

Fraktal Eğimden Arındırılmış Dalgalık Analizi ve Pencereleli Kare Ortalamasının Karekökü Tabanlı EMG Sınıflandırma

Ömer Faruk ALÇİN*

¹ Elektrik-Elektronik Müh. Böl., Mühendislik ve Doğa Bilimleri Fak., Malatya Turgut Özal Üniversitesi, Malatya, Türkiye
*1 omer.alcin@ozal.edu.tr

(Geliş/Received: 18/07/2020;

Kabul/Accepted: 08/08/2020)

Öz: Elektromiyografik (EMG) kas aktivitesini ölçmek için kullanılan faydalı bir tekniktir. EMG sinyalleri çoğunlukla protez, fiziksel rehabilitasyon, Nöromusküler bozuklukların teşhisi ve beyin-bilgisayar arayüzü gibi medikal uygulamalara yardımcı karar destek sistemlerinde kullanılır. Bu çalışmada EMG sinyallerini sınıflamak için kullanışlı bir yaklaşım önerilmiştir. Önerilen yöntemde, özellik çıkarma yöntemi olarak Fraktal Eğimden Arındırılmış Dalgalanma Analizi (F-EADA) ve örtüşmeyen pencereleli Kök Ortalama Karesi (p-KOK) kullanılmıştır. F-EADA yöntemi korelasyon ve istatistiksel benzerliği ölçmek için kullanılan bir yöntemdir. KOK istatistiksel bir ölçüdür ve EMG tanıma sistemlerinde ayırt edici bir parametre olabilmektedir. p-KOK yaklaşımı geleneksel KOK yönteminden daha yeteneklidir ve bu ayırt edici yetenek deneysel sonuçlarla gösterilmiştir. Çıkarılan EMG öznitelikleri, Destek Vektör Makinesi (DVM), k-En Yakın Komşu (KEYK), Karar Ağacı (KA) ve Doğrusal Diskriminant Analizi (DDA) yöntemleri ile sınıflandırılmıştır. DVM Sınıflandırıcı bu yöntemler arasında en iyi performansa sahiptir. Önerilen yöntem, altı farklı nesne tutma eylemini içeren EMG veri seti ile test edilmiştir. Deneysel çalışmalar, önerilen yöntemin %96.83 doğruluk ile EMG veri setini sınıflamak için uygun olduğunu göstermiştir. Ayrıca, önerilen yöntem aynı veri setini kullanan diğer yöntemlerle karşılaştırıldığında daha iyi performansa sahiptir.

Anahtar kelimeler: EMG, fraktal eğimden arındırılmış dalgalık analizi, pencereleli kare ortalamalarının karekökü, DVM.

Fractal Detrended Fluctuation Analysis and Windowed Root Mean Square Based EMG Classification

Abstract: Electromyographic (EMG) is useful technique to measure muscle activity. EMG signals mostly used in decision support system to help medical purposes such as prosthesis, physical rehabilitation, the diagnosis of neuromuscular disorders, and brain computer interface. This work proposes a useful approach to recognize EMG signals. Fractal Detrended Fluctuation Analysis (F-DFA) and non-overlap windowed Root Mean Square (w-RMS) are used as a feature extraction method. In the proposed method, F-DFA method has been exploited to determine correlation and statistical similarity. RMS is statistical measure and it can be as a distinctive parameter in EMG recognition systems. w-RMS approach is capable more than traditional RMS and this distinctive capable showed with experimental results. The features of EMG are classified common the four method such as Support Vector Machine (SVM), k-nearest Neighbor (kNN), Decision Tree (DT), and Linear Discriminant Analysis (LDA). The SVM Classifier has best performance in among these methods. The proposed method has been tested with the EMG dataset consisting of six different object holding actions. The experimental works have been demonstrated the convenient of the proposed method with %96.83 accuracy to classify the EMG dataset. Also, the proposed method has a better performance compared to other methods using the same dataset.

Key words: EMG, fractal detrended Fluctuation Analysis, windowed root mean square, SVM.

1. Giriş

Elektromiyografi (EMG) istemli veya istemsiz kas aktiviteleri sırasında kaslarda oluşan elektriksel aktiviteyi ölçmek ve kaydetmek için kullanılan bir yöntemdir. EMG, kas aktif olduğunda kas hücreleri tarafından üretilen elektriksel potansiyeldir. EMG sinyalleri sadece hastalık tespitinde değil teknolojinin gelişmesi ile robotik ve akıllı sistemlerde de sıkça çalışılan bir konu haline gelmiştir. Bu nedenle EMG sinyallerinin kullanımı günümüzde popüler hale gelmiştir. Literatürde EMG sınıflandırma yoğun bir şekilde çalışılmaktadır. [1] nolu çalışmada üçlü desen ve Ayrık Dalgacık Dönüşümü (ADD) tabanlı öznitelik çıkarım yöntemi önerilmiştir. Amputé kişilerden alınmış yüzey EMG sinyalleri 3 kuvvet seviyesine göre (düşük, orta, yüksek) sınıflandırılmıştır. Önerilen sistemin k-En Yakın Komşuluk (KEYK) sınıflandırıcı ile tüm güç seviyelerine göre %99.14 doğruluk oranı elde edilmiştir. Düşük, orta ve yüksek güç seviyelerinde ise sırasıyla %97.78, %93.33 ve %92.96 başarımlarına ulaşılmıştır. [2] nolu çalışmada EMG sinyallerinden Nöromusküler kas hastalık tespiti amaçlanmıştır. Bu amaçla öncelikli olarak

* Sorumlu yazar: omer.alcin@ozal.edu.tr. Yazarların ORCID Numarası: ¹ 0000-0002-2917-3736

EMG sinyallerinden öznitelik çıkarmak amacıyla EMG sinyallerine ADD uygulamışlardır, daha sonra Dalgacık katsayılarının dağılımını göstermek için ADD'nin istatistiksel değerleri hesaplanmıştır. Nöromusküler hastalıkların tespiti amacıyla çıkarılan bu özellikler Torbalama Topluluk (TT) sınıflandırıcısına giriş verisi olarak verilmiştir. Deneysel sonuçlar neticesinde TT sınıflandırıcısı Destek Vektör Makinesi (DVM) ile beraber doğruluk oranının %99 olduğu gözlemlenmiştir. [3] nolu çalışmada miyopati, Amiyotrofik Lateral Skleroz (ALS) ve normal EMG sinyallerinin sınıflandırılması amaçlanmıştır. Öncelikle gürültü gidermek amacıyla Çok Ölçekli Temel Bileşen Analizi (ÇÖTBA) ve öznitelik çıkarımı için ADD kullanılmıştır. EMG sinyallerini sınıflandırmak amacıyla CART, C4.5 ve Rassal Orman (RO) Karar Ağaç (KA) algoritması kullanılmıştır. Yapılan çalışma neticesinde en iyi sonucun %96.67 doğruluk oranına RO ile ulaşıldığı gösterilmiştir. [4] nolu çalışmada miyopati, ALS ve normal bireylere ait EMG sinyallerinin sınıflandırılması amaçlanmıştır. EMG sinyallerine öncelikle ADD ve güç spektral yoğunluğu yöntemleri uygulanarak sinyallere ait öznitelik çıkarılmıştır. Çıkarılan bu özniteliklerden en etkin öznitelikleri belirlemek için ReliefF algoritması kullanılmıştır. Elde edilen yeni öznitelikler RO ve KEYK sınıflandırıcılarına giriş verisi olarak verilmiştir. Yapılan çalışmalar sonrasında RO sınıflandırıcısının ReliefF ile %88.8 doğruluk oranı ile en iyi sonucu verdiği gözlemlenmiştir. [5] nolu çalışmada miyopati ve normal EMG sinyallerini sınıflandırma amaçlanmıştır. Bu amaçla EMG sinyallerinden Sürekli Dalgacık Dönüşü ile dört istatistiksel öznitelik çıkarılmıştır. Sinyallerin sınıflandırılması için k-en yakın komşuluk ve DVM sınıflandırıcısı kullanılmıştır. Yapılan çalışmalar sonucunda KEYK sınıflandırıcısı 9 en yakın komşuyu kullanarak %91.11 doğruluk oranı, DVM ise %91.01 doğruluk oranı ile sınıflandırma yaptığını göstermişlerdir. [6] nolu çalışmada gerçek zamanlı alınan EMG sinyallerinin sınıflandırılması amaçlanmıştır. 5 farklı hareket için öncelikle sinyaller Dalgacık dönüşümünü ile Dalgacık katsayıları çıkarılmıştır daha sonra çıkarılan bu katsayılar DVM'ye giriş verisi olarak verilmiştir. Yapılan çalışma sonrasında sistemin doğruluk oranı %83 olarak belirlenmiştir. [7] nolu çalışmada EMG sinyallerinde hareket tespiti amaçlanmıştır bu amaçla alınan 8 farklı harekete ait EMG sinyallerine ADD uygulanmıştır ve buradan gelen katsayılara bazı istatistiksel metotlar uygulanarak öznitelik çıkarılmıştır. Çıkarılan bu verilerin Yapay Sinir Ağı (YSA) ile sınıflandırılmıştır. Tüm sınıflandırma işlemleri sonucunda %77.50 doğruluk oranı tespit edilmiştir. [8] nolu çalışmada 3 farklı el hareketinin sınıflandırılması amaçlanmıştır. Bu amaçla alınan EMG sinyallerine ADD uygulanarak katsayıları alınmış ve bu katsayılar YSA'ya giriş verisi olarak uygulanmıştır. Yapılan çalışma sonucunda ortalama %93.25 doğruluk oranı bulunmuştur. [9] nolu çalışmada 6 farklı el hareketinin sınıflandırılması amaçlanmıştır. Bu amaçla ADD ile özellik çıkarılmıştır daha sonra önerilen Dalgacık Sinir Ağı ile sınıflandırılma işlemi yapılmıştır. Yapılan çalışma sonucunda sistemin doğruluk oranı %94.67 olarak bulunmuş ve önceki çalışmalarla kıyaslanmıştır. [10] nolu çalışmada EMG sinyallerinden normal, miyopati ve ALS hastalarının tespiti amaçlanmıştır. EMG sinyallerinin sınıflandırılması için ADD ile istatistiksel öznitelikler kullanılmıştır. Öznitelikler DVM ile sınıflandırılmış ve stokastik analiz ile %93.08 doğruluk oranı tespit edilmiştir. [11] nolu çalışmada 6 farklı nesne tutma eylemi için veri seti hazırlanmıştır. Bu veri seti %75.00 başarımla sınıflandırılmıştır. Daha sonra bu veri seti için Sapsanis ve diğerleri ayırık kip dönüşümü ve gerçek kip fonksiyon bileşenleri öznitelikleri ve doğrusal sınıflandırıcıya tabanlı yaklaşım ile %80.00 doğruluk elde edilmiştir [12]. [13] nolu çalışmada Sapsanis'in EMG seti [11] kısa zamanlı Fourier yöntemi ile zaman-frekans görüntüleri oluşturulmuştur. Yerel İkili Örüntü (YİÖ) ve gri seviye eş oluşum matrisi yöntemleri tabanlı öznitelikler YSA ile %92 doğruluk ile sınıflandırılmıştır. Arı ve diğerleri bir boyutlu (YİÖ), permütasyon entropi ve DVM sınıflandırıcısından oluşan yaklaşım önermişlerdir [14]. Önerilen yaklaşım ile 6 temel nesne tutma hareketi için yaklaşık %93.167 performans ile tanımlanmıştır.

Bu çalışmada EMG sinyallerin sınıflamak için Fraktal Eğimden Arındırılmış Dalgalık Analizi (F-EADA) ve Karesel Ortalamanın Karekökü'un (KOK) iletirilmiş versiyonu olan pencereli KOK (p-KOK) yöntemleri öznitelik çıkarmak için kullanılmıştır. EADA yöntemi EMG sınıflama sistemlerinde kullanılmaktadır [15]. Bu çalışmada F-EADA yönteminin fraktal parametresinin belirlenmesinde sınıflama performansına bağlı kaba arama algoritması kullanılmıştır. Öznitelik çıkarma işleminde kullanılan p-KOK yöntemi EMG kayıt işleminde ön işlem olarak kullanılmaktadır [16]. Bu çalışmada ise p-KOK yöntemi öznitelik çıkarmak için kullanılmıştır. Geleneksel KOK yönteminde EMG sinyalinin tamamı için KOK değeri hesaplanır. Bu durum bölgesel değişikliklerin dikkate alınmamasına sebep olabilmektedir. Bu durumun önüne geçebilmek için sinyal boyunca sabit genişlikli pencere örtüşmesiz kaydırılarak bu pencerede ki EMG sinyal parçasının KOK değeri hesaplanmıştır. Böylece bölgesel değişiklikler dikkate alınarak sınıflandırma performansında artışı gözlenmiştir. Önerilen yöntemde, yaygın kullanılan DVM, KEYK, KA ve DDA sınıflandırıcı yöntemlerinin uygunluğu araştırılmıştır. DVM yöntemi bu sınıflandırıcılar arasında en iyi performansa sahiptir.

Bu çalışmanın geri kalan kısmı şu şekilde düzenlenmiştir. Veri seti, öznitelik çıkarma yöntemleri ve DVM sınıflandırıcısı ikinci bölümde tanıtılmıştır. Üçüncü bölümde deneysel çalışma ve sonuçlar detaylı bir şekilde anlatılmıştır. Çalışmadan elde edilen sonuçlar son bölümde tartışılmıştır.

2. Materyal ve Yöntem

Bu başlıkta çalışmada kullanılan yöntemler ve veri seti detaylandırılmıştır.

2.1. Fraktal Eğimden Arındırılmış Dalgalık Analizi

Peng ve ark. DNA dizilimlerin analiz edilmesi için EADA yöntemini önermişlerdir [15]. EADA yöntemi finansal, fiziksel, sosyal ve biyomedikal gibi çeşitli zaman serilerinin analizinde de yaygın bir şekilde kullanılmaktadır. EADA yöntemi istatistiksel ölçkleme teoremi tabanlı bir yöntemdir. N örnekli zaman serisini $x(i)$, $i=1, \dots, N$ şeklinde gösterelim. Verilen x zaman serisinin profil fonksiyonu Denklem 1'deki gibi hesaplanabilir [15-18].

$$y(k) = \sum_{i=1}^k (x(i) - \bar{x}) \quad (1)$$

Burada \bar{x} verilen $x(i)$ sinyalinin aritmetik ortalamasıdır. Ardından profil sinyali eşit m uzunluklu parçalara bölünerek her bir parçaya karşılık en küçük kareler metoduyla bir $y_m(k)$ eğrisi uydurulur. Eğri uydurma işleminde L derece ile polinomal eğilimi temsil edildiği kabul edilmektedir. Daha sonra Dalgalanma fonksiyonu Denklem 2'de verildiği gibi hesaplanabilir.

$$F(m) = \sqrt{\frac{1}{N} \sum_{k=1}^N (y(k) - y_m(k))^2} \quad (2)$$

Ölçkleme teoreminde ölçkleme üsteli α gösterilirse Dalgalanma fonksiyonu olarak tanımlanan parametre Denklem 3'te verildiği gibi hesaplanır.

$$F(m) = m^\alpha \quad (3)$$

Ölçkleme parametresi α $\log(F(m)) - \log(m)$ grafiğinin eğiminden de hesaplanabilir. İncelenen zaman serisinin bağımlılığı hakkında bilgi vermektedir. Temel EADA tanımlamasından sonra fraktal (F-EADA) daha anlaşılır bir şekilde verilebilir. F-EADA Denklem 4'te verildiği gibi tanımlanabilir.

$$F_q(m) = \sqrt[q]{\frac{1}{N} \sum_{k=1}^N (y(k) - y_m(k))^q} \quad (4)$$

Burada q , F-EADA'nın derecesini göstermektedir. Denklem 4 sıfırdan farklı q değeri için olup $q=0$ için L 'Hospital kuralı dikkate alınarak Denklem 5'teki gibi bir tanımlama yapılabilir. F-EADA ile ölçkleme üsteli arasında, Denklem 6'da verilen bir ilişki vardır [18].

$$F_0(m) = \exp\left(\frac{1}{N} \sum_{k=1}^N \ln(y(k) - y_m(k))\right) \quad (5)$$

$$F_q(m) = m^{h(q)} \quad (6)$$

Bu çalışmada F-EADA analizi ile F-EADA1 ve F-EADA2 (1. ve 2. Dereceden eğimden arındırılmış polinom) katsayıları öznitelik olarak kullanılmıştır. Bir kanal EMG sinyali için F-EADA1 ve F-EADA2 polinom katsayılarından her birinden 21 öznitelik, toplamda 42 öznitelik elde edilmiştir.

2.2. Pencerele Kare Ortalamalarının Karekökü


KOK değişkenliğin miktarını ölçmek için kullanılan istatistiksel temelli bir yöntemdir. Genliğinde pozitif ve negatif değişime sahip sinyallerde kullanışlı bir tekniktir. Sürekli değişen zaman serileri için sürekli bir şekilde değişen fonksiyon hesaplanabilir. KOK yöntemi EMG sinyalinin özelliği itibarıyla kullanışlı bir yöntemdir. KOK değeri Denklem 7'de verildiği gibi hesaplanabilir [19].

$$KOK = \sqrt{\frac{1}{N} \sum_{i=1}^N x(i)^2} \quad (7)$$

Bu çalışmada örtüşmesiz kayar pencere yapısı kullanılarak her bir pencerenin KOK değeri hesaplayan bir yaklaşım kullanılmıştır. Belirlenen pencere genişliği sinyal boyunca gezdirilerek her pencere için bir KOK değeri hesaplatılmıştır. Böylece genlik bazlı değişkenliğin sinyalin tamamı yerine bölgesel olarak hesaplanması amaçlanmıştır. Pencere genişliği için 250 örnek ampirik yolla seçilmiştir. 2500 örneğe sahip bir kanal EMG sinyalinden 250 örnek pencere uzunluğu ile 10 öznitelik elde edilmiştir.

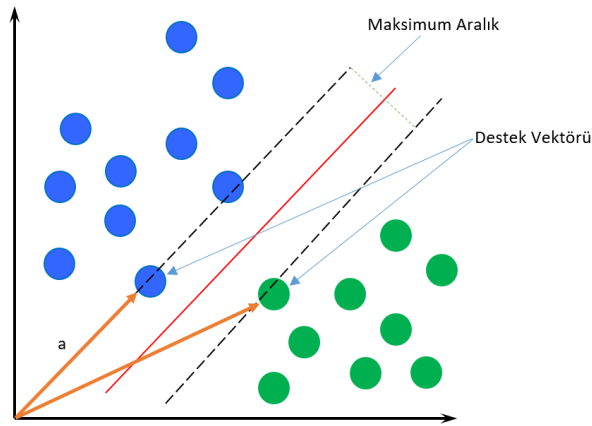
2.3. Destek Vektör Makinesi

DVM istatistiksel öğrenme teorisi temelli bir gözetimli öğrenme algoritmasıdır. Doğrusal ve doğrusal olmayan verilerin sınıflandırılmasında yaygın olarak kullanılan basit ve oldukça etkili bir yöntemdir [20]. Bu yöntem, Vapnik ve Cortes tarafından önerilmiştir [21]. Doğrusal DVM sınıflandırıcının temel çalışma prensibi, iki sınıflı verileri birbirinden ayırabilecek en uygun olan hiper düzlemi bulma esasına dayanmaktadır [22]. Sınıf etiketleri $y_n \in \{-1, 1\}$ olan ve $D = \{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$ şeklinde bir veri setimiz olduğunu düşünelim. Burada $x_n \in \mathbb{R}$, n veri kümesinin eleman sayısını tanımlamaktadır. Buna göre bu iki sınıflı verileri birbirinde ayırmak istediğimizde Şekil 1 görüldüğü gibi verileri ayırabilecek çok sayıda ayırım çizgisinin çizilebildiği görülmektedir.




Şekil 1. Olası ayırım çizgilerinin gösterimi.

Fakat bu verileri sınıflandırmada hangi ayırım çizgisinin en iyi başarıyı sağlayacağını kestirmek oldukça zor görünüyor. DVM iki sınıflı verileri sınıflandırırken, Şekil 2'de görüldüğü gibi birbirine en yakın farklı sınıf noktalar arasındaki uzaklığı maksimum yapabilecek olan hiper düzlemi bulmaktadır [21].



Şekil 2. En iyi hiper düzlem ve marj gösterimi.

Şekil 2'deki a vektörümüzün, ağırlık vektörü (hiper düzlemin normali) w olsun. Buna göre w ağırlık vektörü, Şekil 3'teki gibi bulunabilir.



Şekil 3. Ağırlık vektörü w Hesaplanması.

Bu durumda iki sınıflı verimizi ayıracak en iyi hiper düzlem için karar fonksiyonları Denklem 8'deki gibi yazılabilir.

$$\begin{aligned} w \cdot x_i + b &\geq 1, & \text{her } y &= +1 \\ w \cdot x_i + b &\leq 1, & \text{her } y &= -1 \end{aligned} \quad (8)$$

Burada b eğilim değerini tanımlamaktadır [21]. Sınıf etiketleri dikkate alınırsa Denklem 8 düzenlenerek Denklem 9 ve Denklem 9 kısıtlamalar ile Denklem 10'daki yazılabilir.

$$y_i \cdot (w \cdot x_i + b) \geq 1 \quad (9)$$

$$y_i \cdot (w \cdot x_i + b) \leq 1 \quad (10)$$

DVM'de hiper düzlem sınırlarının maksimum olabilmesi $\|w\|$ değerinin minimum olması ile mümkün olabilecektir [23, 24]. Bunun için maksimum aralık mesafesi, $d = (x_+ - x_-) \cdot \frac{w}{\|w\|}$ bağıntısında görüldüğü üzere d 'nin maksimum olması için $\|w\|$ mümkün olduğunca azaltılması gerekmektedir. Bu durumda, en uygun hiper düzlemin belirlenmesinde, $\min \left[\frac{1}{2} \|w\| \right]$ sınırlı optimizasyon probleminin çözümüne bağlıdır. Böylece Denklem 10, minimum $\|w\|$ sınırlamalarına bağlı olarak Denklem 11'deki gibi yazılabilir.

$$\min \frac{1}{2} \|w\|^2 \text{ kısıt: } y_i (w x_i + b) \geq 0 \text{ ve } y_i \in \{1, -1\} \quad (11)$$

Bu optimizasyon probleminin çözümü için Lagrange çarpanları eklenerek kısıtlama olmadan Denklem 12'deki gibi yazılabilir.

$$L(w, b, \alpha) = \frac{1}{2} \|w\|^2 - \sum_{i=1}^N \alpha_i y_i (w x_i + b) + \sum_{i=1}^N \alpha_i \quad (12)$$

$$f(x) = \text{sign}(\sum_i \alpha_i y_i k(x, x_i) + b) \quad (13)$$

Burada, k kernel fonksiyonu ve α lagrange çarpanıdır.


2.4. Veri Seti

EMG veri seti altı el hareketi düşünülerek ikisi erkek olmak üzere sağlıklı beş katılımcı ile oluşturulmuştur. Her bir hareket için üç kanallı 100 ölçüm kaydedilmiştir. EMG veri seti 2500 örnek uzunluğunda 50 Hz çentik ve 15-500 Hz bant geçiren filtrelenmiş 600 sinyalden oluşmaktadır. EMG veri setindeki altı el hareketi ve çalışmada kullanılan kısa tanımlamalar Tablo 1'de verilmiştir [11-12].

Tablo 1. EMG veri seti hareketleri ve tanımlamalar.

Silindirik nesne tutma	Silindir
Parmak ucu ile küçük nesne tutma,	Parmak ucu
İnce düz nesne tutma	Düz
Küresel nesne tutma	Küre
Avuç içine bakacak şekilde nesne tutma	Avuç
Ağır yük tutma	Askı

Şekil 4’de veri setine ait örnek EMG sinyalleri verilmiştir.


**Şekil 4.** Örnek EMG sinyalleri.

Şekil 4’de verilen sinyaller birinci kanala ait kayıtlardır. Deneysel çalışmalarda üç kanal EMG sinyalinin bir hareketi tanımladığı düşünülmüştür. Yani öznelik çıkarma işleminde üç kanala ait öznelikler birleştirilerek kullanılmıştır.

3. Deneysel Çalışma ve Sonuçlar

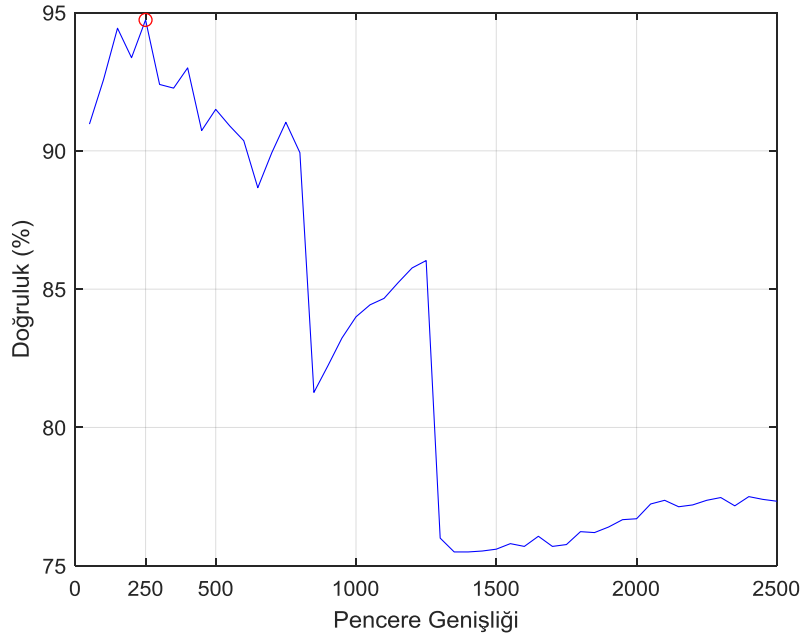
Bu çalışmada önerilen yöntem 6 temel hareketi içeren 3 kanallı 600 kayıttan oluşan veri seti ile test edilmiştir. Önerilen yaklaşımın geçerliliğini göstermek için bütün deneysel işlemlerde 10-kat çapraz doğrulama kullanılmıştır. Deneysel çalışmalar MatLab ortamında 2.7 GHz işlemci ve 32GB belleğe sahip bilgisayarda gerçekleştirilmiştir. Önerilen yöntemde F-EADA ve örtüşmesiz pencereleli KOK yöntemleri EMG sinyallerinden ayırt edici öznelikleri çıkarmak için ve bu öznelikleri sınıflandırmak için ise DVM sınıflandırıcı kullanılmıştır. DVM sınıflandırıcısı doğrusal çekirdeğe sahip ve çekirdek ölçeği bir olarak ampirik yolla belirlenmiştir. Deneysel çalışmada DVM’nin yanı sıra yaygın kullanılan KEYK, KA ve DDA kullanılmıştır. KEYK sınıflandırıcı için k değeri 1 ve öklid uzaklığı, KA için Gini indeksi, kök sayısı en küçük 10 ve yaprak sayısı ise en küçük 1 olarak ampirik yol ile seçilmiştir. Deneysel çalışmalarda fraktal ve pencere boyutu parametrelerinin belirlenmesinde DVM iyi başarıma sahip olduğu için kullanılmıştır. F-EADA fraktal parametresi belirlenmesinde ampirik yaklaşımla -5 ve 5 arasında 0.05 adım artışı ile en yüksek doğruluk dikkate alınarak kaba arama algoritması kullanılmıştır. F-EADA ile bir kanal EMG sinyalinden birinci ve ikinci derece polinom katsayıları kullanılarak 42

öz nitelik elde edilmiştir. F-EADA yöntemi ile üç kanallı 600 EMG ölçümü için 600×126 öz nitelik matrisi hesaplanmıştır. Belirtilen aralıktaki q parametresine karşın doğruluk değerleri yüzde olarak Şekil 5’de verilmiştir.



Şekil 5. q parametresine karşın doğruluk değişim eğrisi.

Şekil 5’de Şekil 5’de görüleceği gibi en yüksek başarımla %94.67 olarak -0.95 q değeri için elde edilmiş ve deneysel çalışmanın devamında bu değer kullanılmıştır. Kayar pencerele KOK ile bölgesel değişkenliğin EMG sınıflandırmada başarımla olumlu etkileyeceği düşünülmüştür. 50 ile 2500 arasında 50 adım aralığı ile pencere genişliği analiz edilmiştir. Pencere genişliğine karşın doğruluk değişimi Şekil 6’da verilmiştir.



Şekil 6. Pencere genişliğine karşın doğruluk değişim eğrisi.

Şekil 6’da görüldüğü gibi Deneysel çalışmaların bu kısmında geleneksel KOK ve DVM sınıflandırıcısı ile %77.33 doğruluk elde edilmiştir. 250 pencere genişliği p-KOK yaklaşımında 600×30 öznelik matrisi DVM sınıflandırıcısı ile %94.73 doğruluk başarımına sahiptir. Böylece p-KOK yaklaşımı EMG sinyalleri için KOK yöntemine göre daha ayırt edicidir. Önerilen öznelik çıkarma yöntemlerinin tek tek ve birleştirilmiş başarımları Tablo 2’de verilmiştir.

Tablo 2. Önerilen öznelik çıkarma işlemlerinin doğrulukları.

Öznelik	Doğruluk (%)			
	DVM	kNN	KA	DDA
KOK	94.73	91.00	83.17	86.33
F-EADA	95.67	83.33	77.83	88.83
KOK+ F-EADA	96.83	88.17	84.33	90.83

Tablo 2’de KOK+F-EADA, KOK öznelikleri ile F-EADA birleştirilerek 600×156 boyutlu öznelik matrisi elde edilmektedir. Tablo 2’den görüleceği üzere DVM sınıflandırıcısı en yüksek doğruluğa sahiptir. Birleştirilmiş öznelikler için ikinci en yüksek doğruluk DDA sınıflandırıcısı ile elde edilmiştir. En yüksek başarıma sahip KOK+F-EADA DVM sınıflandırıcısı yöntemine ait karmaşıklık matrisi Şekil 7’de verilmiştir.

Gerçek	Askı	97	2				1
	Avuç		94	5			1
	Düz		4	96			
	Küresel				99		1
	Parmak Ucu		2				98
	Silindirik	3					
		Askı	Avuç	Düz	Küresel	Parmak Ucu	Silindirik
		Tahmin					

Şekil 7. Önerilen yönteme ait karmaşıklık matrisi.

Şekil 7’de görüleceği gibi en düşük başarımlar %94 ile avuç ile tutma eylemi ve en yüksek ise %99’luk başarımlar ise küresel tutma eyleminde elde edilmiştir. Askı ve silindirik eylemler aynı %97 gibi bir başarımlara sahiptir. Karmaşıklık matrisinin satırlarında ki 1-5 arası değerler ilgili harekete ilişkin yanlış tahmini göstermektedir. Örneğin avuç eyleminde 94 tanesi doğru tahmin edilmiştir. 5 tanesi düz eylem ile 1 tanesi parmak ucu olarak yanlış tahmin edilmiştir. En yüksek başarımlara sahip Küresel eylem ise 1 silindirik eylem hatası ile karıştırılmıştır. Askı eylemi 2 avuç ve 1 silindirik eylemi ile karıştırılmıştır. Silindirik eylemi ise 3 yanlış askı eylemi ile karıştırılmıştır. Ayrıca her hangi bir hareketi hatasız bir şekilde ayırt edememiştir. Önerilen yöntemin aynı veri setini kullanan yöntemler ile karşılaştırması Tablo 3’te verilmiştir.

Tablo 3. Önerilen yöntemin diğer yöntemler ile karşılaştırılması.

Yöntem	Doğruluk (%)
Sapsanis C. [11]	75.000
Sapsanis ve diğerleri [12]	80.000
Arı ve diğerleri [13]	92.000
Arı ve diğerleri [14]	93.167
Önerilen Yöntem	96.833

Tablo 3'ten görüleceği üzere önerilen yöntem daha yüksek sınıflandırma doğruluğu göstermektedir. Bu karşılaştırma, önerilen yöntemin uygulama da tercih edilebilirliğini artırmaktadır.

4. Tartışma

Bu çalışmada EMG sinyallerinin sınıflandırılması için KOK, F-EADA ve DVM sınırlandırıcılı yaklaşım önerilmiştir. EADA yöntemi yaygın olarak biyomedikal sinyallerden ayırt edici öznelik elde edilmesinde yaygın bir şekilde kullanılmaktadır. Bu çalışmada F-EADA yönteminin EMG sınıflama için uygunluğu araştırılmıştır. Doğruluk odaklı en uygun fraktal değeri için kaba arama algoritması kullanılmıştır. Biyomedikal sinyallerden öznelik çıkarmak için KOK yöntemi kullanılmaktadır. Geleneksel KOK yöntemi bütün bir sinyal için hesaplanmaktadır. Bu çalışmada bütün bir sinyal yerine örtüşmesiz pencereci p-KOK kullanılmıştır. Bu yaklaşım sadece KOK yöntemi dikkate alındığında yaklaşık %17 doğruluk başarımı sağlamıştır. Her iki yöntem birleştiğinde %96.83 başarımla altı el hareketi tanımlanmıştır. Önerilen yöntem aynı veri setini kullanan diğer yöntemler ile karşılaştırıldığında kendine en yakın yöntemden %3'ün üstünde performans sergilemektedir. Ayrıca karmaşıklık matrisi dikkate alındığında yüksek başarımla altı harekete düzgün bir şekilde dağılmıştır. Bu sonuçlar hareket tespiti ve protez/ ortorik aygıt kontrollerinde, beyin bilgisayar arayüz uygulamalarında önerilen yöntemin tercih edilebileceğini göstermektedir.

Kaynaklar

- [1] Tuncer T, Sengul D, Subasi A. Surface EMG signal classification using ternary pattern and discrete wavelet transform based feature extraction for hand movement recognition. *Biomedical Signal Processing and Control* 2020; 58: 101872.
- [2] Subasi A, Yaman E, Somaily Y, Alynbawi H A, Alobaidi F, Altheibani S. Automated EMG signal classification for diagnosis of neuromuscular disorders using DWT and bagging. *Procedia Computer Science* 2018; 140: 230-237.
- [3] Gokgoz, E, Subasi A. Comparison of decision tree algorithms for EMG signal classification using DWT. *Biomedical Signal Processing and Control* 2015; 18: 138-144.
- [4] Benazzouz A, Guilal R, Amirouche F, Slimane, Z E H. EMG Feature Selection for Diagnosis of Neuromuscular Disorders. 2019 International Conference on Networking and Advanced Systems (ICNAS); 26-27 June 2019; Annaba, Algeria: IEEE. pp. 1-5.
- [5] Belkhou A, Achmamad A, Jbari A. Classification and Diagnosis of Myopathy EMG Signals Using the Continuous Wavelet Transform. 2019 Scientific Meeting on Electrical-Electronics & Biomedical Engineering and Computer Science (EBBT); 24-26 April 2019; Istanbul, Turkey: IEEE. pp. 1-4.
- [6] Anil N, Sreeletha SH. EMG Based Gesture Recognition Using Machine Learning. 2018 Second International Conference on Intelligent Computing and Control Systems (ICICCS); 14-15 June 2018; Madurai, India: IEEE. pp. 1560-1564.
- [7] Arozi M, Putri, FT, Ariyanto M, Caesarendra W, Widoyatriatmo A, Setiawan, JD. Electromyography (EMG) signal recognition using combined discrete wavelet transform based on artificial neural network (ANN). 2016 2nd International Conference of Industrial, Mechanical, Electrical, and Chemical Engineering (ICIMECE); 6-7 Oct. 2016; Yogyakarta, Indonesia: IEEE. pp. 95-99.
- [8] Mane SM, Kambli RA, Kazi FS, Singh, NM. Hand motion recognition from single channel surface EMG using wavelet & artificial neural network. *Procedia Computer Science* 2015; 49: 58-65.
- [9] Duan F, Dai L, Chang W, Chen Z, Zhu C, Li W. sEMG-based identification of hand motion commands using wavelet neural network combined with discrete wavelet transform. *IEEE Transactions on Industrial Electronics* 2015; 63(3): 1923-1934.
- [10] Duque CJG, Muñoz, LD, Mejía JG, Trejos ED. Discrete wavelet transform and k-nn classification in EMG signals for diagnosis of neuromuscular disorders. 2014 XIX Symposium on Image, Signal Processing and Artificial Vision; 17-19 Sept. 2014; Armenia, Colombia: IEEE. pp. 1-5.
- [11] Sapsanis, C., Recognition of basic hand movements using Electromyography, Diploma Thesis, University of Patras, Patras, Greece, 2013

- [12] Sapsanis C, Georgoulas G, Tzes A, Lymberopoulos D. Improving EMG based classification of basic hand movements using EMD, 35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC); 3-7 July 2013; Osaka, Japan: IEEE. pp. 5754-5757.
- [13] Arı A, Ayaz F, Hanbay D. EMG Sinyallerinin Kısa Zamanlı Fourier Dönüşüm Özellikleri Kullanılarak Yapay Sinir Ağları ile Sınıflandırılması. Fırat Üniversitesi Mühendislik Bilimleri Dergisi 2019; 31(2): 443-451.
- [14] Arı, A, Arı B, Alçin Ö.F. Elektromiyografi Sinyallerinin Permütasyon Entropi ve Bir Boyutlu Yerel İkili Özellikler Kullanılarak Sınıflandırılması. İzmir Tepecik Eğitim ve Araştırma Hastanesi Dergisi 2020; 30: 46-49.
- [15] Peng CK, Buldyrev SV, Havlin S, Simons M, Stanley HE, Goldberger AL. Mosaic Organization of DNA Nucleotides. Physical Review E 1994; 49(2): 1685.
- [16] Castiglioni P, Andrea F. A fast DFA algorithm for multifractal multiscale analysis of physiological time series. Frontiers in physiology 2019; 10: 115.
- [17] Bursa N, Tatlıdil H. Investigation of credit default swaps using detrended fluctuation analysis which is an Econophysical technique. Eurasian Eonom Stat Empr Econ J 2015; 2: 25-33.
- [18] Qian XY, Gu GF, Zhou WX. Modified detrended fluctuation analysis based on empirical mode decomposition for the characterization of anti-persistent processes. Physica A: Statistical Mechanics and its Applications 2011; 390(23-24): 4388-4395.
- [19] Ulkır O, Gokhan G, Kaplanoglu E. EMG signal classification using fuzzy logic. Balkan Journal of Electrical and Computer Engineering 2017; 5(2): 97-101.
- [20] Yu S, Li X, Zhang X, Wang H. The OCS-SVM: An Objective-Cost-Sensitive SVM With Sample-Based Misclassification Cost Invariance. IEEE Access 2019; 7: 118931-118942.
- [21] Vapnik VN. An overview of statistical learning theory. IEEE transactions on neural networks 1999; 10(5): 988-999.
- [22] Aslan M, Akbulut Y, Şengür A, İnce MC. Eklem tabanlı etkili düşme tespiti. Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi 2017; 32(4): 1025-1034.
- [23] Wu X, Zuo W, Lin, L, Jia W, Zhang D. F-SVM: Combination of feature transformation and SVM learning via convex relaxation. IEEE transactions on neural networks and learning systems, 2018; 29(11): 5185-5199.
- [24] Nguyen H, Demir B, Dalponte M. Weighted Support Vector Machines for Tree Species Classification Using Lidar Data. In IGARSS 2019-2019 IEEE International Geoscience and Remote Sensing Symposium: 28 July-2 Aug. 2019; Yokohama, Japan: IEEE. pp. 6740-6743.