



MAKÜ FEBED  
ISSN Online: 1309-2243  
<http://dergipark.ulakbim.gov.tr/makufebed>

Mehmet Akif Ersoy Üniversitesi Fen Bilimleri Enstitüsü Dergisi 7(1): 84-93 (2016)  
The Journal of Graduate School of Natural and Applied Sciences of Mehmet Akif Ersoy University 7(1): 84-93 (2016)

**Araştırma Makalesi / Research Paper**

## **Veri Madenciliği Süreç Modeli ile El Hareketlerinin Myoelektrik Kontrolü**

Musa PEKER<sup>1</sup>, İsmail KIRBAŞ<sup>2\*</sup>

<sup>1</sup> Muğla Sıtkı Koçman Üniversitesi, Teknoloji Fakültesi, Muğla

<sup>2</sup> Mehmet Akif Ersoy Üniversitesi, Mühendislik Mimarlık Fakültesi, Burdur

Geliş Tarihi (Received): 24.03.2016, Kabul Tarihi (Accepted): 25.04.2016

✉ Sorumlu Yazar (Corresponding author): [ismailkirbas@mehmetakif.edu.tr](mailto:ismailkirbas@mehmetakif.edu.tr)

☎ +90 248 2132751 📠 +90 248 2132704

### **ÖZ**

Yüzey elektromiyogram (EMG) sinyali, zengin motor kontrol bilgilerini içeren bir non-ninvaziv ölçümdür. Myoelektrik sinyal olarak da adlandırılan bu sinyaller, Myoelektrik kontrol olarak bilinen güç protez kontrolü için önemli bir girdidir. Bu sinyaller durağan olmayan bir yapıya sahiptir. Bu nedenle bu sinyallerden anlamlı bir bilgi keşfi yapmak için iyi bir analiz yöntemine ihtiyaç vardır. Bu çalışmada, bu amaç için veri madenciliği tekniklerini kullanan bir karar destek sistemi geliştirilmiştir. Veri madenciliği metodolojisi olarak Çapraz Endüstri Standart Süreci (CRISP-DM) yaklaşımı kullanılmıştır. Veri hazırlama aşamasında entropi tabanlı öznitelikler kullanıldı. 8 kanal EMG sinyallerinin kullanıldığı çalışmada her kanaldan 8 entropi tabanlı öznitelik elde edildi. Modelleme aşamasında etkili ve hızlı bir sınıflandırma algoritması olan destek vektör makinesi (DVM) kullanılmıştır. Performans değerlendirme aşamasında sınıflandırma doğruluğu, kappa istatistik değeri, ortalama mutlak hata ve kök ortalama kare hatası ölçütleri kullanıldı. Deneysel sonuçlar, önerilen yöntem ile elde edilen sonuçların literatürdeki yöntemlerden daha iyi sonuçlar verdiğini göstermektedir. Geliştirilen bu sistem, ilgili alandaki uzman kişilere yardımcı olabilecek bir karar destek sistemi olarak kullanılabilir.

**Anahtar Kelimeler:** Veri madenciliği, myoelektrik kontrol, EMG sınıflandırma, CRISP-DM modeli

## **Myoelectric Control of Hand Movements Using Data Mining Process Model**

### **ABSTRACT**

Surface electromyography (EMG) signal is a noninvasive measurement with rich motor control information. These signals which are also called as Myoelectric signal, is an important input for power prostheses control known as myoelectric control. These signals have non-stationary structure. Therefore, a good analysis method is required to make a meaningful knowledge discovery. In this study, a decision support system which uses data mining techniques has been developed for this purpose. Cross Industry Standard Process for Data Mining (CRISP-DM) approach has been used as data mining methodology. Entropy-based features have been used during data preparation stage. In the study in which 8-channel EMG signals are used, 8 entropy-based features have obtained from each channel. Support vector machine which is a fast and effective classification algorithm has used in the modeling phase. Classification accuracy, kappa statistic value, mean absolute error (MAE) ve root square mean error (RMSE) have been used in performance evaluation stage. Experimental results show that the results obtained with the proposed method are better than the results obtained with the methods in the literature. The developed system can be used as a decision support system that could help to the experts in related field.

**Keywords:** Data mining, myoelectric control, EMG classification, CRISP-DM model

## GİRİŞ

Elektromiyogram (EMG), elektriksel bir aktivite olup, kasların dinlenme ve kasılma durumlarında oluşur. Bu sinyaller, kaslarda ve motor sistemdeki anormalliklerin teşhisinde önemli bilgiler sunar (Bronzino ve Peterson, 2015). EMG işareti genellikle iki yöntemle elde edilir. Birincisi kasa iğne elektrot yerleştirilmesi, ikincisi ise kas üzerindeki deriye yüzey elektrot bağlanmasıdır. Yüzey EMG sinyalleri, kas enerjilerinin değerlendirilmesini sağlayan, kolay, güvenilir ve non-invaziv bir yöntemdir (Özmen ve ark., 2014).

Elektromiyogram (EMG) sinyali olarak da bilinen myoelektrik sinyal (MES), insan vücudu tarafından üretilen biyosinyallerden biridir (Khushaba ve ark., 2009b). Bu, pek çok motor ögesinden kas aktivitesini veya aksiyon potansiyellerinin toplamını temsil eder (Cameron ve Skofronick, 1978; Tanner, 2003). Myoelektrik kontrol (MEC) terimi elektrikli bir harici cihazı kontrol etmek için insan kaslarından myoelektrik sinyallerin kullanım işlemini ifade etmektedir. Özellikle, MEC genellikle eksik uzuvlara yapay alternatif olan protez cihazlarının kontrolünde kullanılmaktadır (Khushaba ve ark., 2009b). MES kol hareketlerinin farklı türleri için şakak yapısında belirgin farklılıklar sergiler. Bu da bir kas kasılması şeklinde sunulan zengin bilgilere dayanarak kullanıcının niyetini tanımlamak için bir örüntü tanıma yaklaşımının kullanımını kolaylaştırır.

Bilgilendirici bir sinyal olmasına rağmen, aynı kas üzerinde farklı konumlarda tespit edilen MES önemli ölçüde farklı genliklere sahip olabilir (Merletti ve ark., 2004). Bu durumda böyle bir sinyali kaydederken karmaşıklık artacaktır. Kas faaliyetlerinin tümünü yakalamak için, MES genellikle 4, 8, veya 16 gibi bir kanal sayısı kullanılarak kaydedilir (Khushaba ve ark., 2009b). EMG sinyallerinin doğasında olan durağan olmama sebebiyle, olası EMG varyasyonu elektrot durumu, kas yorgunluğu gibi faktörler tarafından tetiklenir. Bu büyük bir sorun olup laboratuvar ortamında geliştirilen myoelektrik kontrollü protez cihazlarının ticarileştirilmesini engellemektedir. Ayrıca myoelektrik kontrolde önemli zorluklardan biri sınıflar arasında en iyi ayırım yapabilen optimal bir öznitelik kümesi bulmaktır. Myoelektrik sinyallerinin sınıflandırılmasında belirtilen nedenlerden dolayı uzmanlara destek amaçlı etkili bir karar destek sistemine ihtiyaç duyulmaktadır.

Son yıllarda bu sinyallerden öznitelikler elde etmek amacıyla çok sayıda öznitelik çıkarma yönteminin kullanıldığı görülmektedir. Ortalama mutlak değer (Hudgins ve ark., 1993; Englehart ve Hudgins 2003), sıfırdan geçiş sayısı (Hudgins ve ark., 1993; Engle-

hart ve Hudgins, 2003), eğim işareti değişiklikleri sayısı (Hudgins ve ark., 1993; Englehart ve Hudgins, 2003), dalga şekli boyu (Hudgins ve ark., 1993; Englehart ve Hudgins, 2003), ortalama mutlak eğim değeri (Chan ve ark., 2000; Englehart ve Hudgins, 2003), Willison genliği (Chan ve ark., 2000), varyans (Chan ve ark., 2000), ortalama karekök (Momen ve ark., 2007), histogram (Huang ve ark., 2003), otoregresif (AR) katsayılar (Santa-Cruz ve ark., 2001; Peleg ve ark., 2002), hızlı fourier dönüşümü katsayıları (Yazama ve ark., 2003), kısa zamanlı Fourier dönüşümü katsayıları (Hannaford ve Lehman, 1986), dalgacık dönüşümü katsayıları (Karlsso ve ark., 2000; Rodriguez-Carreño ve Vuskovic, 2005; Carreño ve Vuskovic, 2007), dalgacık paket dönüşüm katsayıları (Englehart ve ark., 2001) ve örüntü tanıma için spektral bileşenler (Du ve Vuskovic, 2004; Vuskovic ve Du, 2006; Parker ve ark., 2006) gibi birçok öznitelik çıkarma yöntemi araştırmacılar tarafından kullanılmaktadır. Modellemenin sınıflandırma aşamasında, doğrusal diskriminant analizi (Englehart ve Hudgins, 2003; Geethanjali ve Ray, 2011; Geethanjali ve Ray, 2013), k-en yakın komşular (Peleg ve ark., 2002; Carreño ve Vuskovic, 2007), sinir ağı (Englehart ve Hudgins, 2003; Geethanjali ve Ray, 2011), bulanık sistemler (Chan ve ark., 2000), nöro-bulanık sınıflandırıcılar (Kiguchi ve ark., 2003) ve destek vektör sınıflandırıcılar (Oscoei ve Hu, 2008; Rekhi ve ark., 2009; Naik ve ark., 2010) gibi farklı sınıflandırma yaklaşımları bu sinyallerden hareketin örüntüsünün tanınması için uygulanmıştır.

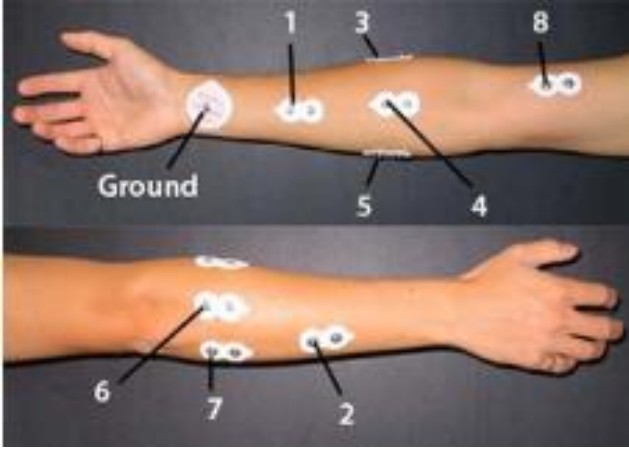
Bu çalışmada literatürdeki çalışmalardan farklı olarak yeni bir öznitelik kümesi oluşturulmuştur. Öznitelik kümesi entropi tabanlı özniteliklerden oluşmaktadır. Bu kapsamda 8 kanaldan veri alındıktan sonra, spektral entropi, örnek entropi, dalgacık entropi, permütasyon entropi, logaritmik enerji entropi, renyi entropi, yaklaşık entropi ve shannon entropi olmak üzere her kanaldan 8 entropi değeri hesaplanmıştır. Elde edilen öznitelik kümesi DVM algoritmasına giriş verisi olarak sunulmuştur.

Makalenin organizasyonu şu şekildedir: Bölüm 2'de bu çalışmada kullanılan veri ve metotlar hakkında bilgiler sunulmuştur. Bölüm 3'de deneysel sonuçlar, karşılaştırmalı analizler ve tartışma bulunmaktadır. Bölüm 4'de elde edilen sonuçlar ve gelecekte planlanan çalışmalar hakkında bilgiler verilmiştir.

## MATERYAL VE YÖNTEM

### Veri

Bu çalışmada kullanılan MES veri tabanı, Carleton Üniversitesi'nden Dr. Adrian D.C. Chan tarafından sağlanmıştır (Chan ve Green, 2007). Bu veri tabanındaki sekiz kanal EMG verisi 15 sağlıklı deneğin önkol kaslarından ve pazı kaslarından bileğe yerleştirilen bir referans elektrot ile birlikte AgAgCl elektrotlar kullanılarak alınmıştır (Chan ve Green, 2007). Elektrotların yerleşim düzeni Şekil 1'de görülmektedir. Yüze EMG sinyalleri kanal başına 3000 Hz'de örneklenmiştir. Denekler yedi önkol hareketini yapmıştır: Açık el, el kapalı, supinasyon, pronasyon, bilek esnetme, bilek germe ve dinlendirme. Veriler her denek tarafından tamamlanan beş denemede elde edilmiştir. Her bir hareket, her bir veri toplama denemesinde üç saniye süresince dört kez tekrar edilmiştir. Bu hareketlerin sıralaması rastgeleleştirilmiştir.



Şekil 1. Sağ önkol üzerinde sekiz elektrot yerleşimi (Khushaba ve ark., 2009a)

### Veri Madenciliği

Veri madenciliği, büyük veri tabanları içerisinde daha önceden bilinmeyen, nitelikli bilgilerin ortaya çıkarılması sürecidir (Clifton, 2014). Bu amaç için istatistik, makine öğrenmesi, yapay zekâ, veritabanı yönetimi ve veri görselleştirme gibi yöntemlerden yararlanılır. Literatürde veri madenciliği metodolojisi olarak sunulan çok sayıda yöntem bulunmaktadır. Bu çalışmada CRISP-DM modeli kullanılmıştır.

CRISP-DM sürecine göre veri madenciliği süreci altı aşamadan oluşan etkileşimli ve yinelenmeli bir süreçtir (Shearer, 2000). Bu metodolojiye göre veri madenciliği süreci aşağıdaki adımlardan oluşmaktadır:

- İş anlamak: Hedefler ve ön stratejiler belirlenir
- Veriyi anlamak: Veri toplama ve veri kalitesinin değerlendirildiği aşamadır.
- Veri hazırlama: Son veri hazırlanır, analiz için değişkenler seçilir. Uzun bir süreçtir.
- Modelleme: Modelleme tekniğinin seçildiği aşamadır.
- Değerlendirme: Bu aşamada farklı modeller denenir ve hedefe ulaşıp ulaşılmadığı kontrol edilir.
- Sahaya sürme: Raporlamanın yapıldığı aşamadır.

Veri hazırlama aşamasında, veriler ön işlem aşamalarından geçmektedir. Bu aşamada EMG sinyallerinden daha anlamlı ve düşük boyutlu veri elde etmek için öznelik çıkarma işlemleri yapılmıştır. 256 ms'den oluşan epoklara entropi tabanlı öznelik algoritmaları uygulanmıştır. Modelleme aşamasında ise verilerin sınıflandırılması ve karar işlemleri için DVM algoritması kullanılmıştır. Önerilen yöntemin blok şeması Şekil 2'de sunulmuştur.

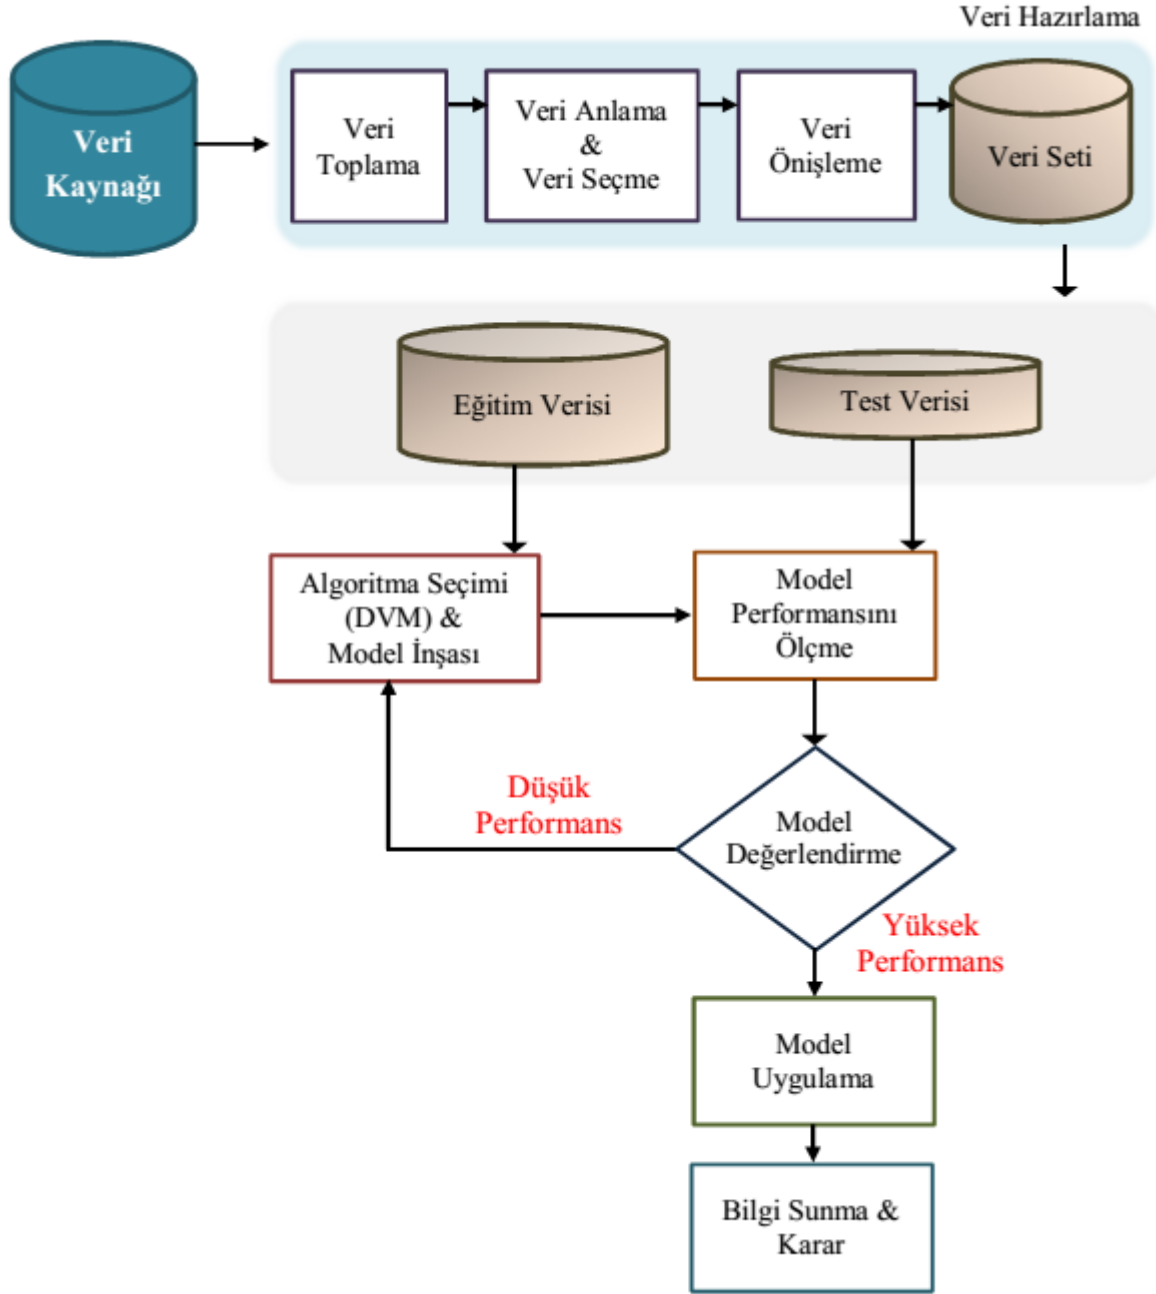
### Veri Hazırlama

Veri hazırlama aşamasında sinyal verileri ön işleme aşamasından geçirilmiştir. Verilere öncelikle 10-400 Hz aralığında bir bant geçiren filtre uygulanmıştır. Sonraki aşamada veriler 256 ms uzunluğunda 128 ms'lik kaydırmalardan elde edilen pencerele bölünmüştür. Her pencereye entropi tabanlı öznelik çıkarma yöntemleri uygulanmıştır. Bu öznelikler ve kısa açıklamaları aşağıda sunulmuştur.

Yaklaşık Entropi (ApEn): Bu parametre sinyaldeki düzensizliği ve kararsızlığı ölçmek için kullanılır (Pincus 1991). Düzensizlikteki artış, ApEn değerinin yükselmesine neden olur. Bu değer Denklem 1'de görüldüğü gibi hesaplanır.

$$ApEn = \ln \left( \frac{S_L(k)}{S_{L+1}(k)} \right) \quad (1)$$

Burada  $S_L(k)$ ,  $L$  sinyal örüntüsünün ortalama uzunluğudur.  $S_{L+1}(k)$ ,  $L + 1$  sinyal örüntüsünün ortalama uzunluğudur.



**Şekil 2.** El hareketlerinin myoelektrik kontrolü için uygulanan veri madenciliği yaklaşımı

Permütasyon Entropi (PE<sub>n</sub>): PE<sub>n</sub>, sinyaller arasındaki bağlantıları hesaplayarak, sinyalin karmaşıklığını tahmin eder (Bandt ve Pompe, 2002). PE<sub>n</sub>, Denklem (2) kullanılarak hesaplanır.

$$PE_n = - \sum_{f=1}^n R_f \log_2 R_f \quad (2)$$

Burada  $R_f$ , bağıl frekansı ifade eder.

Renyi entropi (RE<sub>n</sub>): RE<sub>n</sub>, Shannon entropisinin genelleştirilmiş şeklidir (Rényi, 1961). Bu değer spektral karmaşıklığı tahmin eder ve Denklem 3'de görüldüğü gibi hesaplanır.

$$REn = -\frac{a}{1-a} \sum \log sp_i^a \quad (3)$$

Burada  $sp_i$  toplam spektral gücü ifade eder.

Dalgacık Entropisi (WE): WE, farklı frekans bantlarında sinyalin bağıl enerjisini hesaplar (Rosso ve ark. 2001). Bu ölçüt, düzensizliğin derecesini belirlemek için kullanılır. WE değeri, Denklem 4'de görüldüğü gibi hesaplanır.

$$WE = -\sum_{i < 0} \alpha_i \ln \alpha_i \quad (4)$$

Burada  $\alpha_i$  sinyalin olasılık dağılımını temsil eder ve  $i$ , farklı çözünürlük seviyelerini tanımlar.

Shannon entropisi: Bu spektral entropi çeşitlerinden biridir ve sinyalin spektral karmaşıklığı ölçmek için kullanılır (Shannon ve Weaver, 1964). Bu değer, Denklem (5) kullanılarak hesaplanır.

$$ShEn = -\sum_{i=0}^{N-1} (p_i(x))^2 (\log_2(p_i(x)))^2 \quad (5)$$

Burada  $p_i(x)$  sonlu uzunlukta sayısal bir rastgele değişkenin olasılık dağılım fonksiyonudur.

Logaritmik enerji entropisi (LogEn): Entropi ölçümü için kullanılan algoritmalarından birisi de LogEn yöntemidir. Bu değer, Coifman ve Wickerhauser (Coifman ve Wickerhauser, 1992) tarafından entropi tabanlı dalgacık paket dönüşümü kullanılarak hesaplanmıştır. Bu değer, Denklem (6) kullanılarak hesaplanır.

$$LogEn = -\sum_{i=0}^{N-1} (\log_2(p_i(x)))^2 \quad (6)$$

Burada  $p_i(x)$  sonlu uzunlukta sayısal bir rastgele değişkenin olasılık dağılım fonksiyonudur.

Örnek Entropi (SampEn): SampEn, zaman dizisinin karmaşıklığını ölçmek için Ricman tarafından önerilmiştir (Richman ve Moorman, 2000). Bu yöntem yak-

laşık entropinin modifiye edilmiş bir versiyonudur. Bu değer, Denklem (7)'de görüldüğü gibi hesaplanır.

$$SampEn = -\log\left(\frac{A}{B}\right) \quad (7)$$

Burada  $A$ ,  $(m + 1)$  uzunluğundaki vektör çiftlerinin toplam sayısını içerir ve  $B$ ,  $m$  uzunluğundaki vektör çiftlerinin toplam sayısını içerir.  $m$  değeri, bu çalışmada 2 olarak alınmıştır.

Spektral entropi (SpEn): Bu değer hesaplanırken işaretin güç spektrumu bileşenlerinin olasılıkları dikkate alınır. SpEn, Denklem (8) kullanılarak hesaplanır.

$$SpEn = \sum_f P_f \log\left(\frac{1}{P_f}\right) \quad (8)$$

Öncelikle Fourier dönüşümü kullanılarak işaretin güç spektral yoğunluğu hesaplanır. Elde edilen her bir frekans değeri sinyalin toplam güç miktarına bölünür. Bu şekilde bir olasılık yoğunluk fonksiyonu elde edilir. Denklem (8)'deki  $P_f$  bu olasılık yoğunluk fonksiyonunu ifade eder.

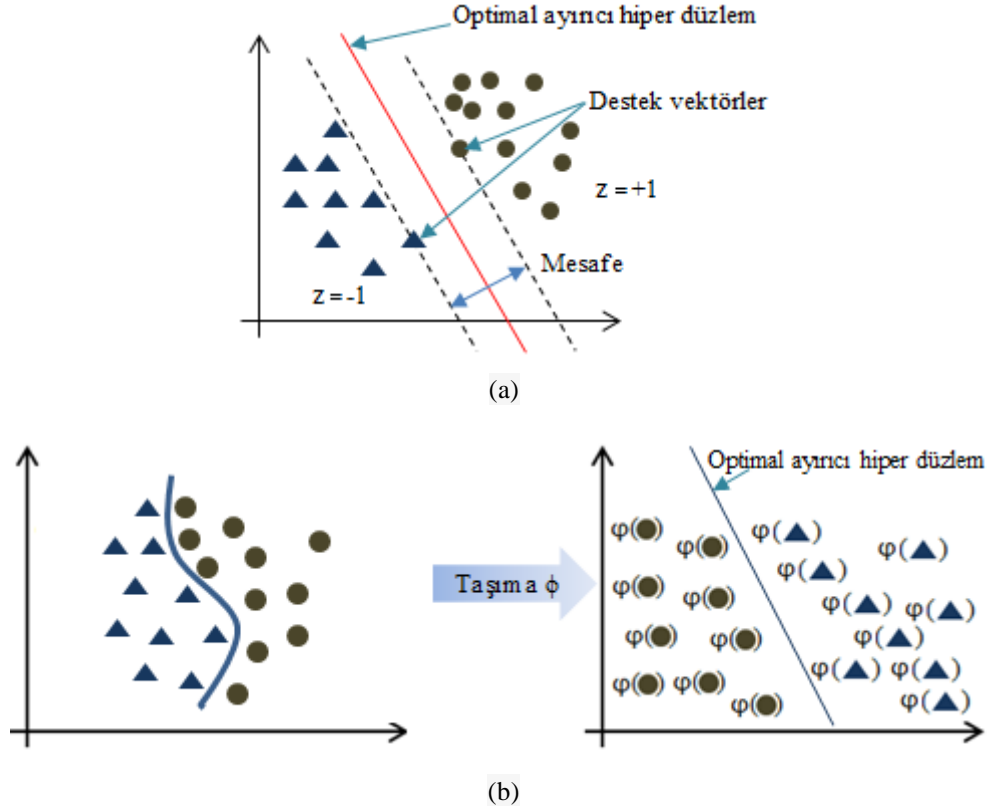
### Destek Vektör Makineleri (DVM)

DVM, Vapnik tarafından sınıflandırma ve modelleme için geliştirilen bir algoritmadır (Cortes ve Vapnik, 1995). Bu algoritma Lagrange çarpanları denklemlerinin formasyonuna dayanmaktadır. Algoritmanın nihai hedefi; veri noktalarını iyi seviyede farklı sınıflara ayıran optimum ayırıcı düzlemin tespitidir. Bu şekilde iki sınıf arasındaki maksimum uzaklık elde edilecektir. DVM'nin doğrusal ve doğrusal olmayan iki durumu vardır. Doğrusal DVM lineer olarak ayırt edilebilen problemlere uygulanır. Doğrusal DVM yapısı Şekil 3a'da sunulmuştur.  $(y_1, y_2, \dots, y_n)$  veri seti,  $z_i \in (-1, 1)$  sınıf etiketleri ve  $b$  eşik değeri olsun. DVM algoritmasında veri,  $g(x) = w^T y + b = 0$  hiper düzlemi ile ayrılmaktadır.

$$w^T y_t + b \geq +1, \quad \text{eğer } z_t = +1 \text{ (sınıf 1)} \quad (9)$$

$$w^T y_t + b \leq -1, \quad \text{eğer } z_t = -1 \text{ (sınıf 2)} \quad (10)$$

$g(x) = w^T y + b = 0$  hiper düzleminin alt ve üst tarafında kalan noktalar Denklem 9 ve 10 kullanılarak hesaplanmaktadır.



**Şekil 3.** DVM'nin geometrik sunumu (a) Doğrusal DVM (b) Doğrusal olmayan DVM (Su ve ark., 2013)

Pratik uygulamalarda genellikle doğrusal olarak ayırt edilme durumu yoktur. Bu gibi durumlarda verinin daha yüksek boyutlu bir uzaya taşınması bir çözüm olarak düşünülebilir. Doğrusal olmayan DVM'lerin dayandığı temel fikir budur. DVM bu işlemleri gerçekleştirmek için çekirdek fonksiyonlarını kullanır. Bu

durumda  $a$  boyutlu bir veri kümesi,  $b > a$  olacak şekilde  $b$  boyutlu yeni bir veri kümesine taşınır. Doğrusal olmayan DVM yapısı Şekil 3b'de sunulmuştur. DVM için geliştirilen çok sayıda çekirdek fonksiyonu bulunmaktadır. Önemli çekirdek fonksiyonların birkaçı Denklem 11-13'de sunulmuştur.

$$\text{Doğrusal çekirdek fonksiyonu} : K(y_i, y_j) = y_i^T y_j \quad (11)$$

$$\text{Polinom çekirdek fonksiyonu} : K(y_i, y_j) = (1 + y_i^T y_j)^p \quad (12)$$

$$\text{Radyal tabanlı çekirdek fonksiyonu} : K(y_i, y_j) = e^{-\frac{\|y_i - y_j\|^2}{2\sigma^2}} \quad (13)$$

## BULGULAR VE TARTIŞMA

Deneyel çalışmanın geçerliliğini artırmak için 10 kat çapraz doğrulama yöntemi kullanıldı. Sonuçların güvenilirliği ve kararlılığının tespiti için deneyler 10 defa tekrar edilmiştir. Ardından elde edilen değerlerin ortalamaları hesaplanmıştır.


Öznitelik çıkarma aşamasında entropi tabanlı öznitelikler kullanıldı. 8 kanal EMG sinyallerinin kullanıldığı çalışmada her kanaldan 8 entropi tabanlı öznitelik elde edildi. Elde edilen öznitelikler DVM algoritması ile sınıflandırıldı. Performans değerlendirme aşama-

sında sınıflandırma doğruluğu, kappa istatistik değeri, ortalama mutlak hata, kök ortalama kare hatası ölçütleri kullanıldı.

Bu çalışmada, DVM algoritmasının parametre tespiti şu şekilde yapılmıştır. Çekirdek fonksiyonu olarak, iyi sonuçlar verdiği için radyal tabanlı çekirdek fonksiyonu tercih edildi. İyi sonuç veren parametre değerleri, ızgara arama mekanizması ile eğitim veri kümesi üzerinde 10 kat çapraz doğrulama kullanılarak bulundu. Bu ızgara aramasında, düzenleme parametresi C ve çekirdek fonksiyonu yayılım değeri  $\gamma$  için optimum değerler araştırıldı. C pa-

rametresi için  $C = 2^{-10}, 2^{-4}, \dots, 2^{15}$  aralığı belirlenmiştir.  $\gamma$  parametresi için de  $\gamma = 2^{-10}, 2^{-14}, \dots, 2^{10}$  aralıkları belirlenmiştir. Bu aralık değerlerinde yapılan deneyler sonucunda,

problem türüne bağlı olarak bulunan en iyi parametre değerleri  $C = 2^{14}$  ve  $\gamma = 2^{-4}$  şeklinde olmuştur. Sonuçlar Şekil 4'de grafiksel olarak sunulmuştur.



Şekil 4. DVM algoritmasında parametre optimizasyonu

DVM algoritmasının uygulanması ile elde edilen sonuçlar Tablo 1'de sunulmaktadır. DVM algoritması için 3 farklı çekirdek algoritması ile deneyler yapılmıştır. Tabloda da görüldüğü gibi en iyi sonuç RBF çekirdek fonk-

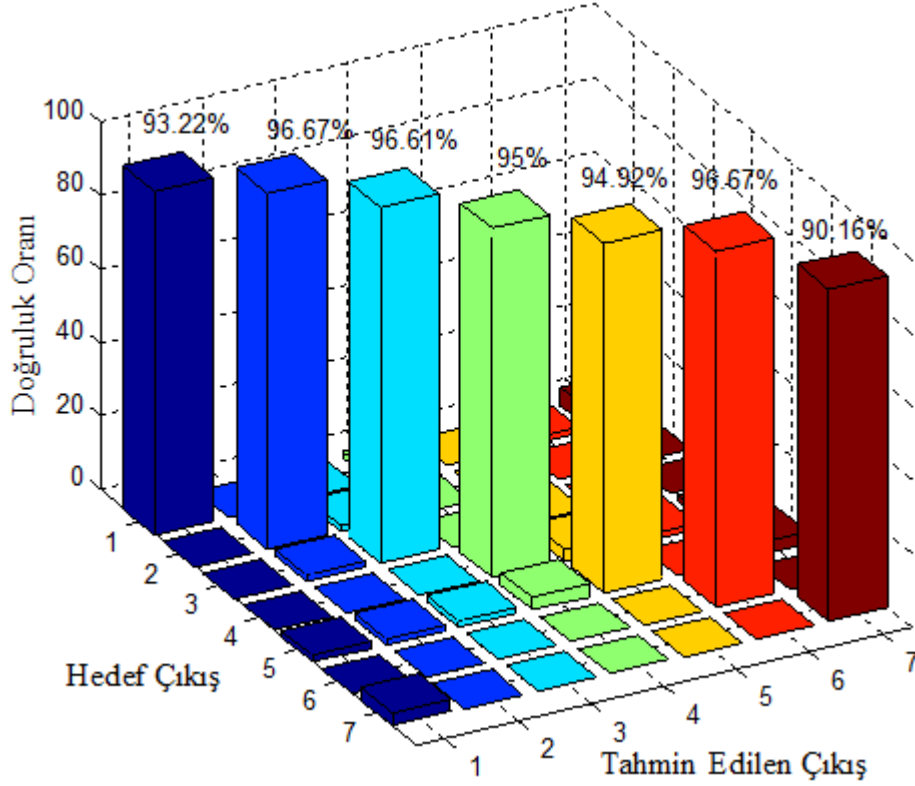
siyonu ile elde edilmiştir. Ayrıca 10 kat çapraz doğrulama deneylerinin Kat 4 aşamasında elde edilen karışıklık matrisi Şekil 5'de sunulmaktadır.

Tablo 1. Farklı çekirdek fonksiyonlarıyla elde edilen sonuçlar

Performans Ölçütü	RBF Çekirdek	Polinom Çekirdek	Doğrusal Çekirdek
Doğruluk	95.31	93.66	91.86
Kappa Değeri	0.93	0.91	0.89
MAE	0.045	0.048	0.05
RMSE	0.125	0.146	0.165

Literatürde aynı veri kümesi üzerinde yapılan çalışmalar ve sonuçlar şu şekildedir. Liu (Liu, 2015) destek vektör makinesi tabanlı uyarlanabilir danışmansız bir sınıflandırıcı ile yaptığı çalışmada %92 sınıflandırma doğruluğu elde etti. Rami ve arkadaşları (Khushaba ve ark., 2010) sürü tabanlı bulanık diskriminant analizi yöntemini kullanarak test verileri üzerinde %94.6 sınıflandırma doğruluğu elde ettiler. Khushaba ve arkadaş-

ları (Khushaba ve ark., 2009a), Fisher lineer diskriminant analizi, bulanık mantık ve diferansiyel gelişim algoritmalarından oluşan hibrit bir yöntem ile yaptığı çalışmada %94.71 sınıflandırma doğruluğu elde ettiler. Sonuç olarak önerilen yöntemin mevcut çalışmalardan daha iyi sonuçlar verdiği görülmektedir.



Şekil 5. Kat 4 aşamasında elde edilen karışıklık matrisi

## SONUÇLAR

Bu çalışmada el hareketlerinin myoelektrik kontrolüne yönelik olarak veri madenciliği tekniklerini kullanan bir sınıflandırma sistemi geliştirilmiştir. Deneklerden alınan myoelektrik sinyallerine veri madenciliği teknikleri uygulanarak yedi önkol hareketinin sınıflandırıldığı çalışmada %95.31 sınıflandırma doğruluğu elde edilmiştir.

Gelecek çalışmalarda modelleme aşamasında farklı algoritmalarla karşılaştırmalı analizlerin yapılması hedeflenmektedir. Ayrıca myoelektrik kontrolü daha çok etkileyen özneliklerin tespiti için öznelik seçme algoritmalarından yararlanılacaktır.

## TEŞEKKÜR

Bu çalışmada kullanılan myoelektrik sinyal verilerini bizimle paylaşan ve yardımlarını esirgemeyen Carleton Üniversitesi'nden Dr. Adrian D. C. Chan'a teşekkür ederiz.

## KAYNAKLAR

- Bandt, C., Pompe, B., (2002). Permutation Entropy: A Natural Complexity Measure for Time Series. *Phys Rev Lett* 88:174102. doi: 10.1103/PhysRevLett.88.174102
- Bronzino, J.D., Peterson, D.R., (2015). *The Biomedical Engineering Handbook, Fourth Edition: Four Volume Set, 4 edition*. CRC Press, Boca Raton, FL
- Cameron, J.R., Skofronick, J.G., (1978). *Medical Physics, 1 edition*. Wiley, New York
- Carreño, I.R., Vuskovic, M., (2007). Wavelet Transform Moments for Feature Extraction from Temporal Signals. In: Filipe J, Ferrier J-L, Cetto JA, Carvalho M (eds) *Informatics in Control, Automation ve Robotics II*. Springer Netherlands, Dordrecht, pp 235–242
- Chan, A.D.C., Green, G.C. ve ark., (2007). Myoelectric control development toolbox. In: In Conference of the Canadian Medical & Biological Engineering Society. Toronto;
- Chan, F.H., Yang, Y.S., Lam, F.K., (2000). Fuzzy EMG classification for prosthesis control. *IEEE Trans Rehabil Eng Publ IEEE Eng Med Biol Soc* 8:305–311.
- Clifton, C., (2014). data mining | computer science. In: *Enycl. Br.* <http://global.britannica.com/technology/data-mining>. Accessed 8 Apr 2016
- Coifman, R.R., Wickerhauser, M.V., (1992). Entropy-based algorithms for best basis selection. *IEEE Trans Inf Theory* 38:713–718. doi: 10.1109/18.119732
- Cortes, C., Vapnik, V., (1995). Support-Vector Networks. *Mach Learn* 20:273–297. doi: 10.1023/A:1022627411411
- Du, S., Vuskovic, M., (2004). Temporal vs. spectral approach to feature extraction from prehensile EMG signals. In:



- Proceedings of the 2004 IEEE International Conference on Information Reuse ve Integration, 2004. IRI 2004. pp 344–350
- Englehart, K., Hudgin, B., Parker, P.A., (2001). A wavelet-based continuous classification scheme for multifunction myoelectric control. *IEEE Trans Biomed Eng* 48:302–311. doi: 10.1109/10.914793
- Englehart, K., Hudgins, B., (2003). A robust, real-time control scheme for multifunction myoelectric control. *IEEE Trans Biomed Eng* 50:848–854. doi: 10.1109/TBME.2003.813539
- Geethanjali, P., Ray, K.K., (2011). Identification of motion from multi-channel EMG signals for control of prosthetic hand. *Australas Phys Eng Sci Med Support Australas Coll Phys Sci Med Australas Assoc Phys Sci Med* 34:419–427. doi: 10.1007/s13246-011-0079-z
- Geethanjali, P., Ray, K.K., (2013). Statistical Pattern Recognition Technique For Improved Real-time Myoelectric Signal Classification. *Biomed Eng Appl Basis Commun* 25:1350026. doi: 10.4015/S1016237213500269
- Hannaford, B., Lehman, S., (1986). Short Time Fourier Analysis of the Electromyogram: Fast Movements ve Constant Contraction. *IEEE Trans Biomed Eng BME-33:1173–1181*. doi: 10.1109/TBME.1986.325697
- Huang, H-P., Liu, Y-H., Wong, C-S., (2003). Automatic EMG feature evaluation for controlling a prosthetic hand using supervised feature mining method: an intelligent approach. In: *Robotics ve Automation, 2003. Proceedings. ICRA '03. IEEE International Conference on*. pp 220–225 vol.1
- Hudgins, B., Parker, P., Scott, R.N., (1993). A new strategy for multifunction myoelectric control. *IEEE Trans Biomed Eng* 40:82–94. doi: 10.1109/10.204774
- Karlsson, S., Yu, J., Akay, M., (2000). Time-frequency analysis of myoelectric signals during dynamic contractions: a comparative study. *IEEE Trans Biomed Eng* 47:228–238. doi: 10.1109/10.821766
- Khushaba, R.N., Al-Ani, A., Al-Jumaily, A., (2010). Swarm Based Fuzzy Discriminant Analysis for Multifunction Prosthesis Control. In: *Schwenker F, Gayar N (eds) Artificial Neural Networks in Pattern Recognition: 4th IAPR TC3 Workshop, ANNPR 2010, Cairo, Egypt, April 11-13, 2010. Proceedings. Springer Berlin Heidelberg, Berlin, Heidelberg*, pp 197–206
- Khushaba, R.N., Al-Jumaily, A., Al-Ani, A., (2009a). Evolutionary fuzzy discriminant analysis feature projection technique in myoelectric control. *Pattern Recognit Lett* 30:699 – 707. doi: <http://dx.doi.org/10.1016/j.patrec.2009.02.004>
- Khushaba, R.N., AlSukker, A., Al-Ani, A. ve ark., (2009b). A novel swarm based feature selection algorithm in multifunction myoelectric control. *J Intell Fuzzy Syst* 20:175–185. doi: 10.3233/IFS-2009-0426
- Kiguchi, K., Esaki, R., Tsuruta, T. ve ark., (2003). An exoskeleton for human elbow ve forearm motion assist. In: *Intelligent Robots ve Systems, 2003. (IROS 2003). Proceedings. 2003 IEEE/RSJ International Conference on*. pp 3600–3605 vol.3
- Liu, J., (2015). Adaptive myoelectric pattern recognition toward improved multifunctional prosthesis control. *Med Eng Phys* 37:424 – 430. doi: <http://dx.doi.org/10.1016/j.medengphy.2015.02.005>
- Merletti, R., Bottin, A., Cescon, C. ve ark., (2004) Multichannel surface EMG for the non-invasive assessment of the anal sphincter muscle. *Digestion* 69:112–122. doi: 10.1159/000077877
- Momen, K., Krishnan, S., Chau, T., (2007). Real-time classification of forearm electromyographic signals corresponding to user-selected intentional movements for multifunction prosthesis control. *IEEE Trans Neural Syst Rehabil Eng Publ IEEE Eng Med Biol Soc* 15:535–542. doi: 10.1109/TNSRE.2007.908376
- Naik, G.R., Kumar, D.K., Jayadeva, (2010). Twin SVM for Gesture Classification Using the Surface Electromyogram. *IEEE Trans Inf Technol Biomed* 14:301–308. doi: 10.1109/TITB.2009.2037752
- Oskoei, M.A., Hu, H., (2008). Support Vector Machine-Based Classification Scheme for Myoelectric Control Applied to Upper Limb. *IEEE Trans Biomed Eng* 55:1956–1965. doi: 10.1109/TBME.2008.919734
- Özmen, G., Özbay, Y., Ekmekçi, A.H., (2014). EMG sinyallerinde kas yorgunluğunun YSA ile sınıflandırılması. *Kapadokya*, pp 279–282
- Parker, P., Englehart, K., Hudgins, B., (2006). Myoelectric signal processing for control of powered limb prostheses. *J Electromyogr Kinesiol Off J Int Soc Electrophysiol Kinesiol* 16:541–548. doi: 10.1016/j.jelekin.2006.08.006
- Peleg, D., Braiman, E., Yom-Tov, E., Inbar, G.F., (2002). Classification of finger activation for use in a robotic prosthesis arm. *IEEE Trans Neural Syst Rehabil Eng* 10:290–293. doi: 10.1109/TNSRE.2002.806831
- Pincus, S.M., (1991). Approximate entropy as a measure of system complexity. *Proc Natl Acad Sci U S A* 88:2297–2301.
- Rekhi, N.S., Arora, A.S., Singh, S., Singh, D., (2009). Multi-Class SVM Classification of Surface EMG Signal for Upper Limb Function. In: *Bioinformatics ve Biomedical Engineering , 2009. ICBBE 2009. 3rd International Conference on*. pp 1–4
- Rényi, A., (1961). On Measures of Entropy ve Information. In: *Proceedings of the Fourth Berkeley Symposium on Mathematical Statistics ve Probability, Volume 1: Contributions to the Theory of Statistics. University of California Press, Berkeley, Calif.*, pp 547–561
- Richman, J.S., Moorman, J.R., (2000). Physiological time-series analysis using approximate entropy ve sample entropy. *Am J Physiol Heart Circ Physiol* 278:H2039–2049.
- Rodriguez-Carreño, I., Vuskovic, M., (2005). Wavelet-Based Feature Extraction from Prehensile EMG Signals. In: *NBC. Sweden*,
- Rosso, O.A., Blanco, S., Yordanova, J. ve ark., (2001). Wavelet entropy: a new tool for analysis of short duration brain electrical signals. *J Neurosci Methods* 105:65 – 75. doi: [http://dx.doi.org/10.1016/S0165-0270\(00\)00356-3](http://dx.doi.org/10.1016/S0165-0270(00)00356-3)
- Santa-Cruz, M.C., Riso, R., Sepulveda, F., (2001). Optimal selection of time series coefficients for wrist myoelectric control based on intramuscular recordings. In: *Engineering in Medicine ve Biology Society, 2001. Proceedings of the 23rd Annual International Conference of the IEEE*. pp 1384–1387 vol.2
- Shannon, C.E., Weaver, W., (1964). *The Mathematical Theory of Communication*, First Edition. University of Illinois Press, Urbana
- Shearer, C. (2000). The CRISP-DM Model: The new blueprint for data mining. *J Data Warehous* 5:13–22.

Su, L., Shi, T., Xu, Z. ve ark., (2013) Defect Inspection of Flip Chip Solder Bumps Using an Ultrasonic Transducer. Sensors 13:16281–16291. doi: 10.3390/s131216281  
Tanner GA (2003) Medical Physiology, Second edition. LWW, Philadelphia  
Vuskovic M, Du S (2006) Marko Vuskovic ve Sijiang Du Spectral Moments for Feature Extraction from Temporal

Signals Spectral Moments for Feature Extraction from Temporal Signals.  
Yazama Y, Fukumi M, Mitsukura Y, Akamatsu N (2003) Feature analysis for the EMG signals based on the class distance. In: Computational Intelligence in Robotics ve Automation, 2003. Proceedings. 2003 IEEE International Symposium on. pp 860–863 vol.2

---