

Çok Katmanlı Algılayıcı Yapay Sinir Ağı Kullanarak Packman Oyununda Yapılan El Hareketlerinin Sınıflandırılması

Classification of Hand Gestures in Packman Game Using Multilayer Sensor Neural Network

Rukiye Uzun Arslan^{1*}, Gizem Kübra Yaman¹ and Yalçın İşler²

¹ Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü, Zonguldak Bülent Ecevit Üniversitesi, Türkiye

² Mühendislik Fakültesi, Biyomedikal Mühendisliği Bölümü, İzmir Katip Çelebi Üniversitesi, Türkiye

*Sorumlu yazar: rukiveuzun67@gmail.com

+Konuşmacı: gizem.2406@gmail.com

Presentation/Paper Type: Oral / Abstract

Özet – Elektromiyografi, kas aktivitesi sonucunda meydana gelen biyolojik işaretlerin ölçülmesine olanak sağlayan invaziv olmayan bir yöntemdir. Yüzeysel ve iğne elektromiyografisi olarak uygulama amacına göre iki şekilde kullanılmaktadır. Bu çalışmada internet üzerinden açık erişime sahip ‘UCI Machine Learning Repository’ veri tabanında bireylerin packman oyununda yapmış oldukları yedi farklı el hareketi (el dinlenimde, el yumruk yapıldığında, bilek büküldüğünde, bilekte radyal ve ulnar sapma olması durumunda), bireylerden ölçülen yüzeysel elektromiyogram sinyalleri veri seti kullanarak sınıflandırılmaya çalışılmıştır. Bu amaçla ilk olarak verilerden ayırık dalgacık dönüşümüyle öznelik çıkarımı yapılmıştır. Daha sonra çıkarılan öznelikler literatürde çok yaygın olarak kullanılan çok katmanlı algılayıcı yapay sinir ağı yaklaşımı kullanılarak sınıflandırılmıştır. Sınıflandırma sürecinde yapay sinir ağı basit çapraz doğrulama algoritması kullanılarak eğitilmiştir ve sınıflandırıcının algoritması ile başarımları Matlab2017a programıyla gerçekleştirilmiştir. Sınıflandırıcının başarımları veri setinin farklı oranlarda bölünmesi ve farklı ara katman sayıları için araştırılmıştır. Optimum ağ topolojisi veri setinin %20-%80 oranında eğitim ve test verisi olarak bölünmesi ve ara katman sayısının 18 olması durumunda en yüksek başarımlar %91,67 olarak elde edilmiştir.

Anahtar Kelimeler – Yapay sinir ağları, çok katmanlı algılayıcı, sınıflandırma, elektromiyogram, ayırık dalgacık dönüşümü

Abstract – Electromyography is a noninvasive method that allows measurement of biological markers as a result of muscle activity. It is used as surface and needle electromyography according to the application purpose in two ways. In this study, seven different hand gestures (hand rest, hand punch, wrist bend, radial and ulnar deviation of the wrist) made by the individuals in the packman game in the ‘UCI Machine Learning Repository’ database with open access over the internet were measured by using the data set of surface electromyogram signals tried to be classified. For this purpose, firstly, feature is extracted from data by discrete wavelet transform. Then, the extracted features were classified using the multi-layered sensor artificial neural network approach, which is widely used in the literature. In the classification process, artificial neural network was trained using simple cross validation algorithm, the algorithm and performance of the classifier were realized with Matlab2017a program. The performance of the classifier has been investigated for the division of the data set at different rates and for different number of intermediate layers. The optimum network topology is obtained when the data set is divided by 20% -80% and the number of interlayers is 18, the highest performance is obtained as 91.67%.

Keywords – Artificial neural network, multilayer perceptron, classification, electromyogram, discrete wavelet transform.

I. GİRİŞ

Elektromiyogram (EMG); iskelet kaslarının kasılıp gevşemesiyle ortaya çıkan, zamanla değişen özellikte biyolojik ve elektriksel kökenli sinyallerdir [1]. Bu sinyallerin insan vücudundan uygun ölçüm düzenekleriyle kaydedilmesi, analizi ve yorumlanmasıyla ilgili yöntemlerin bütünü elektromiyografi olarak adlandırılmaktadır [2]. EMG sinyallerinin elde edilme yöntemleri kullanım amacına göre farklılıklar sergilemektedir. Bu bağlamda deri altına iğne elektrotları kullanılarak kas içinden veya yüzeysel elektrotuyla kas üzerindeki derinin üst tabakasından elde edilebilmektedir [3]. Bu yöntemler sırasıyla iğne elektromiyografisi ve yüzeysel elektromiyografisi (sEMG) olarak adlandırılmaktadır [4]. sEMG yöntemi, herhangi bir cerrahi müdahalenin olmadan deri yüzeyine yerleştirilen tek kullanımlık yüzeysel elektrotları

ile deri altında bulunan kas ya da kas gruplarının elektriksel aktivitesinin elde edilmesine olanak sağlaması nedeniyle tercih edilmektedir [4-7].

EMG sinyallerinin karakteristikleri ölçüm yapılan kasın bulunduğu yere ve uyarılma şiddetine göre değişkenlik göstermektedir [8]. Bunun yanı sıra tek bir matematiksel ifade kullanılarak EMG işaretinin tanımlanması mümkün değildir. Bu bağlamda EMG verisinin tanısal değerini arttırmak için yüksek dereceli istatistikler, spektral ve dalgacık analizi, doğrusal ayırım analizi, sayısal filtreleme, modelleme analizleri ve yapay sinir ağları gibi yeni işaret işleme tekniklerinden faydalanılmaktadır [9].

Günümüzde işaret işleme teknikleri ve yapay zeka tekniklerinin ilerlemesiyle bilgisayar tabanlı EMG analiz

algoritmaları da hızlı bir gelişme sergilemektedir. Bu bağlamda literatürde birçok çalışma bulunmaktadır [10-19]. Örneğin 1999 yılında Cai ve arkadaşları, dalgacık dönüşümü yöntemiyle yapay sinir ağlarını (YSA) kullanarak ön kol hareketinden (el kavrama, el uzatma, ön kol supinasyon ve ön kol pronasyonu) elde edilen EMG sinyallerinin sınıflandırılmasını araştırmışlardır. EMG sinyallerinin sınıflandırılmasında önerilen modelin %90 bir başarımla sergilediği gösterilmiştir [10]. Hardalaç ve Poyraz (2002) geri yayımlı YSA modeli kullanarak normal ve Neuropathy kas hastalığına ait EMG verilerini sınıflandırmasını gerçekleştirmişlerdir. Bu amaçla EMG işaretlerinden Hızlı Fourier Dönüşümü (HFD) analiziyle elde ettikleri katsayılarını iki farklı geri yayılım öğrenme algoritmasıyla (eşlenik gradyan ve hızlıprop öğrenme algoritmaları) eğiterek başarımlarını karşılaştırmış ve sınıflandırmada eşlenik gradyan öğrenme algoritmasıyla daha yüksek bir başarımlar elde edildiği tespit edilmiştir [11]. Güler ve Koçer (2005), normal ve nöromusküler hastalığı olan (nöropati ve miyopati) kişilerden alınan EMG verilerini destek vektör makineleri (DVM) ve çok katmanlı algılayıcılarında (ÇKA) kullanarak sınıflandırma başarımları irdelenmiştir. Yapılan analizler sonucu DVM'nin ÇKA'ya göre nöromusküler hastalıkları teşhisinde daha yüksek bir sınıflandırma başarımlarına sahip olduğu gösterilmiştir [12]. Subasi ve arkadaşları (2006) EMG sinyallerinin sınıflandırılmasında ileri beslemeli hata geri yayılım algoritması ve dalgacık katsayısı metoduna dayanan iki farklı yapay sinir ağı modeli önermişlerdir. Önerilen modellerden dalgacık katsayısına dayanan sınıflandırıcının daha yüksek bir başarımla sahip olduğu kanıtlanmıştır [13]. 2007 yılında Lucas ve arkadaşları miyoelektrik protezlerini kontrol etmek amacıyla çok kanallı yüzey EMG sinyallerinin sınıflandırılmasında destek vektör makineleri ve sinyal tabanlı dalgacık optimizasyonuna dayanan yeni bir yöntem önermişlerdir. Önerilen yöntemin altı farklı el hareketinin sınıflandırma başarımları %95 oranında elde edilmiştir [14]. Koçer (2010) kas rahatsızlığı olan ve olmayan kişilerden aldığı EMG sinyallerinin sınıflandırılmak için yapay sinir ağları (YSA) ve bulanık mantığın bir arada kullanarak geliştirdikleri sistemle %90'lık bir sınıflandırma başarımları elde etmiştir [15]. Akgün ve arkadaşları(2013) elektromekanik denetimli protezlerin kontrolü amacıyla EMG sinyallerini geri yayımlı yapay sinir ağı algoritması ile sınıflandırmış ve yaklaşık %98 oranında bir başarımlar elde etmişlerdir [16]. Uzun ve arkadaşları (2017) diz anormallığı olan ve olmayan bireyleri yürüme esnasında kaydedilen sEMG verileri kullanarak tespit etmişlerdir. Bu amaçla verilerden ayrık dalgacık dönüşümüyle belirledikleri öznelikleri YSA'ya uygulanmış ve %90'ın üzerinde bir sınıflandırma başarımları elde etmişlerdir [7]. Uzun ve arkadaşları (2018) diz rahatsızlıklarının tespit etmek amacıyla farklı duruş pozisyonlarında alınan sEMG sinyallerinin sınıflandırılmasında YSA ve lojistik regresyon (LR) yöntemlerinin başarımlarını karşılaştırmışlardır. Sınıflandırmada YSA yönteminin daha yüksek başarımlar sergilediğini ve diz rahatsızlıklarının sadece oturma durumundaki sEMG verilerini kullanarak tespit edilebileceğini göstermişlerdir [17]. Bireylerin el hareketlerini belirlemek amacıyla sEMG sinyallerinin sınıflandırılmasında radyal fonksiyonlu yapay sinir ağı (RFYSA) ve ileri yayımlı yapay sinir ağı (İYSA) metodları

kullanıldığı başka bir çalışmada sırasıyla % 94.81, %94.05'lik başarımlar elde edilmiştir [18].

Bu çalışmada sEMG verileri kullanarak packman oyununda yapılan yedi farklı el hareketinin sınıflandırılması gerçekleştirilmiştir. Bu amaç doğrultusunda ayrık dalgacık dönüşümü yöntemiyle (ADD) belirlenen öznelıklar çok katmanlı bir yapay sinir ağına uygulanarak sınıflandırma başarımları araştırılmıştır.

II. YÖNTEM

Bu çalışmada, internet üzerinden açık erişime sahip UCI Machine Learning Repository veri tabanında yer alan packman oyunu esnasında yapılan yedi farklı el hareketi (el dinlenimde, el yumruk yapıldığında, bilek büküldüğünde, bilekte radyal ve ulpar sapma olması durumunda) için el kaslarından kaydedilen sEMG veri setinden (<https://archive.ics.uci.edu/ml/datasets/EMG+data+for+gesture#>) yararlanılmıştır. Bu veriler yaşları 18-41 yaşları arasında olan 24'ü kadın ve 13'ü erkek toplam 37 sağlıklı bireyden alınmıştır. Veriler bireylerin ön koluna takılan bir MYO Thalmic bileklik ve bir bluetooth alıcısının bilgisayara bağlanması ile elde edilmiştir. Bileklerde miyografik sinyalleri alan ön kol etrafına eşit aralıklarla yerleştirilmiş sekiz adet sensör bulunmaktadır. Bireylere her bir hareket 3 saniye süre ve her hareket arası 3 saniye olacak şekilde yaptırılmış ve el kaslarındaki sEMG verileri kaydedilmiştir.

Yapılan bu çalışmada her bireyin yedi farklı el hareketini yaptıklarında kaydedilen sEMG verilerinden faydalanılarak, yapılan hareketler sınıflandırılmaya çalışılmıştır. Bu amaçla öncelikli verilerden ayrık dalgacık dönüşümü (ADD) yöntemiyle öznelik çıkarımı yapılmıştır. Sonrasında, veriden elde edilen öznelikleri anlamlı kılmak adına istatistiksel işlemlerle boyut küçültme ve normalizasyon yapılmıştır. Son olarak [0,1] aralığına normalize edilen veriler çok katmanlı yapay sinir ağı (ÇKYSA) girişi olarak kullanılmıştır. Aşağıda veriye uygulanan işlemler daha ayrıntılı bir şekilde açıklanmıştır.

A. Ayrık Dalgacık Dönüşümü Ve Boyut Azaltma

Biyolojik sinyallerin spektral analizinde en çok tercih edilen yöntemlerden biri ayrık dalgacık dönüşümü (ADD) yöntemidir. Bu yöntem işaretin zaman-frekans düzleminde daha hassas ve verimli (analiz süresi kısa, hesap yükü daha az) bir şekilde işlenmesine imkan tanımaktadır [7, 19, 20]. Filtreler (alçak ve yüksek geçiren) kullanılarak yapılan bu yöntemde işaret alt bantlara (yaklaşım ve detay) ayrıştırılmaktadır. Ayrıştırma işlemiyle, istenen frekans aralığında yaklaşım ve detay bilgisi kullanılarak sinyalin analizi yapılabilmektedir. Yapılan bu çalışmada daubechies-5 filtreli 5. seviyeden bir dalgacık ağacı kullanılarak, her seviyede ayrıntı katsayıları hesaplanmıştır [7]. Bunun yanı sıra sEMG verilerinden ADD yöntemiyle belirlenen öznelıkların boyutları fazla olduğu için çeşitli istatistiksel yöntemler (katsayıların standart sapması, ortalaması, maksimumu, minimumu, varyansı) kullanılarak boyut azaltması yapılmıştır. Böylece yapay sinir ağlarına uygulanacak girdi verilerinin boyutu azaltılarak, verilerin daha hızlı ve hassas bir şekilde sınıflandırılmasının yapılabilmesi sağlanmıştır.

Tablo 1. sEMG Verilerinden Normalize Edilerek Belirlenen Öznelıklar

Standart Sapma	Mak.	Ortalama	Varyans	Min.
0.001285	0.014245	8.41E+08	1.16E+06	-0.0114
0.001245	0.011396	-2.10E+09	1.09E+06	-0.0114
0.014108	0.129633	-7.13E+09	1.40E+08	-0.19944
0.008681	0.080487	3.91E+09	5.29E+07	-0.08547
0.012035	0.146728	4.70E+09	1.02E+08	-0.09901
0.013573	0.132482	4.75E+09	1.29E+08	-0.14032
0.011282	0.159549	-3.82E+09	8.93E+07	-0.20656

Tablo 2. Farklı Veri Set Oranları ve Ara Katman Sayıları İçin Sınıflandırıcı Başarımları

Ara katman sayısı	%20-%80			%30-%70			%40-%60		
	ACC	SEN	SPE	ACC	SEN	SPE	ACC	SEN	SPE
8	0.8770	0.9444	0.8657	0.8651	0.8611	0.8657	0.8849	0.9167	0.8796
10	0.8571	0.9167	0.8472	0.8770	0.9167	0.8704	0.8413	0.6111	0.8796
12	0.8690	0.8333	0.8750	0.8651	0.9167	0.8565	0.8611	0.9444	0.8472
14	0.8095	0.8889	0.7963	0.8810	0.8611	0.8843	0.8690	0.8333	0.8750
16	0.8690	0.7500	0.8889	0.8651	0.9167	0.8565	0.8333	0.9167	0.8194
18	0.9167	0.7778	0.9398	0.8492	0.7500	0.8657	0.8611	0.8889	0.8565
20	0.8651	0.8333	0.8704	0.8849	0.9167	0.8796	0.8611	0.8333	0.8657

B. Çok katmanlı algılayıcı yapay sinir ağı (ÇKYSA)

Son yıllarda EMG sinyallerinin incelenmesi, yorumlanması ve sınıflandırılmasında dalgacık analizi, sayısal filtreleme, yapay sinir ağları (YSA) gibi birçok yeni işaret işleme teknikleri kullanılmaktadır [21]. Bunlardan yapay sinir ağlarının; işaretleri modelleyebilme, işaretin sınıflandırılmasına imkan vermesi ve hızlı olması gibi birçok avantajının olması nedeniyle biyomedikal uygulamalarda sıklıkla tercih edilmektedir [17]. YSA; insan beyninin öğrenme yeteneğinden esinlenerek geliştirilen, her birinin kendine özgü bir belleği olan ve ağırlıklı bağlantılarla birbirine bağlı yapay sinir hücrelerinden oluşmaktadır [22]. Bu hücrelerin 3 katman (girdi katmanı, ara katmanlar ve çıktı katmanı) ve her katmanda paralel olacak şekilde birbiriyle bağlanmasıyla ağ tasarlanmaktadır. YSA'lar ağı mimarisi, öğrenme algoritması, nöronları arasındaki bağlantı şekilleri gibi birçok farklı kritere göre sınıflandırılmaktadır. Bu bağlamda çok katmanlı algılayıcı yapay sinir ağı (ÇKYSA) biyomedikal alanında en çok kullanılan ve tercih edilen ağ yapısıdır [17]. Bu ağ yapısında kendisine girdi olarak verilen bilgidir minimum hatayla istenilen çıktıyı elde etmek için veri işleme süreci yani ağı eğitimi yenilenmektedir. Ağı eğitimi farklı öğrenme algoritmaları mevcut olup, bu çalışmada basit ve eğitim süresi en kısa olan Levenberg-Marquardt geri yayılım algoritması tercih edilmiştir.

Çalışmada öncelikle ADD yöntemiyle ayırt edici olarak öznelikler belirlenerek normalize edilmiştir. Normalize edilen bu değerler YSA' da girdi olarak kullanılmıştır. Tablo 1' de örnek bir veri seti gösterilmiştir.

Daha sonra düzenlenen bu veri seti çapraz doğrulama yöntemiyle eğitim ve test verisi olarak ikiye bölünmüştür. Eğitim verisiyle sınıflandırıcının model parametrelerinin tespitinde, test verisi ise eğitilen sınıflandırıcının daha önce karşılaşmadığı girdiye verdiği cevaba göre sınıflandırıcının başarımını ölçmek için kullanılmaktadır [23]. Sınıflandırıcı algoritmasının başarımının hesaplanmasında ise çoğunlukla basit olması nedeniyle duyarlılık (SEN), belirleyicilik (SPE) ve doğruluk (ACC) oranları kullanılmaktadır. Bu oranlar sınıflandırıcının test verilerinden elde edilen doğru ve yanlış sınıflandırma durumlarına göre hesaplanmaktadır [22, 23]. Bu bağlamda yapılan bu çalışmada çapraz doğrulama yöntemine dayanarak sınıflandırıcının algoritması ve başarımı Matlab2017a programıyla gerçekleştirilmiştir. Buna göre veri setinin farklı oranlarda bölünmesi ve ara katman sayısındaki değişimin sınıflandırıcı başarımı üzerindeki etkisi araştırılmıştır. Elde edilen sonuçlar Tablo 2' de verilmiştir. Tablo 2' den de açıkça görüldüğü gibi en iyi sınıflandırma doğruluğu veri setinin %20-%80 olarak bölündüğü durumda ve ara katman sayısı 18 olması durumunda elde edildiği görülmüştür.

Sonuç olarak, yapılan bu çalışmada packman oyunu esnasında yapılan el hareketleri çok katmanlı algılayıcı yapay sinir ağı kullanarak sınıflandırılmıştır. Çapraz doğrulama yöntemine göre veriler farklı oranlarda bölünmüş ve sınıflandırıcının performansı farklı ara katman sayılarına göre

hesaplanmıştır. Elde edilen sonuçlardan en yüksek sınıflandırıcı başarımının ara katman sayısının 18 ve veri setinin %20-%80 oranında bölündüğünde elde edildiği tespit edilmiştir. Bu çalışmada tek bir sınıflandırıcıya göre el hareketlerinin kısıtlanması çalışmasının kısıtlamalarındandır. Gelecek çalışmalarda farklı sınıflandırıcılar kullanılması durumunda başarımları hesaplanması planlanmaktadır. Bu amaç doğrultusunda için yazarlardan birinin yüksek lisans tezi bu kapsamda gerçekleştirilmektedir.

KAYNAKLAR

- [1] M.Z. Al Faiz and A.H. Miry, Artificial Human Arm Driven by EMG MATLAB - A Fundamental Tool for Scientific Computing and Engineering Applications, Ed. In Katsikis VN., Intech Open, Greece, 2012.
- [2] P. Konrad, ABC of EMG: A Practical Introduction To Kinesiological Electromyography, Noraxon USA, Inc., Arizona, USA, 2005.
- [3] S.A. Güvenç, "Ön kol yüzey EMG sinyallerinin örüntü tanıma tabanlı analizi ve yapay sinir ağları ile sınıflandırılması," Yüksek lisans tezi, Bilgisayar Mühendisliği Anabilim Dalı, Fen Bilimleri Enstitüsü, Karadeniz Teknik Üniversitesi, Trabzon, Türkiye, 2014.
- [4] S. Yağcıoğlu, "El hareketlerinin elektromiyogram sinyalleri ve yardımcı sensör verileri ile sınıflandırılması," Yüksek lisans tezi, Fen Bilimleri Enstitüsü, Elektronik ve Haberleşme Mühendisliği Anabilim Dalı Biyomedikal Mühendisliği Programı, İstanbul Teknik Üniversitesi, İstanbul, Türkiye, 2016.
- [5] H.J. Hermens, B. Freriks, C. Disselhorst-Klug and G. Rau, "Development of recommendations for sEMG sensors and sensor placement procedures", J Electromyogr Kinesiol, vol.10(5), pp.361-74, 2000.
- [6] C. Tepe, "EMG işareti ile protez elin değişken hızla denetimi: Donanım, yazılım ve algoritmik yöntemler", Doktora tezi, Fen Bilimleri Enstitüsü, Elektrik-Elektronik Mühendisliği Anabilim Dalı, Ondokuz Mayıs Üniversitesi, Samsun, Türkiye, 2014.
- [7] O. Erkaymaz, İ. Şenyer, and R. Uzun, "Yüzey EMG sinyallerinden diz anormallığının yapay sinir ağları ile tespiti", IEEE 25. Sinyal İşleme ve İletişim Uygulamaları Kurultayı, Malatya, 2017, p.16-19.
- [8] M.J. Aminof, Clinical electromyography. In: Electrodiagnosis in Clinical Neurology, New York, USA: Churchill Livingstone, 1992.
- [9] K. Biçen, "EMG (Elektromiyografi) kontrollü protez kol tasarımı," Yüksek lisans tezi, Fen Bilimleri Enstitüsü, Mekatronik Mühendisliği Anabilim Dalı, Dokuz Eylül Üniversitesi, İzmir, Türkiye, 2011.
- [10] L. Cai, Z. Wang, and H. Zhang, "An EMG classification method based on wavelet transform," Proceedings of the First Joint BMES/EMBS Conference, 1999.
- [11] F. Hardalaç and M. Poyraz, "Classification of EMG signals using artificial neural network and diagnosis of neuropathy neuromuscular disease," Journal of Polytechnic, vol. 5, pp. 75-81, 2002.
- [12] N.F. Güler and S. Koçer, "Classification of EMG signals using PCA and FFT," Journal of Medical Systems, vol. 29(3), pp. 241-50, 2005.
- [13] A. Subasi, M. Yilmaz, and H.R. Ozcalik, "Classification of EMG signals using wavelet neural network," Journal of Neuroscience Methods. Vol. 156, pp. 360-367, 2006.
- [14] M.F. Lucas, A. Gaufriau, S. Pascual, S. Doncarli, and D. Farina, "Multi-channel surface EMG classification using support vector machines and signal-based wavelet optimization," Biomedical Signal Processing and Control, vol. 3(2), pp. 169-174, 2008.
- [15] S. Koçer, "Classification of EMG signals using neuro-fuzzy system and diagnosis of neuromuscular diseases," Journal of Medical Systems, vol. 34(3), pp. 321-329, 2010.
- [16] G. Akgün, M. Demetgül ve E. Kaplanoğlu, "EMG sinyallerinin öz nitelik çıkarımı ve geri yayımlı yapay sinir ağı algoritması ile sınıflandırılması," Otomatik Kontrol Ulusal Toplantısı, Malatya, 2013.
- [17] R. Uzun, O. Erkaymaz, İ. Şenyer Yapıcı, "Comparison of artificial neural network and regression models to diagnose of knee disorder in different postures using surface electromyography," Gazi University Journal of Science, vol. 31(1), pp. 100-110, 2018.
- [18] B. Taşar, A.K. Tanyıldızı, O. Yakut ve A. Gülten, "EMG sinyallerinin anımlandırılması için radyal fonksiyonlu yapay sinir ağı tasarımı," Uluslararası Mühendislik Araştırma ve Geliştirme Dergisi, vol. 10(1), pp. 153-159, 2018.
- [19] Y. Koçyiğit ve M. Korürek, "EMG işaretlerini dalgacık dönüşümü ve bulanık mantık sınıflayıcı kullanarak sınıflama," İstanbul Teknik Üniversitesi Dergisi, vol. 4(3), pp. 25-31, 2005.
- [20] G. Özmen, Y. Özbay ve A.H. Ekmekçi, "EMG sinyallerinde kas yorgunluğunun YSA ile sınıflandırılması," Tıp Teknolojileri Ulusal Kongresi, Nevşehir, 25 - 27 Eylül 2014, p.279-282.
- [21] A. Dobrowolski, M. Wierzbowski, and K. Tomczykiewicz, "Multiresolution MUAPs decomposition and DVM-based analysis in the classification of neuromuscular disorders," Comput Methods Prog Biomed, vol. 107(3), pp. 393-403, 2012.
- [22] Y. Kutlu, Y. Isler, D. Kuntalp ve M. Kuntalp, "Çok katmanlı ağ yapıları kullanılarak diken dalgaların algılanması," IEEE 14. Sinyal İşleme ve İletişim Uygulamaları Kurultayı, Antalya, 17-19 Nisan 2006, p. 95.
- [23] R.O. Duda, P.E. Hart, and D.G. Stork, Pattern classification. 2nd Ed. New York: John Wiley and Sons, 2001.