

# Derin Öğrenme ile Motor Hayal Hareketlerinin Analizi

## Analysis of Motor Imaginary by Deep Learning

Erdem Erkan<sup>1</sup>, İsmail Kurnaz<sup>2</sup>

<sup>1</sup> Uzaktan Eğitim Uygulama ve Araştırma Merkezi Bartın Üniversitesi  
erdemerkan@bartin.edu.tr

<sup>2</sup> Bilgisayar Mühendisliği Bölümü Karabük Üniversitesi  
ikurnaz@karabuk.edu.tr

### Özet

Beyin hücreleri arasındaki iletişimin elektriksel temelini oluşturan EEG (Elektroensefalografi) sinyallerinin analizi, insan beyninin mükemmel yapısının işleyişine ışık tutmakta ve bu alanda yapılan her çalışma ile hakkında daha fazla şey öğrenilen bu organ için, yeni arayüzler geliştirmenin kapılarını aralamaktadır. Bu arayüzler kimi zaman ALS hastalarının dış dünya ile iletişim kurmalarını olanaklı hale getirirken, kimi zaman da bilgisayarlara kas sistemlerimizi kullanmadan, daha hızlı ve daha etkin hükmetme imkânı sunmaktadır. Düşük sinyal gürültü oranına sahip olan EEG sinyalleri genel olarak kanal belirleme, filtreleme, alt örnek-leme, normalizasyon, özellik çıkarımı gibi işlemlerden sonra sınıflandırma işlemine tabi tutularak analiz edilmektedir. Bu çalışmada beyin sinyallerine daha farklı bir yaklaşım getirilmiş ve analiz aşamalarını tek bir safhada çözümleyen ve günümüzde daha çok görüntü işlemede kullanımıyla öne çıkan hızlandırılmış yapay sinir ağı, derin öğrenme, yöntemi EEG sinyallerine uygulanmıştır. Önerilen yöntem ile %80 oranında bir sınıflandırma başarısı elde edilmiştir.

### Abstract

Analysis of EEG signals, which forms the electrical basis of communication between brain cells, illuminates the mechanism of this great structure of brain and it opens the door to development of new interfaces for the organ which we learn about more by each study in this area. These interfaces are sometimes making it possible to communicate in ALS patients, sometimes possible to use our computer, faster and more efficient without using our muscular systems. EEG signals have low signal to noise ratio, This signals generally analysis by channel selection, filtering, down sampling, normalization, feature extraction etc. In this study deep learning method (accelerated artificial neural network) which uses in image processing was applied to EEG signals by having different approach. It's obtained that 80% success in classification by the proposed method.

### 1. Giriş

EEG ve ECoG (Electrocorticography) beyin bilgisayar arayüz (BBA) sistemlerinde kullanılan en yaygın sinyal türleridir. Bu sinyaller, beyin içindeki birçok nöronun ateşlenmesiyle oluşur. Sonuçta, aynı etki ile oluşan bu sinyallerden EEG sinyallerinin elde edilmesi daha kolay ve güvenli iken, çözünürlüğü daha yüksek olan ECoG sinyallerinin elde edilmesi daha riskli ve zordur [1].

Günümüzde popülerliği her geçen gün artan derin öğrenme, makine öğrenme yöntemlerinden yapay sinir ağlarını temel alan bir yöntemdir. Google, Facebook, Microsoft gibi firmalar bu makine öğrenme yöntemi üzerinde yoğun çalışmalar yürütmektedir [2, 3, 4]. Günümüzde, derin öğrenme, başta görüntü tanıma olmak üzere video analizi, konuşma tanıma vb. alanlarda başarımı yüksek bir yöntem olarak karşımıza çıkmaktadır. Örnek olarak; yüz tanımda denektaşı testi olarak bilinen LFW (Label Face in Wild) veri kümesi ile oluşturulan yüz tanıma ağı insan başarısının üstüne çıkmayı başarmıştır. İnsanın bu veri kümesindeki başarısı, %97.53 iken Google araştırma grubunun 2015 yılındaki yayınında, yüz tanıma başarısı %99.63 olarak raporlanmıştır [5, 6].

Geleneksel öğrenme yöntemlerinde matematiksel temelli yöntemlerle elde edilen öznitelik vektörleri, yine bilinen sınıflandırma yöntemleriyle sınıflandırmaya tabi tutulurken, derin öğrenme ile önceden belirlenmiş bir matematiksel modele ihtiyaç duyulmamaktadır. Uygun öznitelikler sisteme girilen veri setinden otomatik olarak öğrenilmektedir.

Derin öğrenme yöntemlerinin bir diğer avantajı ise, genelleştirilebilir olmasıdır. Bir probleme yönelik tasarlanan derin öğrenme ağı başka bir problem üzerinde de kullanılabilir. En büyük dezavantajı ise, çok fazla sayıda eğitim verisine ihtiyaç duymasıdır.

Yapılan bu çalışmada; iki veya daha çok boyutlu veri kümelerinde, özellikle de görüntü verilerinde yaygın olarak kullanılan derin öğrenme yöntemi, bir boyutlu EEG verisi içeren ECoG (Electrocorticography) beyin sinyallerine uygulanmıştır. Tasarlanan derin yapay sinir ağı, EEG sinyalinin elde edildiği kanallar (elektrot) bir boyut ve o kanala ait üç saniyelik sinyal diğer bir boyut olmak üzere, bu iki boyutlu verinin oluşturduğu örüntü, derin öğrenme ağına eğitim ve test verisi olarak verilmiştir. Geleneksel BBA sistemlerindeki öznitelik çıkarma aşamasının ağ ile otomatikleştirilmesiyle daha etkin bir sınıflandırma yapılmıştır. Eğitim setinin daha fazla olduğu durumlarda daha başarılı sınıflandırma sonuçlarının elde edilmesi öngörülmektedir.

### 2. EEG Sinyal Analizi


BBA sistemlerinde, hazır veri veya özgün veri setleri kullanılabilir. Kullanılan veri setinin özgünlüğü, her ne kadar çalışmanın özgünlüğünü artırsa da yüksek maliyetli veri toplama cihazları ve veri toplama süreçleri, ilk olarak araştırmacıları hazır veri setlerine yönlendirmektedir.

## 2.1. Kullanılan Veri Seti

Kullanılan veri seti; 2005 yılında üçüncüsü düzenlenen Beyin Bilgisayar Arayüzü yarışmasında (BCI Competition III) kullanılan ve Almanya'nın Tübingen Üniversitesi tarafından sağlanan veri setidir (Dataset1). Veri seti 64 elektrotla kaydedilmiştir. Veri setinde denegin 139 el ve 139 parmak resmine karşı ürettiği beyin sinyalleri 1000 Hz örnekleme frekansı ile her bir deneme 3 sn olacak şekilde kaydedilmiştir. Yarışmada toplam 278 adet el ve parmak denemesinin sınıflandırmada eğitim verisi olarak kullanılması istenmiş, bunun haricinde verilen ve ne olduğu bilinmeyen 100 adet denemenin sonucunun tahmin edilmesi istenmiştir. Yarışma sonucunda; Tsinghua Üniversitesinden Qingguo Wei ve ekibi %91 doğruluk oranıyla 27 katılımcı arasından en yüksek sınıflandırma başarısını göstermiştir [7].

## 2.2. Sinyal Ön İşleme

Uyanık insanlarda, duygusal girdilere maruz kalınmaz ve motor hareketlerin üretilmediği durumlarda, 8-12 Hz aralığında EEG sinyalleri gözlenmektedir ve bu durumda elde edilen sinyallere mü ritmi adı verilmektedir. 18-26 Hz arasında olanlara beta ritmi adı verilmektedir. Hareket veya harekete hazırlık evrelerinde mü ve beta ritimlerinde azalma gözlemlenmektedir. İlgili frekansları beraberce gözlemek için 4. Dereceden Butterworth band geçiren bir filtre kullanılmıştır. Tasarlanan filtre ile sinyal 8-26 Hz arası filtrelenmiş, filtreleme öncesinde ise sinyalin DC bileşeni bastırılmıştır. Üç saniye ve 1000 Hz örnekleme frekansına sahip EEG verisi daha önceki çalışmamızdaki gibi 4. Derecen wavelet transformu ile 188 adet örnekli bir sinyale dönüştürülmüştür [8]. Sinyal ön işleme sonrası elde edilmiş örnek bir sinyal Şekil 1 ile verilmiştir.



Şekil 1. 12. Kanala ait dil resmine karşılık üretilen EEG sinyali.


## 2.3. Derin Öğrenme Ağının Yapısı

Derin öğrenme için 6 katmanlı bir ağ yapısı tasarlanmıştır. Ağ Matlab R2015a ortamında matconvnet kütüphanesi ile oluşturulmuştur. Tasarlanan ağın katmanları Şekil 2 ile, genel yapısı ise Şekil 3 ile verilmiştir.

Her biri 64 kanaldan oluşan 278 adet el ve parmak resmine karşılık üretilmiş EEG verisi 188 örneğe alt örneklenmiş olarak 64x188 lik bir yapıda ağın girişine verilmiştir. İki boyutlu sinyal ilk olarak 9x9 boyutunda iki adet filtre ile konvolüsyon işlemine girmekte sonrasında 7x7 lik filtre ile maksimum havuzlama (max pooling) yapılmaktadır. Havuzlamadan elde edilen sinyal relu (rectified linear unit) aktivasyon fonksiyonuna tabi tutulmaktadır. Aktivasyon fonksiyonları ile yapay sinir ağlarında


| layer      | 0      | 1      | 2    | 3        | 4    | 5       | 6       |
|------------|--------|--------|------|----------|------|---------|---------|
| type       | input  | conv   | pool | dropout  | relu | conv    | softmax |
| name       | n/a    | conv1  |      | dropout2 |      | fc1     |         |
| support    | n/a    | 9      | 7    | 1        | 1    | 8x25    | 1       |
| filt dim   | n/a    | 1      | n/a  | n/a      | n/a  | 2       | n/a     |
| num filter | n/a    | 2      | n/a  | n/a      | n/a  | 2       | n/a     |
| stride     | n/a    | 1      | 7    | 1        | 1    | 1       | 1       |
| pad        | n/a    | 0      | 0    | 0        | 0    | 0       | 0       |
| rf size    | n/a    | 9      | 15   | 15       | 15   | 64x183  | 64x183  |
| rf offset  | n/a    | 5      | 8    | 8        | 8    | 32.5x92 | 32.5x92 |
| rf stride  | n/a    | 1      | 7    | 7        | 7    | 7       | 7       |
| data size  | 64x183 | 56x180 | 8x25 | 8x25     | 8x25 | 1       | 1       |
| data depth | 1      | 2      | 2    | 2        | 2    | 2       | 1       |
| data num   | 50     | 50     | 50   | 50       | 50   | 50      | 1       |
| data mem   | 2MB    | 4MB    | 78KB | 78KB     | 78KB | 400B    | 4B      |
| param mem  | n/a    | 656B   | 0B   | 0B       | 0B   | 3KB     | 0B      |

Şekil 2. Ağ yapısı.



Şekil 3. Ağın genel diyagramı.

doğrusallık giderilmektedir. Popüler olarak kullanılan aktivasyon fonksiyonları sigmoid or hiperbolik tanjant (hyperbolic tangent) aktivasyon fonksiyonlarıdır. Relu ve tanh aktivasyon fonksiyonlarının karşılaştırması Şekil 4 ile verilmiştir. Sigmoid fonksiyonu ise tanh fonksiyonunun ölçeklendirilmiş ve kaydırılmış versiyonudur [9]. Doğrusallığı giderilen sinyal tekrar 8x25 boyutlarında iki adet filtre ile softmaxloss katmanına gönderilmektedir. Softmaxloss katmanı yani türev katmanı, eğitim verisi etiketleriyle karşılaştırma yaparak ağı geri bildirim göndermekte ve ağın doğru eğitim eğilimini artırmaktadır. Havuzlamadan sonra eklenen dropout katmanı ile sinyal düzenliliği sağlanmaktadır.



Şekil 4. Relu ve tanh aktivasyon fonksiyonları [9].


Relu fonksiyonu Denklem 1 ile verildiği gibi ilgili değerler arasında aldığı en yüksek değeri döndürür [9].

$$f(x) = \max(0, x) \quad (1)$$


Şekil 5 ve Şekil 6 ile konvolüsyon ve havuzlama işlemlerine karşılık gelen örnek anlatımlar verilmiştir.

## 3. Bulgular

Çalışmada; invasive olarak elde edilmiş EEG sinyallerinin, geleneksel yöntemlerin dışında, başarısı ve popülerliği hızla artan derin öğrenme yöntemiyle tasarlanmış bir konvolüsyonel ağ ile sınıflandırma başarısı test edilmiştir. Şekil 7 ile ağın eğitim iterasyonlarına göre başarımı gösteren grafik sunulmuştur.



Şekil 5. Konvolüsyon işlemi.



Şekil 6. Havuzlama işlemi.

#### 4. Sonuçlar


Bu çalışma, derin öğrenme yöntemi ile EEG sinyallerinin sınıflandırmasının gerçekleştirildiği ilk çalışmalardan biridir. Derin öğrenme yönteminin kullanılmasıyla, önceki çalışmamızda [8] kullanılan geleneksel yöntemlerdeki kanal seçimi ve özellik çıkarımı gibi sınıflandırma basamakları, derin yapay sinir ağı tarafından gerçekleştirilmektedir. Toplam 278 adet eğitim verisinin eğitim ve doğrulama verileri sırasıyla %70 ve %30 olarak ayrılmış, ağı öğrenme oranı ise 0.0001 olarak belirlenmiştir. Tasarlanan ağı toplamda 200 iterasyonlu bir eğitime tabi tutulmuştur. farklı iterasyonlardaki test eğitim başarıları Çizelge 1 ile verilmiştir. 100 Adet test verisi üzerinde %80 oranında bir sınıflandırma başarıları sağlanmıştır. Derin öğrenme ağlarının ihtiyaç duyduğu eğitim veri sayısı göz önünde bulundurulduğunda, daha fazla eğitim verisine sahip veri setlerinde, daha iyi sonuçlar elde edileceği düşünülmektedir.

Çizelge 1. Farklı iterasyonlardaki eğitimle, test doğruluk oranları.

| İterasyon Sayısı | Test Başarısı % |
|------------------|-----------------|
| 50               | 65              |
| 100              | 70              |
| 150              | 80              |
| 200              | 75              |

#### 5. Kaynaklar

- [1] Wolpaw, J.R., Loeb, G.E., Allison, B.Z., Donchin, E., Nascimento, O.F., Heetderks, W.J., Nijboer, F., Shain, W.G., ve Turner, J.N., "BCI Meeting 2005 Workshop on Signals and Recording Methods", *IEEE Transactions on neural systems and rehabilitation engineering*, cilt no. 14(2), sf: 138-141, 2006.
- [2] Le, Q.V., Ranzato, M.A., Monga, R., Devin, M., Chen, K., Corrado, G.S., Dean ve J., Ng, A.Y., "Building High-Level Features Using Large Scale Unsupervised Learning", *In*



Şekil 7. Ağı eğitim iterasyonlarına göre hata oranları.

*Proceedings of the 29th International Conference on Machine Learning*, Edinburgh, 2012.

- [3] Taigman, Y., Yang, M., Rantazo, M.A., Wolf, L., "DeepFace: Closing the Gap to Human-Level Performance in Face Verification", *CVPR*, sf: 1701-1708, 2014.
- [4] Deng, L. ve Yu, D., "Deep Learning: Methods and Applications", *Foundation and Trends in Signal Processing*, cilt no. 7, sf: 197-387, 2014.
- [5] Huang, G.B., Ramesh, M., Berg, T. ve Learned-Miller, E., "Labeled Faces in the Wild: A Database for Studying Face Recognition in Unconstrained Environments", University of Massachusetts, Amherst, Technical Report 07-49, 2007.
- [6] Schroff, F., Kalenichenko, D. ve Philbin, J., "FaceNet: A Unified Embedding for Face Recognition and Clustering", *CVPR*, 2015.
- [7] Lal, T., Hinterberger, T., Widman, G., Schröder, M., Hill, J., Rosenstiel, W., Elger, C., Schölkopf, B. ve Birbaumer, N., "Methods Towards Invasive Human Brain Computer Interfaces", *NIPS*, 2004.
- [8] Kurnaz, İ., ve Erkan, E., "Classification of ElectroCorticoGraphy Signals Reduced by Wavelet Transform", *SİU*, 2016.
- [9] Toth, L., "PHONE RECOGNITION WITH DEEP SPARSE RECTIFIER NEURAL NETWORKS", *ICASSP*, 2013.