

EMG SİNYALLERİ İÇİN HİBRİD ÖZNETELİK ÇIKARMA YÖNTEMİ GELİŞTİRİLMESİ

Abdullah CALISKAN¹ (ORCID: 0000-0002-9265-6335)*

¹ İskenderun Teknik Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Biyomedikal Mühendisliği Bölümü

Geliş / Received: 21.03.2019
Kabul / Accepted: 17.05.2019

ÖZ

Bu çalışmada EMG sinyalleri kullanılarak 14 farklı parmak hareketi önerilen yeni bir öznetelik çıkarma yöntemiyle sınıflandırılmıştır. EMG sinyallerinden parmak hareketlerinin tespiti / sınıflandırılması, ön işleme, özellik çıkarma ve sınıflandırma adımlarını içeren 3 ana adımdan oluşur. EMG sinyallerinin sınıflandırılmasında, sınıflandırıcının performansı doğrudan öznetelik çıkarma yöntemine bağlıdır. Bu sebeple öznetelik çıkarma yöntemi uygun bir biçimde seçilmelidir. Literatürde zaman, histogram ve frekans tabanlı birçok öznetelik çıkarma yöntemi vardır. Ancak bu yöntemler yüksek zaman karmaşıklığı, çok fazla işleme ihtiyacı, fazla sayıda kontrol parametresi bulundurma, vb. birçok dezavantaja sahiptir. Bu çalışmada EMG sinyallerinden çeşitli parmak hareketlerinin sınıflandırılması amacıyla sayılan dezavantajları ortadan kaldırmak için yeni bir öznetelik çıkarma yöntemi sunulmuştur. Bu yöntem iki zaman tabanlı öznetelik çıkarma yönteminin hibritleştirilmesiyle elde edilmiştir. 10 kat çapraz doğrulamayla elde edilen deneysel sonuçlarına göre, önerilen yöntemin %97,48 doğruluk oranıyla bu çalışmada kullanılan diğer 9 öznetelik çıkarma yöntemlerinden daha iyi olduğu deneysel olarak gösterilmiştir. Deneysel sonuçlar istatistiksel yöntemlerle desteklenmiştir.

Anahtar kelimeler: Elektromiyografi, öznetelik çıkarma, sınıflandırma, parmak hareketleri

IMPROVEMENT OF THE HYBRID FEATURE EXTRACTION METHOD FOR EMG SIGNALS

ABSTRACT

This study aims to discuss classification of 14 different finger movements from EMG signals by using new feature extraction technique. The detection/classification of finger movements consists of 3 main steps including, preprocessing, feature extraction and classification steps. In classification of EMG signals, the performance of the classifier directly depends on feature extraction methods, including, time, histogram and frequency-based methods. However, these feature extraction methods have several drawbacks including, high time complexity, high computation demand, user supplied parameters, etc. In this paper, a new feature extraction method has been proposed for the classification of finger movements from EMG signals to overcome these problems. The proposed method based on hybridization of 2-time domain feature extraction techniques. The use of this method resulted in an accuracy of 97.48% after 10-fold-cross-validation. The experimental results supported with statistical analysis show that proposed method is better than 9 feature extraction methods investigated in this paper

Keywords: Electromyography, feature extraction, classification, finger movements

*Corresponding author / Sorumlu yazar. Tel.: +90 326 613 56 00; e-mail / e-posta: abduallah.caliskan@iste.edu.tr

1. GİRİŞ

Günümüzde elektromiyografi (EMG) sinyallerinden birçok alanda faydalanılmaktadır [1]. EMG, özellikle insanların hayatını kolaylaştırma anlamında ciddi bir öneme sahiptir. Bu önem mevcut verilerin artması ve bilgisayarların hızlanmasıyla birlikte daha da artmaktadır. EMG sinyalleri kullanılarak vücudun çeşitli bölümlerinde oluşan hareketlerin sınıflandırılması [2] değişik amaçlar için yapılmaktadır. Literatürde en çok el hareketlerinin sınıflandırılması [3-7] yapılmakla birlikte parmak hareketlerinin [8, 9] ya da vücut pozisyonunun belirlenmesi [10] gibi çalışmalar da sıklıkla yapılmaktadır. Öte yandan EMG sinyalleri bazı hastalıkların teşhisinde [11], protez kol/el tasarımında [12], eğlence sektöründe [13, 14] yaygın biçimde kullanılmaktadır.

EMG sinyalleri kullanılarak yapılması planlanan sınıflandırma işlemi üç temel adımdan oluşur [8-9]. Birbirine sıkı sıkıya bağlı olan bu üç adım ön işleme, öznelik çıkarma ve sınıflandırmadır. Etkili bir sınıflandırma yapabilmek için bu üç aşamanın dikkatli biçimde planlanması gerekir. Temel olarak, ön işlem aşamasında sinyal gürültüden arındırılarak pencereleme işlemi uygulanır. Sonrasında pencerelenen sinyallerden, sinyali en iyi biçimde temsil edebilecek çeşitli öznelikler çıkarılır. Son olarak çıkarılan öznelikler ve bu özneliklerle ilgili olan etiketler bir sınıflandırıcı yardımıyla sınıflandırılır. Sınıflandırıcının performansı doğrudan özneliklere bağlıdır [13, 14]. Bu nedenle bu çalışmada çeşitli öznelik çıkarma yöntemlerinin EMG sinyallerinin sınıflandırma performansı üzerinde etkileri incelenerek yeni bir öznelik çıkarma yöntemi önerilmiştir.

Literatürde EMG sinyallerinin sınıflandırılması için birçok öznelik çıkarma yöntemi kullanılmıştır [13-17]. Öznelik çıkarma yöntemleri farklı problemler için farklı sınıflandırma performansına sahip olabilmektedir [13]. Bu nedenle hangi öznelik çıkarma yönteminin hangi problem için uygun olduğuna karar vermek son derece güçtür. Ayrıca mevcut öznelik çıkarma yöntemlerinin bazıları iyi sınıflandırma performansına sahip olmasına rağmen çok kompleks ve zaman alıcıdır [16]. Bu tür olumsuzluklar göz önünde bulundurularak bu çalışmada her veri setine kolay uygulanabilir ve yüksek doğruluk oranlarına sahip bir sınıflandırıcı kullanılmıştır. Önerilen yöntemin sınıflandırma performansı K-en yakın komşu (KNN) algoritmasıyla test edilmiştir. Literatürde birçok sınıflandırma algoritması değişik amaçlar için kullanılmaktadır [18,19]. Ancak çalışmamızın amacı yeni bir öznelik çıkarma yöntemi önermek olduğu için sınıflandırma algoritmalarından bu amaca en uygun olanı seçilmiştir. Çünkü gerek literatürden gerekse yapılan simülasyonlardan KNN algoritmasının bu amaç için kullanılabilceği açık bir şekilde görülmektedir.

EMG sinyallerinden öznelik çıkarmak için genellikle zaman tabanlı veya histogram tabanlı öznelik çıkarma yöntemleri kullanılmaktadır. Bu çalışmada koldan kayıt edilen EMG sinyallerinden 14 farklı parmak hareketinin sınıflandırılması için hangi öznelik çıkarma yönteminin daha etkili olduğu incelenmiştir. Bunun yanında yeni bir öznelik çıkarma yöntemi önerilmiştir. Önerilen yöntem zaman tabanlı öznelik çıkarma yöntemlerinden iki örneklemin farkı (IOF) ve Mutlak ortalama (MO) yöntemlerinin hibritleştirilmesine dayanmaktadır. MO, EMG sinyallerinden öznelik çıkarmak için sıklıkla kullanılan yöntemlerin birisidir [13]. Sinyalin mutlak ortalama değerinin alındığı bu yöntem başarılı ve hızlıdır. Öte yandan bir diğer yöntem IOF ise zaman tabanlı öznelik çıkarma yöntemlerinin en popüler olanlarından bir diğeridir [13-14]. Bu yöntemde ise birbiri ardına gelen iki sinyal örneğinin farkları alınarak toplanır. Bu toplam öznelik olarak kullanılır. EMG sinyallerinden öznelik çıkarmada IOF, MO'ya göre gerek hız gerekse de doğruluk oranları açısından daha başarılıdır.

Bu çalışmada önerilen teknikte bu iki farklı yöntemin iyi özelliklerini tek bir öznelik çıkarma yönteminde birleştirilmiştir. Araştırıldığı kadarıyla literatüre daha önce böyle bir yöntem sunulmamıştır. Önerilen yöntemde yer alan dengeleme parametresi sayesinde öznelik çıkarma yönteminin performansı kolayca kontrol edilebilmektedir. Bunun yanında bu parametre kullanılarak önerilen yöntem MO ya da IOF'e yaklaştırılabilmektedir. Bu iki hızlı ve güçlü öznelik çıkarma yöntemi kombine edilerek fark ve ortalamanın hibritleştirilmesi (FOH) adı verilen yeni bir öznelik çıkarma yöntemi literatüre sunulmuştur.

Önerilen yöntemi test etmek için Khushaba ve ark. tarafından toplanan veri seti [9, 20] kullanılmıştır. Veri setinde güvenli otomobil kullanımı sağlamak ve sürüş konforunu arttırmak için el hareketleri yardımıyla çeşitli komutlar verilmesi amaçlanmıştır. Bu komutlar müzik açma, telefona cevap verme, vb. gibi 14 farklı komutu içermektedir. Böyle bir sistemi kurmak için basit bir sınıflandırıcı ve basit bir öznelik çıkarma yöntemi kullanmak en doğru seçim olacaktır. Çünkü bu ve buna benzer işlemlerin hız ve hafıza açısından ciddi kısıtları olan gömülü sistemler aracılığıyla yapılacağı düşünülürse maliyeti ve işlem yükünü azaltmak son derece önemlidir. Bu çalışmada, bu ve benzeri EMG hareketlerinin etkin bir biçimde sınıflandırılması için karmaşık olmayan ve kolay bir biçimde uygulanabilecek sınıflandırıcı ve öznelik çıkarma kombinasyonunun nasıl elde edileceği üzerinde durulmaktadır. Bunun yanında önerilen yöntem FOH'un bir veri setine nasıl uygulandığı gösterilmiştir.

Bu çalışma dört ana kısımda ele alınmıştır. Birinci kısım giriş bölümüdür. İkinci kısım olan metod kısmında çalışmada önerilen yöntemle karşılaştırılan öznelik çıkarma yöntemleri ele alınmıştır. Üçüncü kısımda deneysel sonuçlar sunulmuş ve tartışılmıştır. Son kısımda ise sonuç bölümü yer almaktadır.

EMG SİNYALLERİ İÇİN HİBRİD ÖZİNİTELİK ÇIKARMA YÖNTEMİ GELİŞTİRİLMESİ**Şekil 1.** EMG sinyal işleme temel adımları**2. METOT**


Efektif bir EMG sınıflandırıcısı tasarlamak için dikkatli bir biçimde yapılması gereken üç aşama vardır. Bu aşamalardan ilki önileme aşamasıdır. Önileme aşamasında öncelikle ham sinyalde bulunan gürültüler filtrelendir. Sonrasında filtrelenen sinyallere pencereleme işlemi uygulanarak sinyal daha küçük parçalara ayrılır [13,14]. İkinci aşama öznitelik çıkarma aşamasıdır. Bu aşamada pencerelenen sinyallerden öznitelikler çıkarılır. Bu öznitelikler ilgili sinyal parçasını en iyi biçimde temsil etmek amacıyla çıkarılır. Üçüncü aşamada ise çıkarılan bu öznitelikler ve bu özniteliklere ait sınıflar uygun bir sınıflandırıcı ile sınıflandırılır. Sonuç olarak ham EMG sinyalinden hangi parmak hareketinin yapıldığı tespit edilir. Bu üç aşamanın blok diyagramı Şekil 1’de görülmektedir.

2.1. Veri Seti

Çalışmada kullanılan veri seti Khushaba ve ark [9, 20] tarafından güvenli sürüş amacıyla oluşturulmuştur. Otomobil kullanırken çoğu sürücünün, müzik çaları kontrol etmek, arabanın pencerelerini açmak, telefona cevap vermek gibi temel işleri yaparken dikkati kolayca dağılabilmektedir. Bu amaçla basit parmak hareketleri yardımıyla yukarıda sayılan temel işler yapılabilir. Ancak bu basit parmak hareketlerini birbirinden ayırmak karmaşık bir problemdir. Bu problemi aşmak için sürücünün sağ koluna bağlanan 8 kanallı olan EMG kayıt edici ile sürücünün Şekil 2’de görülen 14 farklı parmak hareketini gerçekleştirirken EMG sinyalleri kayıt edilmiştir [9]. Şekil 2 orijinal haline [9] benzer bir biçimde tekrar çizilmiştir. Daha öncede bahsedildiği gibi bu çalışmada koldan kayıt edilen EMG sinyallerinden çeşitli parmak hareketleri sınıflandırılmıştır. Sınıflandırma işleminin etkin bir biçimde yapılmasıyla sürücü direksiyondan elini çekmeden sadece basit parmak hareketiyle temel işleri yapabilecektir. Örnekleme frekansı 4 kHz olan yaklaşık 10 saniyelik kayıtlardan oluşan 8 kanallı EMG sinyalleri 8 sağlıklı kişiden alınmıştır [9, 20].

2.2. Önileme

Önileme aşaması filtreleme ve pencereleme olmak üzere iki bölümden oluşur. İlk aşamada ham EMG sinyalleri gürültüden arındırılır. EMG sinyalleri kayıt edilirken sinyal, sıcaklık, kişinin hareketleri, vücudun farklı kısımlarından kaynaklanan istenmeyen gürültü, şebeke gürültüsü vb. gibi birçok gürültü karışır. EMG sinyallerinde anlamlı bilgi 20-450 Hz aralığında yer alır [9,13,20]. Sinyal bu aralıktaki bilgilerin korunması şartıyla bant geçiren bir filtre tasarlanarak gürültüden arındırılmıştır. Sinyal 5. dereceden Butterworth filtre kullanılarak gürültüden arındırılmıştır.


**Şekil 2.** 14 Farklı Parmak Hareketi Gösterimi

A.CALISKAN

Önişlem aşamasının bir başka kısmı ise pencerelemedir. Bu aşamada EMG sinyalleri durağan olduğu varsayılan 128 ms'lik parçalara ayrılır. Şekil 3 de görüldüğü üzere sarı olan kısım sinyal üzerinde 25ms'lik zaman dilimleriyle kaydırılır [9]. Her bir kaydırma işleminde ilgili kısım (sarı) alınır. Daha sonra bu kısımlardan öznitelikler çıkarılır.

2.3. Öznitelik Çıkarma

Etkili bir biçimde öznitelik çıkarma sinyalin yüksek doğruluk oranıyla sınıflandırılması için son derece önemlidir. Bu aşamada pencerelenen sinyal parçalarından çeşitli öznitelikler çıkarılır. Normalde 128 ms'lik bir sinyal parçasında sinyalin 4000 Hz ile örneklendiği göz önüne alınırsa örnek sayısı 512 olacaktır. Sinyal 8 kanallı olduğu için bu sayı 8 ile çarpılır. Sonuç olarak tek bir sinyal parçasından 4096 örnek elde edilir. Bu örnekleri doğrudan sınıflandırıcıya göndermek mümkündür. Ancak giriş sayısının bu kadar çok olması sınıflandırıcının karmaşıklığının ve işlem yükünün artmasına sebep olur. Bunun yanında bu kadar çok girişle baş edebilecek sınıflandırıcı sayısı son derece azdır. Ayrıca bu kadar çok öznitelikle/girişle yapılan sınıflandırma işleminin eğitimi bir hayli uzun sürer. Bu sebeple etkili ve hızlı bir sınıflandırma yapabilmek için sinyalden öznitelik çıkarmak gereklidir [1]. Öznitelik adın da anlaşılacağı üzere ilgili sinyali en iyi biçimde temsil edebilen sayısal bilgidir. Literatürde EMG sinyallerinden öznitelik çıkarmak için önerilen birçok öznitelik çıkarma yöntemi vardır [13-17]. Bu çalışmada hızlı ve kolay uygulanabilir oldukları için aşağı verilen öznitelik çıkarma yöntemleri üzerinde durulmuştur.



Şekil 3. Pencereleme işlemi

2.3.1 Zaman tabanlı öznitelik çıkarma yöntemleri

- Mutlak ortalama (MO)

EMG SİNYALLERİ İÇİN HİBRİD ÖZNETELİK ÇIKARMA YÖNTEMİ GELİŞTİRİLMESİ

EMG sinyalinin mutlak değerinin ortalaması alınarak elde edilir. Son derece basit olmasına rağmen önemli bir öznetelik çıkarma tekniğidir. s_k ($k = 1, 2, \dots, N$) N adet örneğe sahip EMG sinyalini temsil etmek üzere MO aşağıdaki gibi tanımlanır [4,14].

$$MO = \frac{1}{N} \sum_{k=1}^N |s_k| \quad 1$$

- Sıfır eksen geçişi (SEG)

EMG sinyalinin x eksinini kaç kere kestiğini ifade eder [4]. Bir başka ifadeyle sinyalin kaç kere işaret değiştirdiğinin sayıdır. s_k ve s_{k+1} arka arkaya gelen iki EMG sinyali örneği olmak üzere

$$f(x) = \begin{cases} 1 & \text{eğer } (s_k > 0 \text{ ve } s_{k+1} < 0) \text{ yada } (s_k < 0 \text{ ve } s_{k+1} > 0) \\ 0 & \text{bunun dışında} \end{cases} \quad 2.a$$

burada $k = 1, 2, \dots, N - 1$ olmak üzere *SEG* aşağıdaki gibi tanımlanır.

$$SEG = \sum f(x) \quad 2.b$$

- İki örneklemin farkı (IOF)

IOF arka arkaya gelen iki sinyal örneğinin mutlak farklarının toplamıdır [4]. Aşağıdaki denklemde olduğu gibi tanımlanır. s_k ve s_{k+1} arka arkaya gelen iki EMG sinyali örneği ve $k = 1, 2, \dots, N - 1$ olmak üzere

$$IOF = \sum_{k=1}^{N-1} |s_k - s_{k+1}| \quad 3$$

- Willison Genliği (WG)

Arka arkaya gelen iki örnek arasındaki fark belirlenen bir eşik değerinden daha büyükse bu durum hesaba katılır [4]. Eğer daha küçükse önemsenmez. *WG*, *IOF*'ye çok benzemekle birlikte aşağıdaki gibi tanımlanır.

$$f(x) = \begin{cases} 1 & \text{eğer } s_k > \text{Eşik değeri} \\ 0 & \text{bunun dışında} \end{cases} \quad 4.a$$

olmak üzere

$$WG = \sum_{k=1}^{N-1} f(|s_k - s_{k+1}|) \quad 4.b$$

2.3.2. Histogram tabanlı öznetelik çıkarma yöntemleri

Histogram sinyalin içerisinde bulunan verilerin nasıl bir dağılıma sahip olduğunu gösterir. Histogram tabanlı öznetelikleri çıkarmak için öncelikle sinyalin histogramı elde edilir. Histogram elde edildikten sonra istenilen öznetelikler çıkarılır. X , histogramdan elde edilen rassal değişkeni göstermek üzere. Aşağıdaki denklemlerde x rassal değişkene ait bir örneği, μ rassal değişkenin ortalamasını ve σ rassal değişkenin varyansını göstermek üzere çarpıklık, basıklık ve standart sapma aşağıdaki gibi hesaplanır [4].

A.CALISKAN

- Çarpıklık (HC)

$$HC = \frac{E[(x - \mu)^3]}{\sigma^3} \quad 5.a$$

- Basıklık (HB)

$$HB = \frac{E[(x - \mu)^4]}{\sigma^4} \quad 5.b$$

- Standart sapma (HSP)

$$HB = \sqrt{\sigma} \quad 5.c$$

2.3.3. Önerilen Öznitelik Çıkarma Yöntemi

Önerilen yöntem yukarıda anlatılan MO ve IOF tabanlı yöntemlerinin hibritleştirilmesine dayanmaktadır. Yöntem fark ve ortalamanın hibritleştirilmesi (FOH) adıyla anılmaktadır. Aşağıda yer alan denklemlerle yöntemin matematiksel olarak tanımı ayrıntılı biçimde yapılmıştır.

Her bir kanaldan çıkarılan MO öznitelikleri her bir kanal bir sütuna gelecek şekilde yerleştirilerek X_{mo} matrisi elde edilir. n pencere sayısını, k ise kanal sayısını göstermek üzere MO özniteliklerini tutan X_{mo} matrisi aşağıdaki denklemde olduğu gibi tanımlanır.

$$X_{mo} = [mo_1 \ mo_2 \ mo_3 \ \dots \ mo_k] \quad 6.a$$

Burada yer alan mo_1, mo_2, \dots, mo_k vektörleri aşağıdaki gibi tanımlanır.

$$mo_k = [mo_{k1} \ mo_{k2} \ mo_{k3} \ \dots \ mo_{kn}]^T \quad 6.b$$

mo_{kn} her bir pencereden çıkarılan özniteliği göstermektedir. Bu problemde $k=8$ ve $n=176960$ 'dır.

MO özniteliklerinde olduğu gibi IOF öznitelikleri de aynı şekilde aşağıdaki gibi yapılandırılarak IOF özniteliklerini tutan X_{iof} matrisi aşağıdaki denklemlerde olduğu gibi tanımlanır.

$$X_{iof} = [iof_1 \ iof_2 \ iof_3 \ \dots \ iof_k] \quad 6.c$$

Burada yer alan $iof_1, iof_2, \dots, iof_k$ vektörleri aşağıdaki gibi tanımlanır.

$$iof_k = [iof_{k1} \ iof_{k2} \ iof_{k3} \ \dots \ iof_{kn}]^T \quad 6.d$$

iof_{kn} her bir pencereden çıkarılan öznitelik değerini göstermektedir. Burada yer alan $k=8$ ve $n=176960$ 'dır.

Yukarıda elde edilen X_{mo}, X_{iof} matrislerinde yer alan sütunların veri dağılımları birbirlerine yakın olması için her bir matrisin sütunları aşağıdaki denklemle normalize edilerek Z_{mo}, Z_{iof} matrisleri elde edilir.

$$z = \frac{x - \mu}{\sigma} \quad 7$$

Burada x, μ ve σ sırasıyla X rassal değişkenine ait bir örneği, X rassal değişkeninin ortalamasını, X rassal değişkeninin standart sapmasını gösterir. z ise x örneğinin yeni değerini gösterir. Bu işlem X_{mo} ve

EMG SİNYALLERİ İÇİN HİBRİD ÖZNETELİK ÇIKARMA YÖNTEMİ GELİŞTİRİLMESİ

X_{iof} matrislerinin her bir sütununa uygulanarak matrisin her bir sütunun ortalaması 0 standart sapması 1 olacak şekilde normalize edilir. Verinin şekli ve diğer istatistiksel özellikleri kesinlikle değiştirilmez.

Normalize edilen Z_{mo} ve Z_{iof} matrisleri aşağıdaki denklemlerle hibritleştirilerek Z_{foh} matrisi elde edilir.

$$Z_{foh} = \alpha Z_{mo} + (1 - \alpha) Z_{iof} \quad 8$$

Burada yer alan $\alpha \in [0 1]$ dengeleme parametresidir. Bu parametre bilindiği kadarıyla literatüre ilk defa sunulmuştur. Dengeleme parametresi Z_{mo} ve Z_{iof} öznelik matrislerinin Z_{foh} yeni öznelik matrisine ne oranda etki edeceğinin belirlenmesinde kullanılır. Dengeleme parametresi bire yaklaştığında Z_{foh} Z_{mo} 'ya yakınsarken dengeleme parametresi sıfıra yaklaşırsa Z_{foh} Z_{iof} 'ya yakınsar. Önerilen yöntemin performansı dengeleme parametresine doğrudan bağlıdır.

2.4. Sınıflandırma

Karmaşık sınıflandırma problemlerini çözmek için kullanışlı ve pratik bir tekniğe ihtiyaç vardır. Bir önceki aşamada elde edilen öznelikler bu aşamada sınıflandırıcıya giriş olarak verilir. Oluşturulan veri setinde 176960 örnek, 14 sınıf ve maksimum 56 öznelik ($kanal\ sayısı \times öznelik = 8 \times 7$) bulunmaktadır. Veri kümesinin girişi aşağıdaki gibi yapılandırılmıştır:

$$X = [x_1 \ x_2 \ x_3 \ \dots \ x_n] \quad 9.a$$

burada $x_1, x_2, x_3 \dots x_n$ m boyutlu öznelik vektörlerini gösterir. Bu problem için $n = 56, m = 176960$ 'dır. y_i 1 ve 14 aralığında yer alan tüm tamsayıları almak üzere veri setinin çıkışı ise aşağıdaki gibi verilmiştir.

$$y = [y_1 \ y_2 \ y_3 \ \dots \ y_m]^T \quad 9.b$$

Sınıflandırma işleminde veri seti genellikle eğitim $\{X_e, y_e\}$ ve test $\{X_t, y_t\}$ olmak üzere iki gruba ayrılır. Gerek eğitim seti gerekse test seti Eşitlik 9.a ve 9.b de tanımlandığı gibi ayarlanır. Bir veri setinin sınıflandırılması, sınıflandırıcı modeli ile yapılır. Modelin iç parametreleri öyle bir ayarlanır ki modelin giriş ile çıkış arasındaki ilişkiyi en iyi şekilde öğrenmesi sağlanır.

2.4.1. K-en yakın komşu algoritması

Önerilen yöntemin sınıflandırma performansı KNN algoritmasıyla test edilmiştir. Literatürde birçok sınıflandırma algoritması değişik amaçlar için kullanılmaktadır [18,19]. Ancak çalışmamızın amacı yeni bir öznelik çıkarma yöntemi önermek olduğu için sınıflandırma algoritmalarından bu amaca en uygun olanı seçilmiştir. Çünkü gerek literatürden gerekse yapılan simülasyonlardan KNN algoritmasının EMG sinyallerinin sınıflandırılması için kullanılabilmesi görülmektedir.

Bir önceki adımda elde edilen öznelikler ve bu özneliklere ait etiketler KNN algoritmasıyla sınıflandırılmıştır. Bu algoritma basit ve hızlı olması sebebiyle birçok sınıflandırma probleminin çözümünde kullanılmaktadır. Sınıfları belli olan bir grup veri seti kullanılarak sınıfı belli olmayan bir örneğin hangi sınıfa ait olduğuna karar verilerek sınıflandırma işlemi gerçekleştirilir. Örnek verecek olursak eğitim verisine yeni bir örnek dahil edildiğinde bunun hangi sınıfa ait olacağına şu şekilde karar verilir. Eğer yeni gelen örneğin k adet en yakın komşusu aynı grubun elemanı ise yeni gelen örnek de o gruba dahil olur [21].

3. BULGULAR VE TARTIŞMA

Bu çalışmada 14 farklı parmak hareketinin etkin bir şekilde sınıflandırılması için yeni bir öznelik çıkarma yöntemi önerilmiştir. Bu parmak hareketleri Şekil 2 'de görülmektedir. Önerilen yöntemin geçerliliği, 9 farklı öznelik çıkarma yöntemiyle kıyaslanarak istatistiksel olarak doğrulanmıştır. Önerilen yöntem ve tüm öznelik çıkarma yöntemlerinin performansı KNN algoritmasıyla test edilmiştir. Yapılan deneysel çalışmalarda ve ön

A.CALISKAN

simülasyonlarda KNN algoritmasının diğer sınıflandırıcılardan daha iyi bir performansa sahip olduğu görülmüştür. Bu sebeple sınıflandırıcı olarak KNN algoritması kullanılmıştır.

Önerilen yöntemin etkinliğini göstermek için EMG sinyalleri sınıflandırılırken 10 kat çapraz doğrulama [22] tekniği kullanılmıştır. Bu yöntemde veri seti 10 eşit parçaya bölünür. Bu parçalardan birisi test verisi olarak, geri kalan parçalar ise birleştirilerek eğitim verisi olarak kullanılır. Bir parça test edildikten sonra elde edilen sınıflandırma performansı kaydedilir. Sonra ilkinden farklı olan 10 adet parçadan bir diğeri test verisi olarak, geri kalan parçalar birleştirilerek eğitim verisi olarak kullanılır. Bu yeni parçanın sınıflandırma performansı da ilk parçada olduğu gibi kaydedilir. Bu işlem, her bir parça bir kez test verisi olarak kullanılına kadar 10 kere tekrar edilir. Elde edilen 10 adet test sonucunun ortalaması hesaplanarak sınıflandırıcının performansı ölçülür. 10 kat çapraz doğrulama tekniği, verinin dağılımından kaynaklanabilecek avantaj ya da dezavantajların ortadan kaldırılmasında kullanılan son derece objektif bir şekilde sınıflandırıcının performansının ortaya koyulmasını sağlar. Öte yandan her bir simülasyon 50 kere tekrar edilerek tüm yöntemlerin performansı objektif bir biçimde ortaya konmuştur. Böylece her bir yöntem 500 kere çalıştırılmış olur.

Bu çalışmada gerçekleştirilen söz konusu simülasyonlar aşağıdaki gibi planlanmıştır.

- i. Her bir öznitelik çıkarma yöntemi MO, SEG, IOF, WG, HC, HB ve HSP ayrı ayrı ele alınarak gerçekleştirilmiştir.
- ii. Zaman tabanlı ZT öznitelik çıkarma yöntemleri MO, SEG, IOF ve WG gruplandırılarak gerçekleştirilmiştir.
- iii. Histogram tabanlı HT öznitelik çıkarma yöntemleri HC, HB ve HSP gruplandırılarak gerçekleştirilmiştir.
- iv. Önerilen yöntem FOH kullanılarak gerçekleştirilmiştir.

Çalışmada, MO, SEG, IOF, WG, HC, HB, HSP, ZT, HT ve FOH gibi 10 farklı öznitelik çıkarma yönteminin başarımı test edilmiştir. Tablo 1'de 50 kere 10 kat çapraz doğrulama tekniğiyle KNN sınıflandırma algoritması kullanılarak yapılan simülasyonların ortalama, maksimum, minimum ve standart sapma değerleri görülmektedir. Histogram tabanlı öznitelik çıkarma yöntemleriyle kıyaslandığında zaman tabanlı öznitelik çıkarma yöntemlerinin daha iyi olduğu tablodan açıkça görülmektedir. Zaman tabanlı öznitelik çıkarma yöntemlerinden en iyi olanının IOF olduğu görülürken, SEG en kötü performansa sahiptir. Tablodan zaman tabanlı özniteliklerin tamamı bir arada kullanıldığında performansta düşüş olduğu gözlenirken histogram tabanlı öznitelik çıkarma yöntemleri bir arada kullanıldığında sonuçlarda iyileşme olduğu göze çarpmaktadır. Ancak önerilen yöntemle gerek zaman tabanlı yöntemlerden gerekse histogram tabanlı öznitelik çıkarma yöntemlerinden daha iyi sonuç alındığı açıkça görülmektedir. Ortalama, maksimum minimum doğruluk değerlerinin tamamında önerilen yöntemin daha bir performansa sahip olduğu açıkça görülmektedir. Bunun yanında önerilen yöntemin en düşük standart sapma değerine sahip olduğu görülmektedir. Bu yöntemin diğer yöntemlerden daha tutarlı ve kararlı sonuçlar ürettiğinin en büyük göstergesidir.

Tablo 1. Önerilen yöntemin (FOH) sınıflandırma performansının diğer öznitelik çıkarma yöntemlerinin sınıflandırma performanslarıyla kıyaslanması

	FOH	IOF	MO	ZT	WG	SEG	HT	HSP	HC	HB
Ortalama	97,43	97,22	96,25	95,62	82,46	34,82	31,82	23,74	17,68	13,32
Maksimum	97,48	97,27	96,33	95,75	82,68	35,06	32,07	23,97	18,14	13,76
Minimum	97,40	97,17	96,18	95,52	82,23	34,53	31,51	23,46	17,33	12,87
Standart Sapma	0,02	0,03	0,03	0,04	0,10	0,15	0,13	0,14	0,19	0,19

Daha önce belirtildiği gibi önerilen yöntemin performansı dengeleme parametresine doğrudan bağlıdır. Bu sebeple önerilen öznitelik çıkarma yönteminin dengeleme parametresi doğru biçimde seçilmelidir. Tablo 1'de FOH ile elde edilen sınıflandırma başarımlarında dengeleme parametresi 0,37 alınmıştır. Çalışmanın bu bölümünde neden 0,37 alındığı açıklanmıştır. Maalesef dengeleme parametresinin değerini belirlemenin analitik bir yolu yoktur. Bu sebeple bu parametre deneysel ve sezgisel olarak seçilir. Dengeleme parametresinin değerini belirlemek için önerilen öznitelik çıkarma yöntemiyle 10 kat çapraz doğrulama tekniği kullanılarak EMG sinyalleri sınıflandırılmıştır. Bu amaç için değerleri 0 ile 1 arasında 0,01 artırılarak değiştirilen her bir dengeleme parametresi için simülasyon 50 kere tekrar edilmiştir. Şekil 4'de değişen dengeleme parametresinin değişimine karşın ortalama, maksimum ve minimum doğruluk yüzdeleri görülmektedir. Yapılan simülasyonlara göre dengeleme parametresi $\alpha = 0.37$ olduğunda en iyi sonuçlar elde edilmiştir. Genel olarak $\alpha = 0.25 - 0.4$ aralığında sınıflandırma başarımı belirgin bir biçimde artarken $\alpha = 0.37$ de maksimum seviyeye ulaşmaktadır. Öte yandan α değeri bire yani MO'ya yaklaştığında performansın düştüğü gözlenmektedir. Şekil 4'ten alınan sonuçlara bakıldığında önerilen yöntem bölümünde bahsedilen teorik yorumlarla uyum olduğu net bir biçimde görülmektedir.

EMG SİNYALLERİ İÇİN HİBRİD ÖZNETELİK ÇIKARMA YÖNTEMİ GELİŞTİRİLMESİ


Elde edilen sonuçlar başka bir açıdan değerlendirildiğinde $\alpha = 0$ olduğunda Şekil 4’de görülen önerilen yöntem FOH’un doğruluk yüzdesi Tablo 1 de görülen IOF’nin doğruluk yüzdesiyle neredeyse aynıdır. Öte yandan $\alpha = 1$ olduğunda Şekil 4’de görülen FOH’un doğruluk yüzdesi yine Tablo 1’de görülen MO’nun doğruluk yüzdesiyle neredeyse aynı olmaktadır. Bu sonuçlara göre FOH’da kullanılan dengeleme parametresi, MO ve IOF’nin sınıflandırma performansını arttırmaktadır. Öte yandan FOH bu iki öznetelik çıkarma yöntemini de kapsamaktadır.

Tablo 2. Önerilen yöntemin diğer öznetelik çıkarma yöntemlerinin hızlarıyla kıyaslanması

Yöntem	MO	SEG	IOF	WG	HC	HB	HSP	FOH
Zaman (s)	1,10	1,34	0,73	0,76	12,70	12,71	6,68	1.80

Önerilen yöntemin diğer öznetelik çıkarma yöntemlerinin hızlarıyla kıyaslanması Tablo 2’de verilmiştir. Tablo 2’deki süreler, bir kişi için ne kadar sürede öznetelik çıkarıldığını göstermektedir. Bu tabloya göre IOF 0,73 saniye ile en hızlı yöntem olarak belirlenmiştir. Tablodan zaman tabanlı öznetelik çıkarma yöntemlerinin histogram tabanlı öznetelik çıkarma yöntemlerinden daha iyi olduğu açıkça görülmektedir. Bunun yanında önerilen yöntem az bir farkla zaman tabanlı yöntemlerden daha yavaştır. Ancak bu fark önemsenmeyecek kadar az bir farktır.

Önerilen yöntemin çalışma hızı göz önünde bulundurularak, gerçek zamanlı bir sistemde efektif bir biçimde kullanılma potansiyeli son derece yüksektir. Çünkü önerilen yöntem kullanılarak 22120 adet örnekten oluşan 10 saniye (s)’lik bir kayıttan yaklaşık 6.68 s’de öznetelik çıkarma işlemi gerçekleştirilmektedir. Basit bir hesaplama yapıldığında her bir örnekten öznetelik çıkarılma süresi = $6.68 \text{ s} / 22120 \text{ örnek} = 284 \mu\text{s}/\text{örnek}$ olarak hesaplanır. Özetle bir kas hareketinden öznetelik çıkarma süresi mikro saniyeler seviyesindedir. Dolayısıyla önerilen yöntem



Şekil 4. Önerilen yöntemin dengeleme parametresinin değişimine göre doğruluk yüzdeleri

gerçek zamanlı bir sistemde etkin bir biçimde kullanılabilir. Bu veri seti, parmak hareketleriyle araç içerisindeki sürücünün dikkatinin dağılmadan birtakım işleri kolaylıkla yapabilmesi amacıyla toplanmıştır. Dolayısıyla öznetelik çıkarma yönteminin son derece hızlı olması gerekmektedir. Önerilen yöntemin yeterince hızlı olduğu deneysel sonuçlardan görülmektedir. Bunun yanında gerek yüksek doğruluk oranlarına sahip olması gerekse hızlı olması önerilen yöntemin gerçek zamanlı farklı uygulamalarda da güvenle kullanılabileceğinin en büyük göstergesidir.

Öte yandan önerilen öznetelik çıkarma yönteminin performansı Şekil 5’te görülen hata matrisi ile daha ayrıntılı bir biçimde incelenebilir. Hata matrisinden de görüleceği üzere, neredeyse tüm el hareketleri yüksek doğruluk oranlarıyla sınıflandırılmıştır. Diğer hareketlerin sınıflandırma performansı ile kıyaslandığında sadece orta ve baş parmak kombinasyonunun sınıflandırma başarımı diğer hareketlerin sınıflandırma başarımından daha düşüktür. Uygulamalarda bu hareketler yerine farklı parmak kombinasyonları denenmesi daha iyi bir yaklaşım olabilir.

A.CALISKAN

Önerilen yöntem literatürde bu veri setinin kullanıldığı diğer sınıflandırıcılarla kıyaslanmıştır. Yapılan kıyaslama Tablo 3'te özetlenmiştir. Önerilen yöntemin diğer yöntemlerden daha iyi olduğu Tablo 3'ten açıkça görülmektedir.

Tablo 3. Önerilen yöntemin sınıflandırma performansının literatürde yer alan farklı sınıflandırıcılarla kıyaslanması

Yöntem	Doğruluk
HOF-KNN	97,48
LIBSVM [9]	94,90
NavieBayes [9]	94,00
LDA [9]	93,60
RegTree [9]	89,50

Önerilen yöntemin sınıflandırma performansının ne kadar iyi olduğu doğruluk oranlarından anlaşılabilir. Ancak elde edilen bulgular daha sağlam ve objektif yöntemlerle desteklenmediği sürece hangi yöntemin daha iyi olduğuna karar vermek mümkün değildir. Tablo 1'den FOH'un diğer öznitelik çıkarma yöntemlerinden daha iyi olduğu açık şekilde görülmektedir. Ancak FOH ile IOF ve MO arasında doğruluk yüzdeleri açısından çok büyük bir farklılık yoktur. Bu farkın FOH'un bu iki yöntemden daha iyi olduğunu gösterip göstermediğine ancak istatistiksel analiz yapıldıktan sonra karar verilebilir. FOH, IOF ve MO üzerine kurgulanan bir yöntem olduğundan bu iki yöntemi istatistiksel olarak kıyaslamak için Wilcoxon işaretli sıra testi kullanılmıştır [23]. Tablo 4'de verilen sonuçlar incelendiğinde FOH lehine istatistiksel olarak anlamlı bir farklılık gözlenmektedir. Benzer biçimde FOH ile SEG, WG, HC, HB, HSP, ZT ve HT öznitelik çıkarma yöntemleri arasında FOH lehine anlamlı bir farklılık olduğu Tablo 5'ten görülmektedir. Bu karşılaştırmada yöntemler birbirlerinden tamamıyla bağımsız olduğundan Mann Whitney testi kullanılmıştır.

Tablo 4. Wilcoxon işaretli sıra testiyle önerilen yöntem (FOH) ile IOF ve MO'nin istatistiksel olarak kıyaslanması

Karşılaştırma	Z	p	Anlamlılık (p<0.05)
FOH-IOF	-6.1667	0.0000	FOH
FOH-MO	-6.1604	0.0000	FOH

Tablo 5. Mann Whitney testiyle önerilen yöntem (FOH) ile SEG, WG, HC, HB, HSP, ZT ve HT'nin istatistiksel olarak kıyaslanması

Karşılaştırma	Z	p	Anlamlılık (p<0.05)
FOH-SEG	-8.6454	0.0000	FOH
FOH-WG	-8.6419	0.0000	FOH
FOH-HC	-8.6413	0.0000	FOH
FOH-HB	-8.6412	0.0000	FOH
FOH-HSP	-8.6413	0.0000	FOH
FOH-ZT	-8.6410	0.0000	FOH
FOH-HT	-8.6412	0.0000	FOH

EMG SİNYALLERİ İÇİN HİBRİD ÖZNETELİK ÇIKARMA YÖNTEMİ GELİŞTİRİLMESİ

Hata Matrisi

Tahmin	Bas	99.8% 12612	0.0% 4	0.0% 0	0.0% 0	0.0% 1	0.0% 3	0.0% 0	0.0% 0	0.0% 4	0.1% 7	0.0% 1	0.1% 8	0.0% 0	0.0% 0
	Orta Bas	0.0% 0	91.6% 12265	0.1% 7	0.0% 3	0.4% 50	1.3% 164	0.1% 9	0.0% 4	0.0% 0	0.0% 0	0.6% 69	0.0% 0	0.6% 68	0.0% 1
	Yuzuk Bas	0.0% 0	0.2% 22	96.6% 12467	0.0% 2	0.0% 0	0.0% 6	0.3% 42	0.3% 39	0.1% 18	0.0% 0	0.0% 1	0.0% 0	0.0% 1	0.3% 42
	Serce Bas	0.0% 0	0.1% 7	0.1% 18	98.7% 12544	0.0% 2	0.1% 7	0.0% 3	0.1% 12	0.1% 9	0.3% 34	0.0% 1	0.0% 0	0.0% 1	0.0% 2
	Isaret Bas	0.1% 7	0.8% 102	0.0% 0	0.1% 12	97.4% 12301	0.1% 16	0.0% 0	0.0% 1	0.0% 0	0.0% 2	1.2% 149	0.1% 15	0.2% 30	0.0% 5
	Orta	0.0% 1	2.8% 374	0.2% 30	0.1% 16	0.2% 25	95.0% 11953	0.3% 35	0.0% 3	0.0% 5	0.0% 0	0.8% 99	0.0% 0	0.6% 75	0.2% 24
	Yuzuk Orta	0.0% 0	0.5% 66	1.2% 150	0.0% 6	0.0% 0	0.5% 58	98.6% 12327	0.0% 0	0.1% 12	0.0% 0	0.0% 2	0.1% 7	0.0% 6	0.0% 6
	Yuzuk	0.0% 1	0.1% 15	0.8% 106	0.3% 33	0.1% 9	0.0% 3	0.0% 5	97.9% 12297	1.0% 122	0.1% 9	0.0% 0	0.0% 0	0.0% 0	0.3% 40
	Serce Yuzuk	0.0% 0	0.0% 0	0.2% 29	0.1% 15	0.0% 0	0.1% 15	0.2% 19	1.1% 132	97.3% 12384	0.4% 44	0.0% 0	0.0% 0	0.0% 0	0.0% 2
	Serce	0.0% 6	0.0% 1	0.0% 2	0.6% 73	0.0% 4	0.0% 0	0.0% 0	0.1% 11	1.4% 172	99.2% 12371	0.0% 0	0.0% 0	0.0% 0	0.0% 0
	Isaret	0.0% 2	2.1% 276	0.0% 6	0.0% 3	1.4% 171	1.2% 153	0.0% 3	0.0% 4	0.0% 2	0.0% 0	96.3% 11917	0.0% 0	0.5% 57	0.4% 46
	Isaret Goster	0.1% 12	0.0% 0	0.0% 0	0.0% 1	0.0% 2	0.0% 0	0.2% 27	0.0% 0	0.0% 2	0.0% 0	0.0% 3	99.6% 12587	0.0% 0	0.0% 6
	Orta Isaret	0.0% 0	1.8% 247	0.0% 3	0.0% 1	0.4% 53	1.2% 156	0.1% 14	0.0% 0	0.0% 0	0.0% 0	0.7% 81	0.0% 0	98.1% 12085	0.0% 0
	IO Goster	0.0% 2	0.1% 13	0.7% 90	0.0% 5	0.0% 6	0.4% 47	0.2% 22	0.5% 59	0.0% 3	0.0% 0	0.4% 47	0.2% 19	0.0% 0	98.6% 12327
		Bas	Orta Bas	Yuzuk Bas	Serce Bas	Isaret Bas	Orta	Yuzuk Orta	Yuzuk	Serce Yuzuk	Serce	Isaret	Isaret Goster	Orta Isaret	IO Goster
	Gercek														

Şekil 5. Önerilen yöntemin hata matrisi

4. SONUÇLAR

Yapılan simülasyonlara göre EMG sinyallerinden parmak hareketlerinin sınıflandırılması probleminde gerek hız açısından gerekse doğruluk açısından zaman tabanlı öznetelik çıkarma yöntemlerinin önde oldukları görülmektedir. Hızlı oldukları ve yüksek doğruluk oranlarına sahip oldukları için bu ve benzeri problemler için iki önemli zaman tabanlı öznetelik çıkarma yöntemi MO ve IOF'nin hibritleştirilmesiyle yeni bir öznetelik çıkarma yöntemi FOH önerilmiştir. Önerilen öznetelik çıkarma yöntemi hem MO'dan hem de IOF'dan daha iyi sınıflandırma performansına sahiptir. Böylece EMG sinyallerinin sınıflandırılmasında hem doğruluk hem de hız açısından ön plana çıkan yeni bir öznetelik çıkarma yöntemi önerilmiştir. İstatistiksel analizlerle desteklenerek elde edilen sonuçlara göre önerilen yöntem gözle görünür bir biçimde sınıflandırma başarımlarını artırmaktadır.

Gelişen teknolojiyle birlikte EMG sinyallerinin kullanım alanı hızla artmaktadır. Dolayısıyla EMG sinyalleri gelecekte gerek sağlık sektöründe gerekse eğlence sektöründe yaygın biçimde kullanılacaktır. EMG sinyallerinin karmaşık ve gürültülü sinyaller olduğu göz önünde bulundurulursa yeni hızlı ve etkili öznetelik çıkarma ve sınıflandırma algoritmalarına şiddetle ihtiyaç vardır.

A.CALISKAN

TEŞEKKÜR

Veri setini toplamış ve bilimsel çalışmalar için kullanıma sunmuş olan seti Khushaba ve arkadaşlarına teşekkür ederim.

KAYNAKLAR

- [1] MENG, Q., ZHANG, J., YANG, X. "Virtual Rehabilitation Training System Based on Surface EMG Feature Extraction and Analysis". *Journal of Medical Systems*, 43, 48, 2019
- [2] ZENG, Y., YANG, J., PENG, C., YIN, Y. "Evolving Gaussian Process Autoregression Based Learning of Human Motion Intent Using Improved Energy Kernel Method of EMG", *IEEE Transactions on Biomedical Engineering*, 2019
- [3] ZHANG, X., CHEN, X., LI, Y., LANTZ, V., WANG, K., YANG, J., "A Framework for Hand Gesture Recognition Based on Accelerometer and EMG Sensors" *IEEE Transactions on Systems, Man, and Cybernetics-Part A: Systems and Humans*, 41, 1064-1076, 2011
- [4] SAPSANIS, C., GEORGOULAS, G., TZES, A. "EMG Based Classification of Basic Hand Movements Based on Time-Frequency Features", *21. Mediterranean Conference on Control and Automation*, 716-722, 2013.
- [5] QI, J., JIANG, G., LI, G., SUN, Y., TAO, B. "Surface EMG Hand Gesture Recognition System Based on PCA and GRNN", *Neural Computing and Applications*, 1-9, 2019
- [6] BAŞTÜRK, A., YÜKSEL, M. E., CALISKAN, A., BADEM, H., "Deep Neural Network Classifier for Hand Movement Prediction", *25. Signal Processing and Communications Applications Conference (SIU)*, 1-4.,2017
- [7] RAURALE, S., MCALLISTER, J., DEL RINCON, J. M., "EMG Wrist-hand Motion Recognition System for Real-time Embedded Platform", *arXiv preprint arXiv:1903.06764*, 2019
- [8] TENORE, F.V., RAMOS, A., FAHMY, A., ACHARYA, S., ETIENNE-CUMMINGS, R., THAKOR, N. V., "Decoding of Individuated Finger Movements Using Surface Electromyography", *IEEE Transactions on Biomedical Engineering*, 56, 1427-1434, 2009.
- [9] KHUSHABA, R. N., KODAGODA, S., LIU, D., DISSANAYAKE, G., "Muscle Computer Interfaces for Driver Distraction Reduction". *Computer Methods and Programs in Biomedicine*, 110, 137-149, 2013.
- [10] PHINYOMARK, A., N KHUSHABA, R., SCHEME, E., "Feature Extraction and Selection for Myoelectric Control Based on Wearable EMG Sensors", *Sensors*, 18, 1615-1632, 2018.
- [11] KATAOKA, H., SUGIE, K., "Recent Advancements in Lateral Trunk Flexion in Parkinson Disease", *Neurology: Clinical Practice*, 9, 74-82, 2019
- [12] CHAN, F. H., YANG, Y. S., LAM, F. K., ZHANG, Y. T., PARKER, P. A., "Fuzzy EMG Classification for Prosthesis Control", *IEEE Transactions on Rehabilitation Engineering*, 8, 305-311, 2000.
- [13] REAZ, M. B. I., HUSSAIN, M. S., MOHD-YASIN, F., "Techniques of EMG Signal Analysis: Detection, Processing, Classification And Applications", *Biological Procedures Online*, 8, 11, 2006
- [14] PHINYOMARK, A., PHUKPATTARANONT, P., LIMSAKUL, C., "Feature Reduction and Selection for EMG Signal Classification", *Expert Systems with Applications*, 39, 7420-7431
- [15] ZHANG, L., SHI, Y., WANG, W., CHU, Y., YUAN, X., "Real-time and user-independent Feature Classification of Forearm Using EMG signals", *Journal of the Society for Information Display*, 27, 101-107, 2019
- [16] AMERİ, A., AKHAE, M. A., SCHEME, E., ENGLEHART, K., "Regression Convolutional Neural Network for Improved Simultaneous EMG Control". *Journal of Neural Engineering*, 2019
- [17] TOO, J., ABDULLAH, A. R., MOHD SAAD, N., TEE, W., "EMG Feature Selection and Classification Using a Pbest-Guide Binary Particle Swarm Optimization", *Computation*, 7, 12, 2019
- [18] BAŞTÜRK, A., BAŞTÜRK, N. S., QURBANOV, O. , "A Comparative Performance Analysis Of Various Classifiers For Fingerprint Recognition", *Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi*, 7(2), 504-513, 2018.
- [19] CALISKAN A., BADEM H., BASTURK A., YUKSEL M. E., "Diagnosis Of The Parkinson Disease By Using Deep Neural Network Classifier." *Istanbul University-Journal of Electrical & Electronics Engineering*, 17(2), 3311-3319, 2017.
- [20] <https://www.rami-khushaba.com/electromyogram-emg-repository.html> (erişim tarihi 21.03.2019)
- [21] COVER T. HART P., "Nearest Neighbor Pattern Classification.," *IEEE Transactions On Information Theory*, 13(1), 21-27, 1967.

EMG SİNYALLERİ İÇİN HİBRİD ÖZNİTELİK ÇIKARMA YÖNTEMİ GELİŞTİRİLMESİ

- [22] HOSSIN M., SULAIMAN N., “A Review On Evaluation Metrics For Data Classification Evaluations”, International Journal of Data Mining & Knowledge Management Process, 5(2), 2015.
- [23] CALISKAN, A., YUKSEL, M. E., BADEM, H., BASTURK, “A. Performance Improvement of Deep Neural Network Classifiers by a Simple Training Strategy”, Engineering Applications of Artificial Intelligence, 67, 14-23, 2018.