]. Irvine, CA: University of California, Sch. of Inf. and Comp. Science.
- [7] A.N. Kalinichenko, L.A. Manilo, A.P. Nemirko (2015) "Analysis of Anesthesia Stages Based on the EEG" *Entropy Estimation, Pattern Recognition and Image Analysis*, 25(4), 632--641.
- [8] J. Gao, J. Hu, W. Tung (2011) "Complexity measures of brain wave Dynamics", *Cogn Neurodyn*, 5, 171--182.
- [9] N. Cristianini, J.S. Taylor (2000) "An Introduction to Support Vector Machines and other kernel based learning methods" Cambridge University press
- [10] Z. Xu., R. Jin., I. King, M. Lyu (2009) "An extended level method for efficient multiple kernel learning" *Advances in Neural Inf. Processing Sys.* 21, 1825--1832.
- [11] S. Pöyhönen (2004) "Support Vector Machine Based Classification in Condition Monitoring of Induction Motors" Helsinki University of Technology Control Engineering Laboratory, Finland.
- [12] L. Breiman, (1998) "Arcing classifiers" *The Annals of Statistics* 26, 801--849
- [13] Y. Freund, R.E. Schapire "Experiments with a new boosting algorithm" *In: Proc. of the Int. Conf. on Machine Learning*, 148--156
- [14] S. Ö. Akyüz, T. Windeatt, R. Smith (2015) "Pruning of error correcting output code by optimization of accuracy-diversity trade off" *Machine Learning*, 101(1), 253--269.