

Ampute Elektromiyografi Sinyallerinin Evrişimli Sinir Ağları Kullanılarak Sınıflandırılması

Amputee Electromyography Signal Classification Using Convolutional Neural Network

Fatih ONAY

Elektrik-Elektronik Mühendisliği
İzmir Yüksek Teknoloji Enstitüsü
Urla, İzmir, Türkiye
fatihonay@iyte.edu.tr

Ahmet MERT

Mekatronik Mühendisliği
Bursa Teknik Üniversitesi
Yıldırım, Bursa, Türkiye
ahmet.mert@btu.edu.tr

Özetçe—Ampute elektromiyografi (EMG) sinyallerinin sınıflandırılması kayıp uzvun yerini alacak protezlerin geliştirilmesi için önem arz etmektedir. Kalan uzuv üzerinden alınan EMG sinyalleri, kas hareketlerinin düzgün gerçekleşmemesi sebebiyle sınıflandırma performansını düşürmektedir. Bu çalışmada, karekök ortalama (KÖ) ve dalga form uzunluğu (DFU) gibi EMG analizinde başarı ile kullanılan teknikler ile Evrişimsel sinir ağı (ESA) birleştirilerek sınıflandırma başarısının artırılması amaçlanmıştır. KÖ ve DFU'dan oluşan öznitelik imgesi ESA'ya uygulayarak düşük, orta ve yüksek kuvvet seviyelerinde altı el hareketi için sınıflandırma sonuçları doğrusal ayrımcılık analizi ve en yakın komşu algoritmalarıyla kıyaslanmıştır.

Anahtar Kelimeler — *Elektromiyografi; Evrişimsel sinir ağı; Örüntü tanıma; Ampute.*

Abstract— The classification of EMG signals for the amputees is important to develop a powered-prosthetic that is capable of replacing with lost limbs. The EMG signals collected from residual limbs reduce the classification accuracy due to muscle movements that cannot be realized properly. In this study, classification performance is aimed to be increased by combining CNN with root mean square (RMS) and waveform length (WL) that are used in analysis of EMG signals successfully. The features such as RMS and WL extracted from EMG signals for the classification of six hand movements at the low, medium, and high force levels were applied to CNN input, and classification results were compared with nearest neighbour and linear discriminant analysis.

Keywords *Electromyography; Convolutional neural network; Pattern recognition; Amputee.*

I. GİRİŞ

Ampute bireylerin hayat kalitesini düşüren ve günlük hayattaki aktivitelerini oldukça kısıtlayan uzvun kayıplarının eksikliği, güçlendirilmiş el protezleri ile son yıllarda giderilmeye çalışılmaktadır. Yapılmak istenen el ve kol hareketleri sırasında insan kasları tarafından üretilen elektromiyografi (EMG) sinyallerinin sahip olduğu örüntüleri

ve bilgileri ortaya çıkararak, bunları el protezlerinin kontrolünde kullanmak için çeşitli çalışmalar yapılmıştır [1].

El protezlerinin kontrolünde kullanılan EMG sinyallerinin kalitesi etkileyen ve analizini zorlaştıran birçok fizyolojik ve çevresel faktörler vardır. Bunlardan bazıları, elektrotların kayması, kas yorgunluğu, kişiler arasındaki fizyolojik çeşitlilikler ve farklı güç seviyelerinde meydana gelen kas kasılmaları gibi farklı etkenlerdir [2, 3]. Tüm bunları göz önünde tutarak, EMG sinyallerinin analizinin gerçekleştirilmesi ve sezgisel bir kontrol yönteminin uygulanması gerekmektedir. Bu amaçla, geleneksel örüntü tanıma metodları ile EMG sinyalleri üzerinde geçmiş yıllarda birçok çalışma yapılmıştır [4, 5]. Sinyalden ortalama mutlak değer, sıfır geçiş sayısı, dalga formu uzunluğu (DFU) gibi zaman tabanlı öznitelikler çıkarılarak, doğrusal ayrımcılık analizi (LDA), destek vektör makineleri (SVM), en yakın komşu (k -NN) gibi sınıflandırıcılar ile farklı hareketlere ait sinyallerden elde edilen özniteliklerin içerdiği karakteristik örüntüler tespit edilmeye çalışılmıştır [6]. Tüm bu çalışmalara rağmen, önerilen yöntemler günlük hayatta hassas ve gürbüz bir kontrolün gerçekleşmesini sağlayarak çeşitli el hareketlerine duyarlı akıllı bir protezin ortaya konulması için yeterli değildir [7].

Son yıllarda geleneksel yöntemlere alternatif olarak derin öğrenme tabanlı yöntemler EMG sinyallerinin analizinde kullanılmaya başlanmıştır [8]. Evrişimsel sinir ağları (ESA) ise derin öğrenme tabanlı EMG sinyali analizinde en çok tercih edilen yöntem olmaktadır [9]. Öznitelik çıkarma işlemi yapmadan, EMG sinyallerinin direkt olarak ESA modeline giriş olarak uygulanıp sınıflandırılması ve geleneksel örüntü tanıma yöntemlerine göre daha yüksek başarılı sonuçlar vermesi bu alandaki çalışmalara önem kazandırmıştır. Park ve Lee ESA ve SVM kullanarak EMG sinyallerini farklı el hareketleri için sınıflandırmışlardır. Yapılan çalışma sonucunda ESA SVM'ye göre daha başarılı bir sınıflandırma performansı göstermiştir [10]. Du ve arkadaşları [11] farklı sınıflandırma senaryoları için

ESA ve diğer geleneksel sınıflandırma metodlarını karşılaştırmışlar ve sonuç olarak ESA tabanlı EMG sınıflandırma işleminin daha başarılı sonuçlar verdiğini göstermişlerdir. EMG sinyallerini bir ön işleme tabii tutmaksızın ESA ile kullanılması ağır işlem gücü gerektirmektedir. Bu yüzden işlem yükünü hafifletecek ve sınıflandırma performansını geliştirecek çalışmalar da yapılmıştır [12, 13]. Diğer açıdan EMG sinyalleri ile el hareket resimlerini birlikte işleyerek başarıyı artırma çalışmaları sağlıklı bireyler üzerinde denemiştir. İmgeler için ESA mimarisi ile ve EMG sinyalleri için literatürde sıklıkla kullanılan sinyal morfolojik özellikleri ile dalgacık dönüşüm kullanılmıştır [15].

Bu çalışmada, farklı kuvvet seviyelerindeki EMG sinyallerinin sınıflandırılması ve hassas bir şekilde ayırt edilebilmesini sağlamak amacıyla ESA tabanlı EMG sınıflandırma yöntemi geleneksel örüntü tanıma yöntemlerine alternatif olarak sunularak performansları karşılaştırılacaktır. Bölüm II.'de çalışmanın yapıldığı EMG veri seti tanıtılacak, bölüm III'te ise kullanılan metoda dair bilgiler verilecektir. Son olarak bulgular ayrıntılı bir şekilde gösterilerek gerekli çıkarımlar yapılacaktır.

II. VERİ SETİ

Bu çalışma kapsamında kullanılan EMG sinyalleri, dokuz ampute katılımcıdan, sekiz kanal kullanılarak toplanmıştır. Veri setinde yer alan altı farklı el ve parmak hareketi (başparmak (BP), işaret parmağı (İP), çimdik (ÇK), tripod kavrama (TK) kanca kavrama (KK) ve küresel kavrama (KÜK)) için tüm katılımcılardan 5 ile 8 arası değişen sayıda kayıt alınmıştır. Düşük, orta ve yüksek kuvvet seviyelerine ait sinyallerin her biri için bu işlemler tekrarlanmıştır. Gerçekleştirilen hareketler Şekil 1' de gösterilmiştir [14].



Şekil 1. Altı sınıflı veri seti el hareketleri (1: BP, 2: İP, 3: ÇK, 4:TK, 5: KK, 6: KÜK).

Sinyaller 2000 Hz örnekleme frekansı ve 16 bit çözünürlük ile kayıt edilmiştir. Her bir el ve parmak hareketlerinin, tüm kuvvet seviyelerine ait işaretleri bu çalışma kapsamında kullanılacaktır. Veri setine ait genel bilgiler Tablo I'de gösterilmiştir.

Tablo I. Genel Bilgiler

Katılımcı Sayısı	Hareket Sayısı	Elektrot Sayısı	Trial Sayısı
9 (7E 2K)	6	8	5-8

III. ÖNERİLEN EVRİŞİMSSEL SİNİR AĞI TABANLI EMG ANALİZİ

EMG veri setindeki her bir ampute bireye ait 8 kanallı sinyal için her bir kanala öncelikli olarak karekök ortalama (KO) ve dalda form uzunluğu (DFU) teknikleri uygulanmıştır. Bu iki yöntem EMG sinyal analizinde başarı ile uygulanan yöntemler arasındadır.

$$KO = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2} \quad (1)$$

$$DFU = \sum_{i=1}^N |x_i - x_{i-1}| \quad (2)$$

Bu iki teknik her kanal ($k=1,2,\dots$) sinyale ($x_k[n]$) ve sinyalin türevine ($\nabla x_k[n]$) uygulanarak öznitelik vektörü şöyle elde edilir

$$\mathbf{F} = \begin{bmatrix} KO_1 & \dots & \dots \\ \nabla KO_1 & \dots & \dots \end{bmatrix} \quad (3)$$

Bu öznitelik vektörü \mathbf{F} , 2×16 boyutlarında 9 amputenin 6 sınıflı hareketi için düşük, orta ve yüksek kuvvet seviyelerinde çıkarılır.

Elde edilen bu öznitelikler veri setinin orijinal çalışmasında [14] kullanılan sınıflandırma senaryosuna sadık kalınarak her bir katılımcının her kuvvet için üç defa alınan 8 kanallı EMG sinyalleri eğitim ve kalan en az 2 ve maksimum 5'er adet kayıtları ise test için kullanılmıştır. Aynı kuvvetle eğitilen evrişimsel sinir ağı (ESA), yine aynı kuvvet test verisi ile başarısı değerlendirilmiştir. Önerilen ESA yapısı Şekil 2.'de verilmiştir.

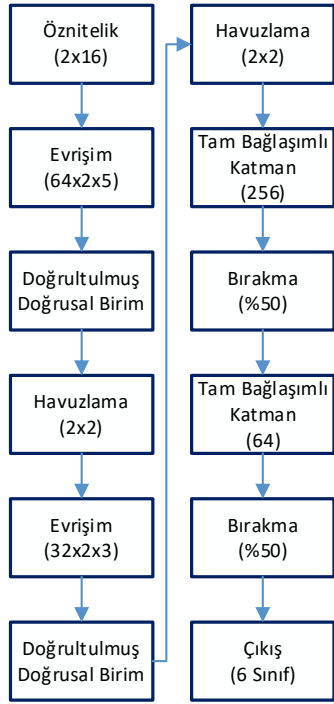
Öncelikle 2×16 boyutlarında oluşturulan öznitelik imgesi \mathbf{F} , 5×5 ve 3×3 boyutlarında 64 ve 32 filtreye sahip evrişim ve bunların arasındaki aktivasyon ile 2×2 boyutlarındaki havuzlama işlemlerine tabi tutularak öznitelikler yeniden değerlendirilir. Böylece kanallara ait KO ve DFU arasındaki etkileşim ve değişim açısından daha çok bilgi içerecek şekilde organize edileceği hedeflenmiştir. Sonraki işlemler yapay sinir ağlarından alışılagelen 256 ve 64 nöron sayısına sahip 6 çıkışlı katmanlardan oluşmaktadır. Bırakma blokları ile ESA'daki aşırı öğrenme problemi aşılmaya çalışılmıştır. Önerilen bu yöntem yaklaşık 160 bin örneklilik veri üzerinde eğitilmiş ve test edilmiştir.

IV. DENEYSSEL SONUÇLAR

EMG veri setindeki 8 kanallı kayıtlar, 3 kuvvet seviyesi ile 6 çıkışlı sınıflandırma bu çalışmada irdelenmiştir. Düşük, orta ve yüksek kuvvet derecelerinde önerilen ESA, KU ve DFU esaslı örüntü tanıma sisteminin sınıf içi (aynı kuvvet seviyesinde) performansı çalışılmıştır.

119738 adet düşük kuvvet ile yapılan 6 el hareketi önerilen yöntem eğitilerek 48787 örneklilik test verisi ile performansı

değerlendirilmiştir. Elde edilen karşıtlık matrisi Şekil 3.'de gösterilmiştir.



Şekil 2. EMG sınıflandırma için önerilen ESA yapısı.

Gerçek Sınıflar	1	2	3	4	5	6
1	6702	177	341	37	37	260
2	82	6917	500	423	496	429
3	768	358	6731	9	715	301
4	38	288	129	6519	250	357
5	206	295	298	102	6710	871
6	321	95	363	48	207	6007
	1	2	3	4	5	6

Şekil 3. Düşük kuvvet sınıflandırma sonuçları.

ESA, ADAM optimizasyon yöntemi 0.001 öğrenme hızı ile çalıştırılarak düşük kuvvet seviyesi için %81.81 doğruluk oranı elde edilmiştir. Aynı yöntemle orta kuvvet örnekleriyle eğitilerek orta kuvvet test verisi ile performansı çıkarılmıştır. Orta kuvvet karşıtlık matrisi Şekil 4.'de gösterilmiştir.

Orta kuvvet karşıtlık matrisi ile çıkarılan sonuçlar neticesinde %79.49 başarı elde edildiği görülmektedir. Son kuvvet olan yüksek seviye için elde edilen matris Şekil 5.'de verilmiştir.

Gerçek Sınıf	1	2	3	4	5	6
1	5821	11	922	87	53	601
2	114	6497	37	730	797	131
3	864	419	5722	556	67	432
4	322	197	47	6707	149	150
5	67	206	500	84	6046	252
6	117	196	371	262	647	5592
	1	2	3	4	5	6

Şekil 4. Orta kuvvet sınıflandırma sonuçları.

Gerçek Sınıf	1	2	3	4	5	6
1	4805	23	354	16	181	177
2	210	6478	8	384	683	158
3	806	55	5433	224	76	467
4	17	139	24	7070	160	40
5	418	530	396	497	5870	658
6	212	79	647	260	702	5547
	1	2	3	4	5	6

Şekil 5. Yüksek kuvvet sınıflandırma sonuçları.

Yüksek kuvvet için elde edilen doğruluk oranı %80.36 olarak elde edilmiştir.

ESA için 2×16 öznitelik imgesi, vektör haline getirilerek LDA, QDA ve k -NN sınıflandırıcılar ile eğitim ve test işlemleri önceki basamaklarda belirtildiği üzere tekrarlanmıştır. Böylece önerilen ESA tabanlı EMG sınıflandırmanın sınıflandırma başarısı üzerine katkısı irdelenmeye çalışılmıştır ve sonuçlar Tablo II'de verilmiştir.

TABLO II. ÖNERİLEN ESA TABANLI YÖNTEM İLE DİĞER SINIFLANDIRICILARIN KIYASLANMASI.

	LDA(%)	QDA(%)	<i>k</i> -NN(%)	ESA(%)
Düşük	46.63	63.21	77.18	81.81
Orta	48.18	59.77	74.00	79.49
Yüksek	44.64	55.93	72.52	80.36

Karşılaştırma tablosuna göre aynı özneliklerle yapılan sınıflandırıcı performansları arasında ESA yüksek başarı oranına sahiptir. LDA ve QDA eğitim ve test 1-2sn arasında sürerken *k*-NN 80-90 sn sürmektedir. ESA yöntemi başarısının yanı sıra eğitim için 10-12 dakika ve 5.81sn ile tüm test verisi sınıflandırma süresi (0.015 sn tek örnek) gerektirmektedir. Bu yöntem ile tek kuvvet için yapılmasına karşı çok kuvvet seviyeli çalışmalarda da başarıyı artırabileceği öngörülmektedir. Böylece diğer çalışma ve araştırmalara zemin hazırlaması planlanmaktadır.

V. SONUÇLAR

Bu çalışmada, 8 kanallı elektromiyografi (EMG) sinyallerinin sınıflandırılmasında başarı ile kullanılan karekök ortalama (KO) ve dalga formu uzunluğu (DFU) özneliklerinin evrimsel sinir ağları (ESA) ile kombinasyonu neticesinde doğruluk değeri artırılmıştır. Ampute katılımcılardan çıkarılan aynı öznelikler ile doğrusal ayırmacılık analizi ve en yakın komşu algoritmaları gibi yöntemlere kıyasla aynı sınıf içi (düşük, orta ve yüksek) %30-40 ve %4-8 gibi artış sağlamıştır. Bu yöntemin karışık kuvvet seviyeleri ampute bireylerdeki kayıp uzuvlardaki sınıflandırma performansını da artırması beklenmektedir.

KAYNAKLAR

- [1] D. S. Naidu, C.-H. Chen, A. Perez, and M. P. Schoen, "Control strategies for smart prosthetic hand technology: An overview," 2008 30th Annu. Int. Conf. IEEE Eng. Med. Biol. Soc., pp. 4314-4317, 2008.
- [2] A. Phinyomark, F. Quaine, S. Charbonnier, C. Serviere, F. Tarpin-Bernard, and Y. Laurillau, "EMG feature evaluation for improving myoelectric pattern recognition robustness," *Expert Syst. Appl.*, vol. 40, no. 12, pp. 4832-4840, 2013.
- [3] R. Chowdhury, M. Reaz, M. Ali, A. Bakar, K. Chellappan, and T. Chang, "Surface Electromyography Signal Processing and Classification Techniques," *Sensors*, vol. 13, no. 9, pp. 12431-12466, 2013.
- [4] M. Zardoshti-Kermani, B. C. Wheeler, K. Badie, and R. M. Hashemi, "EMG Feature Evaluation for Movement Control of Upper Extremity Prostheses," *IEEE Trans. Rehabil. Eng.*, 1995.
- [5] A. Phinyomark, R. N. Khushaba, and E. Scheme, "Feature extraction and selection for myoelectric control based on wearable EMG sensors," *Sensors (Switzerland)*, 2018.
- [6] M. Atzori et al., "Characterization of a benchmark database for myoelectric movement classification," *IEEE Trans. Neural Syst. Rehabil. Eng.*, 2015.
- [7] M. Atzori, M. Cognolato, and H. Müller, "Deep learning with convolutional neural networks applied to electromyography data: A resource for the classification of movements for prosthetic hands," *Front. Neurobot.*, 2016.

- [8] A. Ameri, M. A. Akhaee, E. Scheme, and K. Englehart, "Real-time, simultaneous myoelectric control using a convolutional neural network," *PLoS One*, 2018.
- [9] A. Phinyomark and E. Scheme, "EMG Pattern Recognition in the Era of Big Data and Deep Learning," *Big Data Cogn. Comput.*, 2018.
- [10] K. H. Park and S. W. Lee, "Movement intention decoding based on deep learning for multiuser myoelectric interfaces," in 4th International Winter Conference on Brain-Computer Interface, BCI 2016, 2016.
- [11] Y. Du, W. Jin, W. Wei, Y. Hu, and W. Geng, "Surface EMG-based inter-session gesture recognition enhanced by deep domain adaptation," *Sensors (Switzerland)*, 2017.
- [12] U. Côtéallard et al., "A Convolutional Neural Network for robotic arm guidance using sEMG based frequency-features," in IEEE International Conference on Intelligent Robots and Systems, 2016.
- [13] X. Zhai, B. Jelfs, R. H. M. Chan, and C. Tin, "Self-recalibrating surface EMG pattern recognition for neuroprosthesis control based on convolutional neural network," *Front. Neurosci.*, 2017.
- [14] A. H. Al-Timemy, R. N. Khushaba, G. Bugmann, and J. Escudero, "Improving the Performance Against Force Variation of EMG Controlled Multifunctional Upper-Limb Prostheses for Transradial Amputees," *IEEE Trans. Neural Syst. Rehabil. Eng.*, vol. 24, no. 6, pp. 650-661, 2016.
- [15] J. M. Fajardo, O. Gomez, F. Prieto, "EMG hand gesture classification using handcrafted and deep features", *Biomedical Signal Processing and Control*, 63:102210.