



EMG Sinyalleri İçin Pencere Genişliğinin ve Kaydırma Miktarının Genetik Algoritmayla Belirlenmesi

Determination of Window Size and Sliding Interval for EMG Signals by Using Genetic Algorithm

Abdullah CALISKAN
Biyomedikal Mühendisliği
İskenderun Teknik Üniversitesi
Hatay, Türkiye
abdullah.caliskan@iste.edu.tr

Hasan BADEM
Bilgisayar Mühendisliği
Kahramanmaraş Sütçü İmam Üniversitesi
Kahramanmaraş, Türkiye
hbadem@ksu.edu.tr

Zeynel Abidin ÇİL
Endüstri Mühendisliği
İzmir Demokrasi Üniversitesi
İzmir, Türkiye
zabidin.cil@idu.edu.tr

Özetçe —Elektromiyografi (EMG) sinyalleri işlenirken karşılaşılan önemli bir sorulardan birisi pencere genişliğinin ve kaydırma miktarının seçimidir. Fakat, EMG sinyallerinin sınıflandırılmasında pencere genişliği ve kaydırma miktarını belirleyebilmek için sınırlı sayıda yöntem vardır. Bu çalışmada, EMG sinyallerinin sınıflandırılmasında pencere genişliği ve kaydırma miktarının Genetik Algoritma kullanılarak optimize edildiği yeni bir yöntem önerilmiştir. Bir EMG veri seti kullanılarak elde edilen deneysel sonuçlar, önerilen yöntemin, sınıflandırma doğruluğu açısından geleneksel sınıflandırıcının performansını geliştirdiğini göstermektedir.

Anahtar Kelimeler—Elektromiyografi, genetik algoritma, pencere genişliği, kaydırma miktarı.

Abstract—The selection of window size and sliding interval are one of the important problems encountered in Electromyography (EMG) signal processing. However, there exist a few methods to determine the window size and sliding interval for EMG signal classification problems. In this paper, a new method is proposed to optimize the window size and sliding interval for EMG signals by using Genetic Algorithm. Experimental results on a EMG data set show that the proposed method improve the performance of a traditional classifier in terms of classification accuracy.

Keywords—Electromyography, genetic algorithm, window size, sliding interval.

I. GİRİŞ

Elektromiyografi (EMG), sinir sistemi tarafından kontrol edilen ve kasılmayı sağlayan kaslardan elde edilen elektrik sinyalini ifade eder. Sinyal kasların anatomik ve fizyolojik özelliklerini temsil eder. Son yıllarda EMG sinyallerinden eğlence [1], [2], sağlık [3], [4] ve rehabilitasyon [5] gibi alanlarda sıklıkla faydalanılmaktadır. Bundan dolayı EMG sinyalleri üzerinde yapılan araştırmalar her geçen gün artmaktadır. EMG sinyallerinin gerek gürültülü doğası gerekse çok kanallı olması bu sinyaller üzerinde çalışmayı bir hayli

zorlaştırmaktadır. Bu sebeple EMG sinyallerinin işlenmesi için bir çok teknik geliştirilmiştir.

Karmaşık yapısı gereği EMG sinyalleri temel olarak üç aşamada ele alınır [6], [7]. Bunlar önışlem, öznitelik çıkarma ve sınıflandırmadır. Önışlem aşaması sinyalin bir sonraki adımlara hazırlanmasını sürecini ifade eder. Öznitelik çıkarma adında anlaşılacağı üzere sinyali en iyi biçimde temsil eden bilginin elde edilme sürecidir [8], [9]. Sınıflandırma ise elde edilen öznitelikler ve bunlara ait etiketler kullanılarak uygun bir model ile eğitilmesi aşamasıdır [10]. Eğitilen model girişine verilen özniteliklerin hangi sınıfa ait olduğunun belirlenmesinde kullanılır. Uğraşılan problem gözönüne alındığında, EMG sinyallerinden etkin bir biçimde faydalanabilmek için bu üç aşamanın birbirleriyle uyumlu olması gerekir. Dolayısıyla bu aşamaların hepsi ayrıca önemli olmakla birlikte önışlem aşaması işlemlerin ilk kısmı olduğundan sınıflandırma sonucunu radikal bir biçimde etkilemektedir.

Önışlem aşaması kendi içinde iki ana kısımdan oluşmaktadır. Bu aşamalardan ilki sinyalin şebeke, girişim, istenmeyen hasta hareketleri, elektronik cihazlardan kaynaklanan v.b gürültülerin tamamından arındırılmasıdır. Bu gürültü eliminasyon aşaması genellikle rutin birtakım işlemlerle ve bilinen filtreleme teknikleriyle aşılr. İkinci aşama is pencereleme işlemidir. Bu aşamada sinyal uygun pencere genişlikleriyle daha kısa parçalara ayrılır. Bu pencerelerin her biri toplam sinyali temsil eden en küçük birimlerdir. Dolayısıyla pencere genişliğinin nasıl seçilmesi gerektiği son derece önemlidir.

Pencere seçilirken iki önemli parametrenin belirlenmesi gerekir. Bunlardan ilki pencere genişliği, ikincisi ise pencerenin kaydırma miktarıdır. Bu iki parametre sıklıkla literatürde önerildiği şekilde seçilir [10]. Ancak uğraşılan problemin doğasına göre bu parametreler sınıflandırma başarımını doğrudan etkilemektedir. Dolayısıyla bu parametreler özenle seçilmelidir. Bu çalışmada pencere genişliği ve kaydırma miktarının sınıflandırma başarımı üzerindeki etkileri incelenecektir. Bunun yanında pencere

genişliği ve kaydırma miktarının optimum değerleri genetik algoritma kullanılarak belirlenmiştir. *EMG physical action* veri seti [11] üzerinde yapılan simülasyonlarla önerilen yöntem test edilmiştir. Önerilen yöntemin geçerliği En yakın komşu (k-nearest neighbors, KNN) algoritmasıyla aracılığıyla doğrulanmıştır.

Literatürde EMG sinyallerinin filtrelenmesi, özneteliklerinin çıkarılması [12] ve sınıflandırması [13] ile ilgili yapılmış bir çok çalışma olmasına rağmen pencere genişliğinin ve kaydırma miktarının seçimi ile ilgili diğer yöntemlere göre daha az sayıda çalışma vardır [10]. Bunun yanında bildiğimiz kadarıyla pencere genişliği ve kaydırma miktarının belirlenmesi için önerilen genetik algoritma tabanlı bir yaklaşım mevcut değildir.

Genetik algoritma optimize edilecek fonksiyonun türev bilgisini kullanmaya gerek kalmadan optimum noktanın bulunmasına imkan tanıyan en güvenilir yöntemlerden birisidir [14]–[16]. Bu çalışmada uğraşılan problemin doğası gereği türevi alınabilecek analitik bir amaç fonksiyonu elde etmek son derece güçtür. Dolayısıyla pencere genişliği ve kaydırma miktarını belirlemek için türeve dayalı olmayan optimizasyon algoritmalarının kullanılmasının uygun olacağı belirlenmiştir. Bu amaç için türevden bağımsız algoritmalarından en popüler olanlarından birisi genetik algoritma seçilmiştir.

Çalışmanın bundan sonraki kısmı şu şekilde organize edilmiştir. İkinci bölümde kullanılan veri setinden, önerilen yöntemden, öznetelik çıkarma ve sınıflandırmadan bahsedilmiştir. Üçüncü bölümde deneysel sonuçlar sunulmuştur. Son bölümde ise sonuç kısmı yer almaktadır.

II. YÖNTEM


EMG sinyallerini sınıflandırma işlemi, Şekil 1'de görüldüğü gibi üç temel aşamadan oluşmaktadır. Bunlar önileme, öznetelik çıkarma ve sınıflandırma aşamalarıdır. Önileme, fitreleme ve pencerleme olmak üzere iki kısımdır. Öznetelik çıkarma işleminde, pencerelenen sinyaller içerisinde boyutu ve problemin karmaşıklığını azaltmak için çeşitli öznetelikler çıkarılır. Bu öznetelikler ve bunlarla ilişkili olan etiketler daha önce belirlenen bir sınıflandırıcının iç parametrelerinin belirlenmesinde kullanılır.

A. Veri seti

Bu çalışmada kullanılan *EMG Physical Action* veri seti Theodoridis tarafından oluşturulmuştur [11]. Bu veri setiyle kolların ve bacakların çeşitli yerlerinden kayıt edilen EMG sinyalleri yardımıyla eğilme, alkış, el sıkışma, kucaklama, zıplama, koşma, oturma, ayakta durma, yürüme, el sallama dirseklemek, ön tekme, çivilme, kafa atma, diz atmak, çekme, yumruklama, itme, yan tekme ve tokatlama gibi 20 farklı fiziksel hareketin sınıflandırılması amaçlanmıştır. Tablo 1'de görüldüğü üzere bu hareketler normal ve agresif olmak üzere iki ayrı gruba ayrılmıştır.

EMG kayıtları, yoğun fiziksel deneyimi olan gönüllü üç erkek ve bir kadın denekten (25 ila 30 yaş arası) alınmıştır. Her denek on normal ve on agresif aktivite gerçekleştirmiştir. Kayıtlar örnekleme frekansı 1000 Hz olan 8 kanallı Delsys EMG cihazıyla her bir hareket yaklaşık olarak 10 sn boyunca sürecek şekilde kaydedilmiştir. Kayıtlar her iki kol ve ayaktan

almaz üzere biceps, triceps, quadricep, harnstring gibi büyük kas gruplarından kayıt edilmiştir.



Şekil 1: EMG sinyal işleme adımları

B. Önerilen yöntem

EMG sinyalleri saniyeler ve saatler arasında değişen uzunluklarda olabilen zaman serileridir. Bundan dolayı sinyal üzerinde işlem yapabilmek için sinyalin belli uzunlukta parçalara ayrılması gerekir. Bu uzunluk uğraşılan problemin doğasına göre değişebilmekle birlikte 250 ms civarındadır [10]. Ancak bu değer bir takım tecrübelerle belirlenmiştir. Verilen bir veri seti için en uygun pencere genişliğinin optimize edilmesi daha iyi sınıflandırma başarımlarına ulaşmayı sağlayabilir. Bunun yanında bu pencerinin sinyal üzerinde ne kadar kaydıracağı çözülmesi gereken başka bir problemidir. Bu değerde yaklaşık olarak 25 ms olarak belirlenmiştir [10]. Tıpkı pencere genişliğinde olduğu gibi kaydırma miktarı da dikkatli bir biçimde seçilmelidir. Önerilen model Şekil 2'de görülmektedir. Modelden elde edilen doğruluk oranıyla (*MDO*) ideal doğruluk oranı (*IDO* = 1) arasındaki farkın minimize edilmesi amaçlanmaktadır. Modelin iç parametreleri olan pencere genişliği (*p*) ve kaydırma miktarı (*k*) genetik algoritma kullanılarak öyle bir ayarlanacak ki aradaki farkın minimum olması sağlanacaktır.

$$Hata = IDO - MDO(p, k) \quad (1)$$

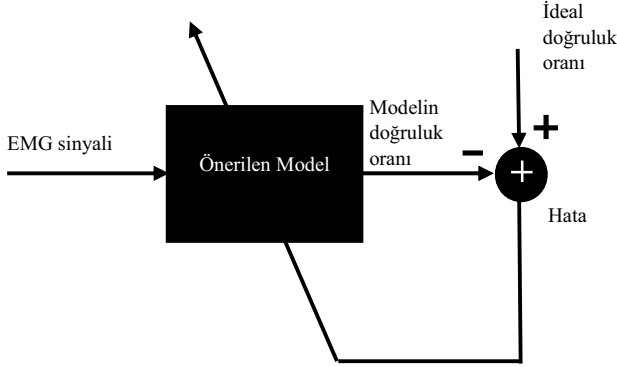
burada ideal değer maksimum olması gerektiği için *IDO* = 1 olarak alınmıştır. Hata genetik algoritma kullanılarak minimize edilmiştir. Genetik algoritma doğal seçim, çaprazlama ve mutasyon olmak üzere 3 operator kullanılarak amaç fonksiyonunun optimize edilmesinde kullanılır. Bu operatorler doğadan esinlenilerek Holland tarafından ortaya konmuştur [14]. Genetik algoritmanın işlem adımları Şekil 3'te verilmiştir. Öncelikle popülasyonda yer alan her bir çözüm adayını rasgele belirler. Daha sonra bu çözüm adaylarının kalitesi uygunluk değerlerinin hesaplanmasıyla belirlenir. Bu aşamada durdurma kriteri kontrol edilir. Durdurma kriteri genellikle maksimum iterasyon sayısıdır. Eğer uygunluk kriteri sağlanıyorsa optimizasyon işlemi sonlandırılır. Eğer kriter sağlanmıyorsa mevcut popülasyondaki en düşük uygunluk değerlerine sahip olan bir grup birey popülasyondan çıkarılır. Sonra kalan bireyler arasında çaprazlama yapılarak yeni bireyler elde edilerek yeni bir popülasyon oluşturulur. Bu yeni popülasyondaki bireyler mutasyona uğratılarak çeşitlilik sağlanır. Durdurma kriteri sağlanana kadar bu işlemlere devam edilir.

C. Öznetelik çıkarımı

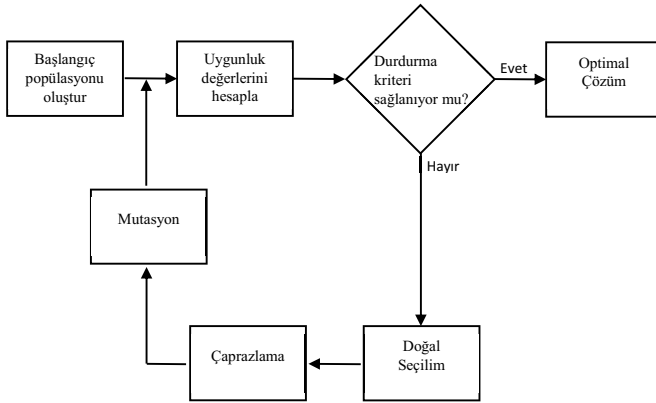
Sınıflandırma işleminden önce elde edilen sinyal parçasından öznetelik çıkarmak, EMG sinyallerinin sınıflandırıldığı bir çok modelde kullanılmaktadır. Sınıflandırma başarımının artması için etkili öznetelik çıkarma yöntemlerine ihtiyaç vardır. Çıkarılan öznetelikler veriyi ne kadar iyi temsil edebilirse sınıflandırma başarısı o kadar yüksek olur. Öznetelik çıkarmak

Tablo I: 20 farklı fiziksel hareket

Normal	Eğilme	Alkış	El sıkışma	Kucaklama	Zıplama	Koşma	Oturma	Ayakta durma	Yürüme	El sallama
Agresif	Dirsekleme	Ön tekme	Çivilme	Kafa atma	Diz atmak	Çekme	Yumruklama	İtme	Yan Tekme	Tokatlama



Şekil 2: Önerilen Model



Şekil 3: Genetik algoritma işlem adımları

için literatüre çok sayıda yöntem sunulmuştur [17]. Bu çalışmada aşağıda özetlenen öznelik çıkarma teknikleri kullanılmıştır [18].

- 1) *Entegre Elektromiyogram*: EMG sinyalinin mutlak değerlerinin ortalamasını ifade eder.
- 2) *Sıfır Eksen Geçişi*: EMG sinyalinin yatay eksen ne kadar geçtiğini ifade eder.
- 3) *Eğim İşaret Değişimi*: EMG sinyallerinde meydana gelen işaret değişikliği sayısıdır.
- 4) *Dalga Formu Uzunluğu*: İki EMG sinyal örneği arasındaki farkların ortalamasını ifade eder.
- 5) *Willison Genliği*: İki EMG sinyal örneği arasındaki belli bir değerin üzerindeki farkların ortalamasını ifade eder.
- 6) *Varyans*: EMG sinyal örneklerinden elde edilen olasılık yoğunluk fonksiyonunun varyansdır.

Tablo II: Önerilen yöntem ile klasik yaklaşımın karşılaştırması

	Ortalama	Maksimum	Minimum	Standart Sapma
Önerilen Yöntem	98.31	98.44	98.21	0.05
Klasik Yaklaşım	91.02	91.27	90.74	0.13

7) *Dağılımın Çarpıklığı*: EMG sinyal örneklerinden elde edilen olasılık yoğunluk fonksiyonunun çarpıklığını ifade eder.

8) *Dağılımın Savrukluğu*: EMG sinyal örneklerinden elde edilen olasılık yoğunluk fonksiyonunun savrukluğu ifade eder.

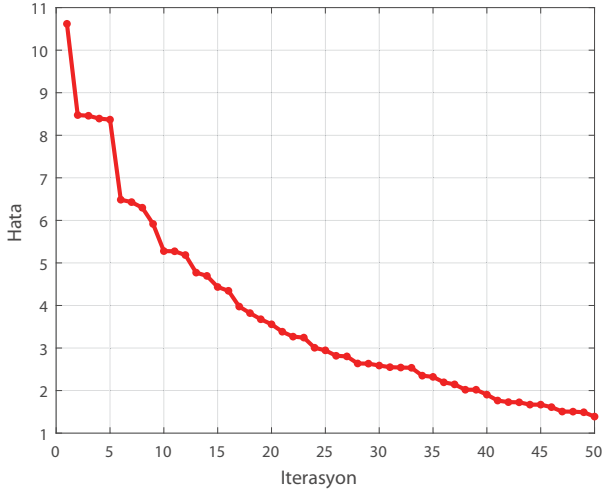
D. Sınıflandırma

Elde edilen öznelikler ve bu özneliklerle ilgili olan etiketler arasındaki ilişki uygun bir sınıflandırıcı kullanılarak belirlenir. Bu çalışmada gerek hız gerekse performans açısından en iyi sınıflandırıcılardan birisi olan KNN algoritması kullanılmıştır [19].

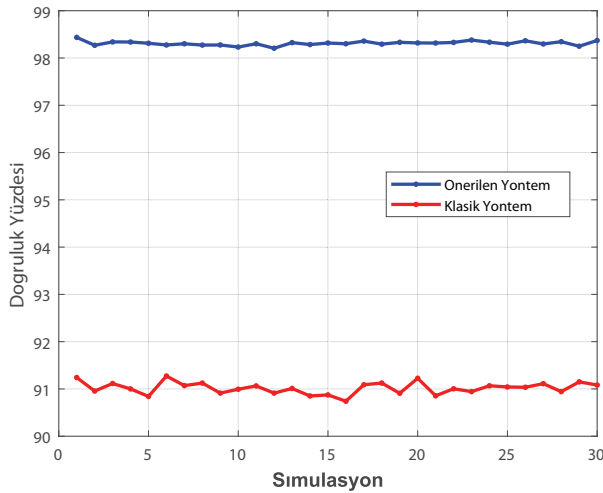
III. DENEYSEL SONUÇLAR

Bu bölümde önerilen yöntemin doğruluğu yukarıda anlatılan *EMG Physical Action* veri seti kullanılarak yapılmıştır. Öncelikle önerilen yöntemin EMG veri seti sınıflandırılırken hata yüzdesinin iterasyon sayısına göre nasıl değiştiği gözlemlenmiştir. Bu gözlemden faydalanılarak elde edilen optimum pencere genişliği ve kaydırma miktarı EMG sinyalinin sınıflandırılmasında kullanılmıştır. Elde edilen sonuçlarla klasik yaklaşım kıyaslanmıştır. EMG sinyali 5 kat çapraz doğrulama tekniği kullanılarak KNN algoritmasıyla sınıflandırılmıştır. 5 kat çapraz doğrulama tekniğinde veri seti 5 parçaya bölünür. Parçalardan birisi test için geri kalanı eğitim için kullanılır. Bu işlem her bir parça test verisi olarak kullanılına kadar devam eder. Test verisinden elde edilen doğruluk oranlarının ortalaması alınarak nihayi doğruluk oranına ulaşılır. Şekil 4'de görüleceği üzere GA kaydırma miktarı ve pencere genişliğini değiştirdikçe elde edilen doğruluk oranı da değişmektedir. GA kaydırma miktarı ve pencere genişliğini sistemli bir biçimde değiştirdiğinden her bir iterasyonda elde edilen hata yüzdesi azalmaktadır. Sonuç olarak hata oranı % 10 civarından % 1,5 civarına kadar gerilmiştir. Bu sonuç bize pencere genişliği ve kaydırma miktarının sistemli bir biçimde değiştirildiğinde ne kadar etkili sonuçlar alınacağını göstermektedir.

GA kullanılarak optimum pencere genişliği ve kaydırma miktarı sırasıyla 170 ms ve 17 ms bulunmuştur. Bu değerler, klasik yaklaşımda önerildiği şekliyle yani 125 ms ve 25 ms olarak alındığında elde edilen değerlerle kıyaslanmıştır. GA'da mutasyon oranı 0.01, çaprazlama oranı 0.7, maksimum popülasyon büyüklüğü 10 olarak alınmıştır. Kıyaslama 30 farklı koşmanın ortalaması, maksimum, minimum ve standart sapma değerleri üzerinden yapılmıştır. Tablo II'de görülen sonuçlara göre önerilen yöntemin ortalama, maksimum ve minimum değerler bakımından klasik yaklaşımdan daha iyi olduğu net biçimde görülmektedir. Ayrıca elde edilen standart



Şekil 4: İterasyon sayısına göre hatanın değişimi



Şekil 5: İterasyon sayısına göre hatanın değişimi

sapma değerinin önerilen yöntemde daha düşük olması önerilen yöntemin daha stabil olduğunun göstergesidir. Ayrıca Şekil 5'ten görüleceği üzere önerilen yöntemle klasik yöntem arasındaki fark açık biçimde görülmektedir.

IV. SONUÇ

Bu çalışmada EMG sinyallerinin etkin bir biçimde sınıflandırılması için yeni bir yaklaşım önerilmiştir. Deneme yanılma yöntemiyle seçilen pencere genişliği ve kaydırma miktarının yerine sistematik bir yaklaşımla pencere genişliği ve kaydırma miktarı belirlenmiştir. Bu yaklaşımda EMG sinyalleri sınıflandırılırken pencere genişliğinin ve kaydırma miktarının ne kadar olması gerektiği GA algoritma kullanılarak belirlenmiştir. Elde edilen sonuçlar, GA'nın pencere genişliğinin ve kaydırma miktarının optimize edilmesinde kullanılmasıyla EMG sinyallerinin daha etkin bir biçimde sınıflandırıldığını net bir biçimde göstermiştir.

KAYNAKÇA

- [1] X. Zhang, X. Chen, Y. Li, V. Lantz, K. Wang, and J. Yang, "A framework for hand gesture recognition based on accelerometer and emg sensors," *IEEE Transactions on Systems, Man, and Cybernetics - Part A: Systems and Humans*, vol. 41, no. 6, pp. 1064–1076, Nov 2011.
- [2] Y. Zeng, J. Yang, C. Peng, and Y. Yin, "Evolving gaussian process autoregression based learning of human motion intent using improved energy kernel method of emg," *IEEE Transactions on Biomedical Engineering*, pp. 1–1, 2019.
- [3] H. Kataoka and K. Sugie, "Recent advancements in lateral trunk flexion in parkinson disease," *Neurology: Clinical Practice*, vol. 9, no. 1, pp. 74–82, 2019. [Online]. Available: <https://cp.neurology.org/content/9/1/74>
- [4] F. H. Y. Chan, Yong-Sheng Yang, F. K. Lam, Yuan-Ting Zhang, and P. A. Parker, "Fuzzy emg classification for prosthesis control," *IEEE Transactions on Rehabilitation Engineering*, vol. 8, no. 3, pp. 305–311, Sep. 2000.
- [5] Q. Meng, J. Zhang, and X. Yang, "Virtual rehabilitation training system based on surface emg feature extraction and analysis," *Journal of Medical Systems*, vol. 43, no. 3, p. 48, Jan 2019.
- [6] M. B. I. Reaz, M. S. Hussain, and F. Mohd-Yasin, "Techniques of emg signal analysis: detection, processing, classification and applications," *Biological Procedures Online*, vol. 8, no. 1, pp. 11–35, Dec 2006. [Online]. Available: <https://doi.org/10.1251/bpo115>
- [7] A. Caliskan, "EMG sinyalleri için hibrid öznelik çıkarma yöntemi geliştirilmesi," *Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi*, vol. 8, no. 2, pp. 652 – 664, 2019.
- [8] A. Phinyomark, P. Phukpattaranont, and C. Limsakul, "Feature reduction and selection for emg signal classification," *Expert Systems with Applications*, vol. 39, no. 8, pp. 7420 – 7431, 2012. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S0957417412001200>
- [9] H. Badem, "Parkinson hastalığının ses sinyalleri Üzerinden makine Öğrenmesi teknikleri İle tanımlanması," *Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi*, vol. 8, pp. 630 – 637, 2019.
- [10] R. N. Khushaba, S. Kodagoda, D. Liu, and G. Dissanayake, "Muscle computer interfaces for driver distraction reduction," *Computer Methods and Programs in Biomedicine*, vol. 110, no. 2, pp. 137 – 149, 2013. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S0169260712003008>
- [11] D. Dua and C. Graff, "UCI machine learning repository," 2017. [Online]. Available: <http://archive.ics.uci.edu/ml>
- [12] J. Too, A. R. Abdullah, N. Mohd Saad, and W. Tee, "Emg feature selection and classification using a pbtest-guide binary particle swarm optimization," *Computation*, vol. 7, no. 1, 2019. [Online]. Available: <https://www.mdpi.com/2079-3197/7/1/12>
- [13] A. Baştürk, M. E. Yüksel, H. Badem, and A. Çalışkan, "Deep neural network based diagnosis system for melanoma skin cancer," in *2017 25th Signal Processing and Communications Applications Conference (SIU)*. IEEE, May 2017, pp. 1–4.
- [14] D. E. Goldberg and J. H. Holland, "Genetic algorithms and machine learning," *Machine Learning*, vol. 3, no. 2, pp. 95–99, Oct 1988. [Online]. Available: <https://doi.org/10.1023/A:1022602019183>
- [15] K. Deb, A. Pratap, S. Agarwal, and T. Meyarivan, "A fast and elitist multiobjective genetic algorithm: Nsga-ii," *IEEE Transactions on Evolutionary Computation*, vol. 6, no. 2, pp. 182–197, April 2002.
- [16] G. R. Harik, F. G. Lobo, and D. E. Goldberg, "The compact genetic algorithm," *IEEE Transactions on Evolutionary Computation*, vol. 3, no. 4, pp. 287–297, Nov 1999.
- [17] K. Anam and A. Al-Jumaili, "Evaluation of extreme learning machine for classification of individual and combined finger movements using electromyography on amputees and non-amputees," *Neural Networks*, vol. 85, pp. 51 – 68, 2017.
- [18] A. Baştürk, M. E. Yüksel, A. Çalışkan, and H. Badem, "Deep neural network classifier for hand movement prediction," in *2017 25th Signal Processing and Communications Applications Conference (SIU)*. IEEE, May 2017, pp. 1–4.
- [19] R. O. Duda, P. E. Hart et al., *Pattern classification and scene analysis*. Wiley New York, 1973, vol. 3.