

# EMG Sinyallerinin Derin Öğrenme ile Hareket Sınıflandırması

## Motion Classification of EMG Signals with Deep Learning

Gazi Akgün<sup>1</sup>, Alper Yıldırım<sup>1</sup>, Uğur Demir<sup>1</sup>, Erkan Kaplanoğlu<sup>2</sup>

<sup>1</sup> Teknoloji Fakültesi

Mekatronik Mühendisliği Bölümü

Marmara Üniversitesi, İstanbul

gazi.akgun@marmara.edu.tr, yildirim.alper@marmara.edu.tr, udemir@marmara.edu.tr

<sup>2</sup> College of Engineering and Computer Science,

Mechatronics Engineering

University of Tennessee at Chattanooga, Tennessee, USA

erkan-kaplanoglu@utc.edu

### Özetçe

Bu çalışmada EMG sinyalleri üzerinde öznitelikler hesaplanmıştır. Bu öznitelikler ile el hareketlerini sınıflandırmak için derin öğrenme algoritmaları kullanılmıştır. Bir zaman serisi olarak toplanan EMG sinyalleri üzerinde zaman alanında hesaplanan öznitelik vektörleri belirli boyutlarda simetrik matrisler olarak kaydedilmiştir. Yeniden oluşturulan ve resim dosyası formatında kaydedilen veri seti ile Evrişimsel Sinir Ağı eğitilmiştir. Bu eğitim sonucunda tüm veriler ile %93, test verileri ile %79 başarı ile hareket sınıflandırması gerçekleştirilmiştir.

### Abstract

In this study, the statistical features are calculated with EMG signals. Deep learning algorithms are used to classify hand gestures with these features. The feature vectors calculated in the time domain using the EMG signals recorded as a time series are stored as symmetric matrices with specific sizes. The data set that is rebuilt and saved as image file format is used to train the convolutional neural network. Thereafter the training, motion classification is carried out with a success rate of 93% for all data and 79% for test data.

### 1. Giriş

İnsanın günlük yaşantısında ihtiyaçlarını karşılamak için yaptığı eylemlerde el fonksiyonunun önemi çok yüksektir. Elde yaşanan fonksiyonel kayıplar ya da oluşan hareket kısıtları insanın yaşam kalitesini çok fazla etkilemektedir. Eli etkileyen hastalıkların biyomekanik tedavisinde biyomekatronik yapıları robotlar kullanılabilir [1]. Ayrıca ampute edilmiş elin fonksiyonları maksimum düzeyde yerine getirmek için akıllı el protezleri yaygın bir şekilde kullanılmaya başlanmıştır [2, 3]. Biyomekatronik bir yaklaşımla tasarlanan bu robotik sistemler elektrik motorları, pnömatik eyleyiciler, mikro-eyleyiciler gibi bileşenler içermektedir. Bu eyleyiciler rehabilitasyon sistemlerinde eli iyileştirmek için elin terapötik rehabilitasyon süreçlerini yönetirken, akıllı el protezlerinde elin temel fonksiyonlarını yerine getirmek için tasarlanan mekanizmaları manipüle etmektedirler [4].

Tüm bu biyomekatronik sistemler için hareketi başlatan kontrol sinyallerine ihtiyaç duyulur. El biyomekanik olarak oldukça kompleks bir yapıya sahiptir. Sağlıklı bir elin sinir sistemi de bir o kadar karmaşık ve üzerinden bilgi toplanması zordur. Robotik bakış açısından incelendiğinde insan elinin 20 serbestliğe sahip olduğu söylenebilir. Tüm bu karmaşık yapıyı kontrol eden kasların kontrolü de bir o kadar karmaşık sinir sistemi yapısı ile gerçekleşir [5].

Ampute olmuş ya da fonksiyonel özelliklerini yitirmiş bir eli kontrol etmekte olan kas gruplarından toplanan elektromiyogram (EMG) sinyalleri, elin o andaki hareketi, jesti ile doğrudan ilişkilidir [6].

EMG sinyalleri yüzeysel elektrotlar ile toplanabildiği gibi, invazif elektrotlar ile doğrudan kas dokusu içinden de toplanabilir. EMG işaretleri kasılma sonucu birçok kas lifinde oluşan biyopotansiyel işaretin toplamı olarak ölçülebilmektedir. Önkolda bulunan birçok kas grubu aynı anda veya ayrı zamanlarda elin kompleks hareketleri sırasında kasılmaktadır [7].

Önkoldan toplanan EMG sinyallerinin elin yaptığı hareket veya jesti ile olan ilişkisi arasındaki derin ve karmaşık ilişkiyi çözmek için sınıflandırma çalışmaları yapılmaktadır. Sınıflandırmada amaç kaslardan alınan EMG sinyalinin hangi el hareketi sırasında toplandığını kestirilmesidir. Bunun için yüksek derecede gürültü içeren EMG sinyalinin filtrelendikten sonra sınıflandırılması ve uygun sinyalin uygun kavrama ile eşleştirilmesi gerekmektedir. Sınıflayıcı tasarımı için sezgisel yaklaşım, belirgin yaklaşım, istatistiksel yaklaşım, yapay sinir ağları yaklaşımı ve bulanık mantık yaklaşım gibi pek çok yöntem önerilmiştir [8, 9].

Derin öğrenme algoritmaları daha çok bilgisayarlı gözü, otonom sürüş, optik karakter tanıma, doğal dil işleme gibi amaçlar için kullanılmaktadır [10, 11]. Konvolüsyon temelli yapısı işaretin çok boyutlu alt katmanlarında bulunan özelliklerini kullanabilmesi açısından evrişimsel sinir ağı algoritmaları karmaşık veri yapılarındaki örüntüleri kestirebilmesini sağlamaktadır [12].


Tsiangos ve ark. CNN temelli, EMG işareti ile el hareketi sınıflandırma çalışmalarını incelemiş ve önerdikleri derin öğrenme metodu ile sınıflandırma başarısını %3 artırmışlardır [13]. Morbidoni ve ark. alt ekstremitayı kontrol eden sekiz farklı kas grubundan topladıkları EMG işaretleri ile eğittikleri

evrimsel sinir ağı ile %93 yürüyüş fazı sınıflandırma başarısına ulaşılmıştır [14]. Phinyomark ve ark. çalışmalarında derin öğrenme ve büyük veri yaklaşımı ile EMG işaret işleme ve sınıflandırmayı tartışmışlardır [15]. Buongiorno ve ark. EMG işaret işleme ve derin öğrenme ile ilgili bir inceleme çalışması yapmışlardır. Bu çalışma el hareketi tanıma, uyku fazları kestirme, konuşma ve duyu durumu sınıflandırma gibi çalışmaları incelemiştir [16]. Xiong ve ark. çalışmalarında EMG örüntü tanıma ile hareket sınıflandırmasını, eklem hareket açıklığı kestirimi gibi konulara derin öğrenme temelli bir yaklaşım ile incelemiştir [17].

Bu çalışmada sağlıklı bireylerden farklı hareketler sırasında kaydedilen EMG verileri üzerinde zaman alanında öznelikler hesaplanarak elde edilen öznelik vektörleri derin öğrenme algoritmaları ile sınıflandırılmıştır. Materyal ve Metot bölümünde, kullanılan EMG verileri ile ilgili bilgi verilmiş ve önerilen sınıflandırma metodu anlatılmıştır. Bulgular ve tartışma bölümünde eğitilen ağıın performansı tartışılmış ve sonuçlar anlatılmıştır.


## 2. Materyal ve Metot

Katılımcılardan dokuz farklı el ve ön kol hareketi sırasında üç farklı kas grubundan yüzeysel elektrotlar ile toplanan ve birleştirilen veriler Şekil 1’de görüldüğü gibidir.



Şekil 1- Toplanan EMG verileri

Verilerin toplanması sırasında yüzeysel EMG sensörleri Şekil-2 de görüldüğü gibi fleksör, ekstansör ve brakiradialis kas gruplarından veri toplayacak şekilde bağlanmıştır.



Şekil 2- Elektrotları yerleşimi

Bu verileri 9 farklı hareket için kaydedilmiş olup bu hareketler Tablo 1 ‘de verilmiştir. Veriler Tablo 1 de görülen etiketler ile her bir hareket/jest sınıfı için etiketlenmiştir. Şekil 1’ de görülen

verilerin toplanması sırasında katılımcılar {9-1-9-2-9-3-9-4-9-5-9-6-9-7-9-8-9} hareketlerini yapmışlardır. Her bir el ve önkol hareketinin arasında “Serbest” sınıfının olmasının hareket sınıflandırma başarısını artıracakları öngörülmüştür.

Tablo 1. Hareket Sınıfları

Hareket Sınıfı	Etiket
El Fleksiyonu	1
Bilek Fileksiyonu	2
Güçlü Bilek	3
Fileksiyonu	
Palmar Fleksiyon	4
Palmar	5
Ekstansiyon	
Radyal Deviasyon	6
Ulnar Deviasyon	7
El Kapalı	8
Serbest	9

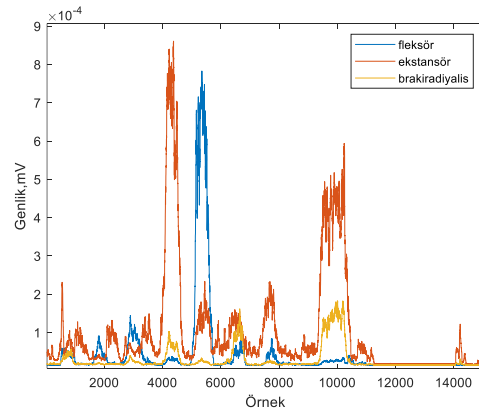
## 2.2 Önerilen Algoritma Akışı

Zaman alanında kaydedilen EMG sinyallerinin hareket sınıflandırılması için Şekil 4’te görülen algoritma önerilmektedir. EMG işareti, kaydındaki zorluklar ve elektrofizyolojik özellikleri bakımından durağan olmayan yapıdadır. İşlenmemiş işaret öncelikle bir önışlemeden geçirilerek öznelikleri çıkarılabilir duruma getirilmelidir.

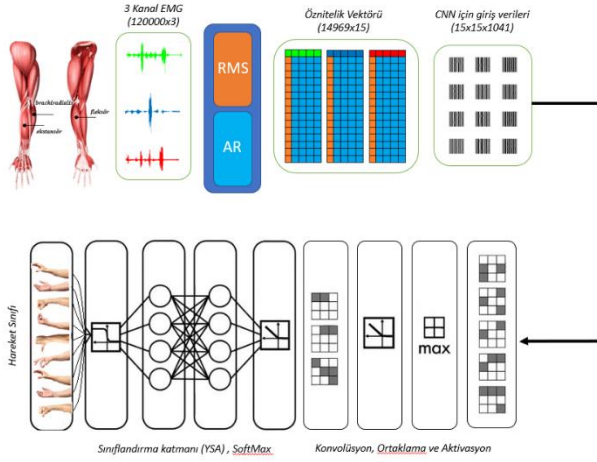
Englehart ve diğerleri daha kısa segmentlere ayrılmış sinyalin sınıflandırmada daha az bozulmaya neden olduğunu göstermiştir. Çerçevesiz ayrılan sinyalin çerçeveleme oranı ne kadar küçük olursa hata o kadar az olmaktadır [8].

Rastgele sayıda elemana sahip bir zaman dizisi olan miyoelektrik sinyalleri sınıflandırma işlemi için pratik değildir. Bu nedenle sinyal dizilerinin öznelik denilen vektörlere eşlenmesi gerekir. Öznelikler zaman, frekans ve zaman-frekans alanlarında hesaplanabilir. Bu çalışmada zaman alanında üç kanal olarak kaydedilen EMG sinyalleri belirli çerçeve boyutlarında zaman boyunca çerçeveleştirilerek segmente edilmiş ve her bir segment için öznelikler hesaplanmıştır.

Bu çalışmada toplamda 120000 veri içeren veri seti üzerinde, sırasıyla her bir işaret segmenti için etkin değer (RMS) (Şekil 3) ve 4. dereceden öz-bağlanım vektörü hesaplanmıştır. Bu öznelikler 256 örnek pencere ve 8 örnek kayma parametresi ile hesaplandığında 14969x15 boyutlarında bir öznelik matrisi elde edilmiştir (Şekil 4).




Şekil 3- Etkin Değer (RMS) Özneliği Zaman Grafiği




Şekil 4- Yüzeysel EMG elektrotlarından toplanan ham EMG sinyali

Elde edilen öznelik matrisi yine üs-tüste çerçeveleme metodu kullanılarak 15x15'lik kare matrisler olarak kesilmiştir. Elde edilen ve yaklaşık 1.92 sn'lik aralık için bilgi içeren öznelik matrisinin bir örneği Şekil 5'te görülmektedir. Beşer sütun kaydırılarak elde edilen matrisler "png" uzantılı görüntü dosyaları olarak kaydedilmiştir. Toplamda etiketlenmiş 1041 adet matris görüntüsü elde edilmiştir.



Şekil 5- 15x15 öznelik matrisi

1041 adet "png" uzantılı görüntü dosyası olarak kaydedilen öznelik matrislerinden oluşan veri setinin bir kısmı Şekil 6'da görülmektedir.



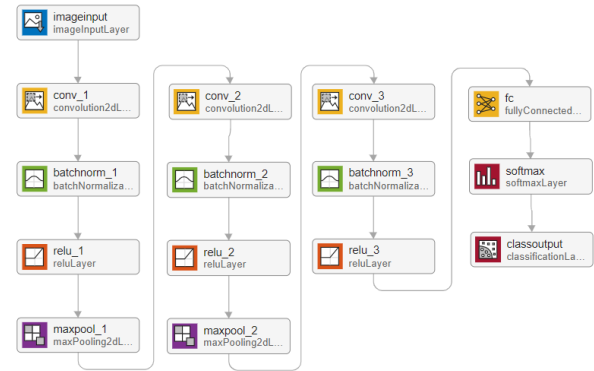
Şekil 6- Öznelik matrislerinden oluşan veri seti

Her bir hareket sınıfı için öznelik görüntüsü sayıları Tablo 2'de verilmiştir.

Tablo 2. Her bir hareket sınıfı için örnek öznelik görüntüsü sayıları

Etiket	Örnek Sayısı
'1'	104
'2'	90
'3'	115
'4'	102
'5'	127
'6'	85
'7'	95
'8'	222
'9'	101

Sonraki adımda öznelik görüntüleri eğitim, test ve doğrulama verileri olarak ayrılmış ve mimarisi Şekil 7'de görülmekte olan Evrişimsel Sinir Ağı (ESA)'nı eğitmek için kullanılmıştır.



Şekil 7- ESA Mimarisi

### 2.3 Evrişimsel Sinir Ağı

Genel olarak görüntü sınıflandırma, bölütleme ve nesne tanıma ya da veri üzerinde örüntü tanıma amaçları ile kullanılan evrişimsel sinir ağları konvolüsyon işlemi temelli bir yaklaşımdır. Konvolüsyonda temel mantık belirli bir çekirdek fonksiyonunun ( $h(x, y)$ ) görüntü matrisi ( $f(x, y)$ ) üzerinde denklem 1 de verildiği gibi teker teker piksellerin çarpımlarının toplamı işlemidir [18].

$$h(x, y) * f(x, y) = \sum_{s=-a}^a \sum_{t=-b}^b h(s, t) f(x-s, y-t)$$

Burada  $h$  çekirdek fonksiyonu,  $f$  görüntü (kaynak) matrisi  $a, b$  çekirdek fonksiyonunun boyutlarıdır. Seçilen çekirdek fonksiyonunun yapısında göre bu işlem matris üzerinde ayrık zamanlı türev, laplasyen gibi sonuçlar üretir. Her bir konvolüsyon katmanında birden fazla farklı çekirdek fonksiyonu ile CNN için öznelikler hesaplanır. Bu işlemler sonucu elde edilen öznelik vektörleri çoğu zaman görüntü matrisindeki çok temel bilgileri içerir. CNN algoritmasında bu temel bilgileri nispeten daha büyük matrisler içinde içeren

öznitelik matrisleri maksimum, minimum, ortalama gibi işlemler ile ortaklama (pooling) konvolüsyon katmanından geçirilir. Bir sonraki katman ise hesaplanmış ve ortaklanmış öznitelikler üzerinde seçilmiş olan aktivasyon fonksiyonlarını uygulamaktır. Tüm bir konvolüsyon-ortaklama ve aktivasyon katmanları birden fazla defa kaskat olarak çalıştırılarak görüntü matrisinde daha derin bilgiler çıkarılabilir [19].

Tüm konvolüsyon-ortaklama ve aktivasyon katmanlarından sonra elde edilen son matrisler sınıflandırma amacıyla inşa edilen yapay sinir ağı katmanından geçirilerek sınıflandırma işlemi yapılır.

### 3. Bulgular ve Tartışma


Gerçekleştirilen eğitim için seçilen parametreler Tablo 3'te verildiği gibidir.

Tablo 3. CNN Eğitim Parametreleri

Parametre	Seçim
En-iyileme metodu	'rmsprop'
Maksimum döngü	1200
Verileri Karıştır	Her döngüde
Validasyon Frekansı	10 iterasyonda
Başlangıç öğrenme oranı	0.01
Öğrenme oranı düşme faktörü	0.1
MiniBatch boyutu	128

Buna göre eniyileme için seçilen 'rmsprop' "root mean square propagation" öğrenme algoritmasıdır. Eğitim maksimum 1200 döngü sürecek ve her 10 iterasyonda bir, daha önceden ayrılmış olan validasyon veri seti ile doğrulama yapılacaktır. Başlangıçta öğrenme oranı 0.01 olarak belirlenecek ve periyotlar boyunca %10 düşecektir. Her bir iterasyon için kullanılacak alt örnek sayısı ise 128'dir.

Yapılan eğitim sonucunda Şekil 7'de görüldüğü gibi validasyon doğruluk değeri %76.09 olmuştur. Eğitim ve validasyon değerleri için doğruluk değeri %93.66 olarak hesaplanmıştır.



Şekil 7- Eğitim Grafikleri

Tablo 4'te eğitim ve validasyon verilerinin kesinlik ve duyarlılık değerleri ile toplam doğruluk değeri yapılan test boyutunda incelenebilmektedir.

Tablo 4. Hata Matrisi

Gerçek Sınıf	Kestirilen Sınıf									Duyarlılık
	1	2	3	4	5	6	7	8	9	
1	103	1	2							0,98
2		89			1					0,99
3	6		105		4					0,91
4				100				2		0,98
5	2	3	2		117	1	1	1		0,92
6						85				1
7						3	92			0,97
8				26		8	3	182	3	0,82
9									101	1
Kesinlik	0,93	0,96	0,96	0,79	0,96	0,89	0,96	0,98	0,97	0,93

Hata matrisinde de görüldüğü gibi Palmar fleksiyon (4) hareketinde kesinlik değeri %79 'da kalmıştır. Palmar fleksiyon hareketine karışan diğer sınıfın el kapalı (8) sınıfı olduğu görülmektedir. Bu durumun bu iki el hareketi sırasında aynı kas gruplarının kasılması sonucu ortaya çıkmasından kaynaklandığı sonucu kolaylıkla çıkarılmaktadır. Bunun dışında eğitilen ağın palmar ekstansiyon (5) hareket sınıfına olan duyarlılığı %92 'lerde olmasına rağmen yanlış sınıf tahminleri diğer tüm sınıflara dağılmıştır. Bunun nedeninin de palmar ekstansiyon hareketinin ağırlıklı olarak brakiradialis kasının kasılması sonucu oluşmasından kaynaklandığı yorumlanabilmektedir.

### 4. Sonuçlar

Bu çalışmada 3 farklı kas gurubundan yüzeysel elektrotlar ile toplanan EMG işaretlerinin derin öğrenme algoritmaları yardımıyla hareket sınıflandırılması yapılması hedeflenmiştir. Zaman ekseninde kaydedilen veriler üzerinde yapılan öznitelik çıkarma işlemi sonucunda elde edilen matrisler öznitelik görüntüleri olarak kaydedilmiş ve derin öğrenme algoritması bu veriler ile eğitilmiştir. Yaklaşık 1.92 sn lik periyotlarda %90'ın üzerinde doğruluk ile hareket sınıfları tahmin edilmiştir.

### Kaynakça

- [1] Johan, N., Axel, S., Edmar, C., Daryl, C., Edward, R., Álvaro, F., ... & Leonardo, M. C. (2020). Preliminary design of an intention-based semg-controlled 3 dof upper limb exoskeleton for assisted therapy in activities of daily life in patients with hemiparalysis, 2020 8th IEEE RAS/EMBS International Conference for Biomedical Robotics and Biomechatronics (BioRob).
- [2] Fajardo, J., Maldonado, G., Cardona, D., Ferman, V., & Rohmer, E. (2021). Evaluation of User-Prosthesis-Interfaces for sEMG-Based

- Multifunctional Prosthetic Hands. *Sensors*, 21(21), 7088..
- [3] U. O. A. G. Kaplanoğlu E., *Biyomekatronik Sistemlere Giriş*, Papatya Yayıncılık, 2017.
- [4] Atasoy, A., Kaya, E., Toptas, E., Kuchimov, S., Kaplanoglu, E., & Ozkan, M. (2016, August). 24 DOF EMG controlled hybrid actuated prosthetic hand. In 2016 38th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC).
- [5] Çapa, E., Çotur, Y., Gümüş, C., Kaplanoğlu, E., & Özkan, M. (2014, October). Comparative EMG classification of index finger. In 2014 18th National Biomedical Engineering Meeting (pp. 1-3). IEEE..
- [6] Inam, S., Al Harmain, S., Shafique, S., Afzal, M., Rabail, A., Amin, F., & Waqar, M. (2021, April). A brief review of strategies used for EMG signal classification. In 2021 International Conference on Artificial Intelligence (ICAI) (pp. 140-145). IEEE..
- [7] Hickman, S. D. (2014). Classification of Surface EMG Signals with Respect to Percent Maximum Voluntary Contraction Using Artificial Neural Networks..
- [8] Englehart, K., Hudgin, B., & Parker, P. (2001). A wavelet-based continuous classification scheme for multifunction myoelectric control. *Biomedical Engineering, IEEE Transactions on*, 48(3), 302-311..
- [9] Ali, A. R. I., Furkan, A. Y. A. Z., & Hanbay, D. (2019). EMG sinyallerinin kısa zamanlı fourier dönüşüm özellikleri kullanılarak yapay sinir ağları ile sınıflandırılması. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 31(2), 443-451..
- [10] Craik, A., He, Y., & Contreras-Vidal, J. L. (2019). Deep learning for electroencephalogram (EEG) classification tasks: a review. *Journal of neural engineering*, 16(3), 031001..
- [11] Ismail Fawaz, H., Forestier, G., Weber, J., Idoumghar, L., & Muller, P. A. (2019). Deep learning for time series classification: a review. *Data mining and knowledge discovery*, 33(4), 917-963..
- [12] Wu, H., Huang, Q., Wang, D., & Gao, L. (2018). A CNN-SVM combined model for pattern recognition of knee motion using mechanomyography signals. *Journal of Electromyography and Kinesiology*, 42, 136-142..
- [13] Tsinganos, P., Cornelis, B., Cornelis, J., Jansen, B., & Skodras, A. (2018, September). Deep Learning in EMG-based Gesture Recognition. In *PhyCS* (pp. 107-114)..
- [14] Morbidoni, C., Cucchiarelli, A., Fioretti, S., & Di Nardo, F. (2019). A deep learning approach to EMG-based classification of gait phases during level ground walking. *Electronics*, 8(8), 894..
- [15] Phinyomark, A., & Scheme, E. (2018). EMG pattern recognition in the era of big data and deep learning. *Big Data and Cognitive Computing*, 2(3), 21..
- [16] Buongiorno, D., Cascarano, G. D., De Feudis, I., Brunetti, A., Carnimeo, L., Dimauro, G., & Bevilacqua, V. (2021). Deep learning for processing electromyographic signals: A taxonomy-based survey. *Neurocomputing*, 452, 549-565..
- [17] Xiong, D., Zhang, D., Zhao, X., & Zhao, Y. (2021). Deep learning for EMG-based human-machine interaction: A review. *IEEE/CAA Journal of Automatica Sinica*, 8(3), 512-533..
- [18] Kiranyaz, S., Avci, O., Abdeljaber, O., Ince, T., Gabbouj, M., & Inman, D. J. (2021). 1D convolutional neural networks and applications: A survey. *Mechanical systems and signal processing*, 151, 107398..
- [19] Michelucci, U. (2019). *Advanced applied deep learning: convolutional neural networks and object detection*. Apress..