



Olaya İlişkin Potansiyelerde Derin Öğrenme ile Örüntü Sınıflandırması Classification of Event Related Potential Patterns using Deep Learning

Dilek Göksel Duru
İstanbul Arel Üniversitesi
İstanbul, Türkiye
dilekgokseldu@arel.edu.tr

Adil Deniz Duru
Marmara Üniversitesi
İstanbul, Türkiye
deniz.duru@marmara.edu.tr

Özetçe —Beyin elektriksel aktivitesi ölçümleri (Elektroensefalogram, EEG) kullanılarak kişinin bilişsel durumu izlenebilmektedir. Bu çalışmada EEG verileri kullanılarak, derin öğrenme ile beyin topografilerinin sınıflandırılması hedeflenmiştir. Bilişsel test bataryalarından olan Stroop testi (dört renkli) ile iki katılımcıdan toplanan EEG verisinden, P300 ve N400 bileşenleri iki sınıf olarak seçilmiştir. P300 topografisi uyaran sonrası 280 ile 320 ms arasındaki ortalama, N400 topografisi ise 380 ile 420 ms arasındaki ortalama ile hesaplanmıştır. EEG gürültü temizliğini takiben, 440 adet topografi imgesi derin öğrenmede eğitim için kullanılmıştır. Eğitim setinden olmayan ve rastgele seçilmiş 10 topografi ile test gerçekleştirilmiştir. Test için kullanılan tüm imgeler doğru olarak sınıflandırılırken, eğitim için kullanılan imgeler %73 doğrulukla bulunmuştur.

Anahtar Kelimeler—P300, N400, topografi, derin öğrenme

Abstract—Cognitive state of a person can be monitored by the use of brain electrical activity measurements (Electroencephalogram, EEG). In the concept of this study, it is aimed to classify EEG topographies using deep learning. Among the cognitive test paradigms, Stroop test with four colors is used to collect EEG from two participants. P300 and N400 components are selected as two classes. P300 topography is computed using the average of EEG from 280 to 320 ms after the stimuli while 380 to 420 ms time window is used for N400 topographies. After the EEG artefact rejection processes, 440 topograph images were used to train the deep network. Randomly selected 10 images that were excluded from training set were used for testing. All of the test images were correctly classified while 73% of the training set images were correctly classified.

Keywords—P300, N400, topography, deep learning

I. GİRİŞ

Yüksek zamansal hassasiyete sahip, kafaderisi üzerinden gerçekleştirilen elektriksel sinyal ölçümleri (Elektroensefalogram, EEG), kişilerin çevresel uyarılara verdikleri yanıtlara göre farklılaşmaktadır. EEG ölçümleri salt uyarılara verilen yanıtları içermeyip, süregiden bir elektriksel aktiviteyi de içermektedir. Bu arka plan beyin aktivitesi nedeniyle, anlık verilen görsel ve işitsel uyarılara karşı üretilen elektriksel

yanıtın çok belirgin olmamasına neden olmaktadır. Araştırmacılar, özellikle görsel ve işitsel uyarılara karşı üretilen elektriksel yanıtın ortaya çıkarılabilmesi için, uyarıların zaman kilitli olarak ortalama olarak, arka plan aktivitesinin baskılanabildiğini göstermiş ve bu yanıtla olaya ilişkin potansiyel (OİP) adını vermişlerdir.

Süregiden EEG kullanılarak beyin bilgisayar arayüzlerinde motor hareketlerin planlanmasının kestirilmesi son onlu yıllardan bu yana araştırılmaktadır. El parmaklarının ve sağ ayağın hareketinin planlanması sürecinin kestirilmesine yönelik EEG tabanlı uzaysal süzgeçler geliştirilmiş ve yüzde seksenbeşten yüksek tahmin başarıları sağlanmışlardır [7]. Sağ ve sol parmak hareketlerinin kestirilmesine yönelik gerçekleştirilen bir diğer çalışmada ise OİP tabanlı özneliklerin destek vektör makinaları sınıflandırıcısı için girdi olarak kullanıldığında, ortalama yüzde seksen üzerinde başarıya ulaşılmıştır [8]. Radyal temelli fonksiyon sınıflandırıcıları kullanılarak bilek hareketlerinin dört sınıfta kestirilmesinde, gama bandı temelli özneliklerle yüzde doksanlara yaklaşan başarıları ulaşılmıştır [9]. Yakın zamanda ise, derin öğrenme ile yapılan bir çalışmada motor hayal etme ödevinde karar destek makinaları sınıflandırmasından daha yüksek başarıları ulaşıldığı gösterilmiştir [6]. Motor hareketlerin uygulanması ve planlanması sürecinde motor bölge kaynaklı elektriksel aktivitenin davranışı hakkında bilgiler, öncül olarak kullanılarak sınıflandırma başarımını arttırmaktadır. Bunun yanında, ölçülen EEG'nin uzamsal örüntüsü aynı motor hareketler için kendini tekrarlayarak oldukça benzer görüntüler sağlamaktadır. Uyarıların ne zaman geldiğini bilmediğimiz durumlarda ise, bu uyarılara karşı oluşturduğumuz yanıtları izleyerek uyarının ne zaman geldiği bilgisine ulaşmak mümkün olabilir. Örneğin, semantik uyum araştırmalarında kullanılan Stroop testinde, uyarının ne zaman geldiği, ölçülen anlık topografinin bilinen yanıt sınıflarından hangisine tekabül ettiğinin bulunmasıyla kestirilebilir.

Günümüze kadar çok çeşitli test bataryaları kullanılarak, OİP ölçümleri gerçekleştirilmiştir. Bu deneylerde, uyarının verilmesinden belli zamanlar sonrasında, verilen uyarıya ilişkin özelleşmiş yanıtlar gözlenmiştir. Yanıtların uyarıdan 100 ms, 170 ms, 200 ms, 300 ms, 400 ms sonrasında oluşan bileşenler en sık araştırılanlarındandır. Bu bileşenler farklı

MAVİ	YEŞİL	KIRMIZI	SARI	MAVİ
Uyumsuz	Uyumlu	Uyumlu	Uyumlu	Uyumlu

Şekil 1: Stroop deney paradigmasının örneği

uzaysal bölgelerde gözlenerek, EEG verisinin kafaderisi üzerindeki uzaysal dağılımlarının çeşitlenmesini sağlamaktadır. Uyarılara zaman kilitli olarak gözlenebilen bu bileşenlerin, tek bir uyarıya karşı oluşabilmesi güç olmakta ve arka plan aktivitesinden ayrılması zorlaşmaktadır. Bu çalışma kapsamında, tek uyarıya karşı elde edilen topografik yanıtların, uyarandan hangi zaman dilimi sonrasında oluşturulduklarının belirlenmesi hedeflenmiştir. Bu bağlamda, Stroop testi kurgulanarak [1]-[3] [5], toplanan EEG verilerinden, P300 ve N400 bileşenleri tanınmaya çalışılmıştır.

II. METOD

A. OİP verisi

Stroop testinde uyumlu ve uyumsuz uyarılara verilen yanıtlardaki farklılıklar, algısal işlemlerde yavaşlama ile açıklanabilmekte ve OİP'nin P300 bileşeni ile ilişkilendirilmektedir [4]. Bunun yanında semantik uyumda N400 bileşeni ile ifade edilebilmektedir. Dört farklı renk yazı ile, yazı rengi ile içeriği uyumlu olanlar ve uyumsuz olanlar şeklinde sunulmuştur (Şekil 1). 16 kanallı BrainProducts Vamp EEG cihazı kullanılarak iki gönüllüden ölçüm gerçekleştirilmiştir. Uyumlu ve uyumsuz uyarılara karşı verilen yanıtlar topografik olarak çok benzerlik göstermekle beraber genlik olarak küçük farklılıklar taşımaktadır. Bu nedenle uyumlu ve uyumsuz uyarılara verilen yanıtların, ayrılmadan tümü birlikte kullanılmıştır.


EEG kayıtlaması 1024 Hz örnekleme frekansında, Fp1, Fp2, F3, Fz, F4, FCz, T3, Cz, T4, CPz, Pz, P7, P8, C3, C4, Oz elektrotları kullanılarak gerçekleştirilmiştir. Göz hareketleri sebebiyle oluşan gürültülü bölgeler sinyalden çıkarılmıştır. Genlikleri mutlak $100\mu V$ dan yüksek olan bölgeleri içeren traseler analizden çıkarılmıştır.

B. Derin Öğrenme ile topografik sınıflama


Evrişimsel Nöral Ağlar: ESA, geniş ve derin yapıları nedeniyle derin nöral ağların veya derin öğrenmenin yaygın bir türüdür.

Evrişim katmanı, girdi matrisi ile filtre (kernel) ve girdide aynı boyuttaki pencerelerin çarpılması sonucu elde edilmektedir. Bu veri evrişimsel öznetelik olarak saklanmaktadır.

Düzleştirilmiş Doğrusal Birim Katmanı: ReLU (Rectified Linear Unit) Activation Function. Evrişim katmanını takiben gelen bu katman ESA nöronlarının çıktuları için en yaygın şekilde devreye sokulan doğrultucu birim olup, bu çalışmada da ReLU kullanılmıştır. ReLU katmanı bir diğer adıyla aktifleştirme katmanı, girdi matrisinde negatif olan değerlerin sıfıra eşitlenerek eşiklenmesini ve ağına daha hızlı öğrenmesini sağlamaktadır (bkz. Şekil 2).



Şekil 2: ReLU katmanının giriş matrisine etkisi



Şekil 3: Havuzlama örneği: ortalama havuzlama (sağ üst), maksimum havuzlama (sağ alt)

Evrişim katmanında gerçekleştirilen belirli matematiksel işlemler sebebiyle ağı doğrusal bir yapıdadır. ReLU aktivasyon fonksiyonu ile derin ağı doğrusal olmayan bir yapıya sokulmaktadır. Tanımlanan aktivasyon fonksiyonu ile modelin düzgün eğitilme ve örtüşme yeteneği azaltılmaktadır. ReLU aktivasyon fonksiyonuna verilecek herhangi negatif girdi değeri grafikte ivedilikle sıfıra atamaktadır. Bu durum çıktı grafiğinde, negatif değerlerin tam olarak yansıtılmaması biçiminde sonuçlanmaktadır.


Havuzlama katmanı ile öznetelik haritalarının alt gruplara indirgenmesi (aşağı örnekleme) ve boyut azaltılması sağlanmaktadır. Alt gruplara indirgeme, ortalama (Şekil 3 üst 2x2 matris) ve(ya) en büyük değeri alma (maksimum havuzlama, Şekil 3 alt 2x2 matris) yoluyla gerçekleştirilmektedir.

Havuzlama işlemi ile öğrenilmiş öznetelikler daha öne çıkartılmakta (robust) ve ağıdaki parametre sayısı azaltılmaktadır.

Öğrenme işlemine girdi olarak iki tür topografik imge kullanılmıştır. Uyarın gösteriminden 280 ms ve 320 ms sonraki bölümün ortalama topografisi P300, 380 ve 420 ms arası bölümdeki ortalama ise N400 bileşeni olarak eğitim kümesi oluşturulmuştur. Her bir sınıftan 220 topografi eğitim kümesinde yer almıştır. İki sınıfa ait örnek eğitim topografileri Şekil 4 'te gösterilmiştir. Tüm topografileri kendi içlerinde 0 ile 1 arasında değişecek şekilde, normalize edilmiştir.

III. SONUÇ

Phyton ortamında tensorflow kullanılarak gerçekleştirilen eğitim sonrasında, sistem, eğitime sokulmayan P300 ve N400



Şekil 4: Derin öğrenme için üçer adet P300 ve N400 topografi örnekleri, EEG zaman serileri üzerinde gösterilmiştir. Serilerde yatay eksen zamanı (ms), dikey eksen ise genliği (μV) göstermektedir.

topografileri ile test edilmiştir. Test için kullanılan topografilerden altı tanesi Şekil 5 te gözükmektedir. Toplam 10 test imgesi test edilmiş ve tamamı doğru şekilde sınıflandırılmıştır (Şekil 6).

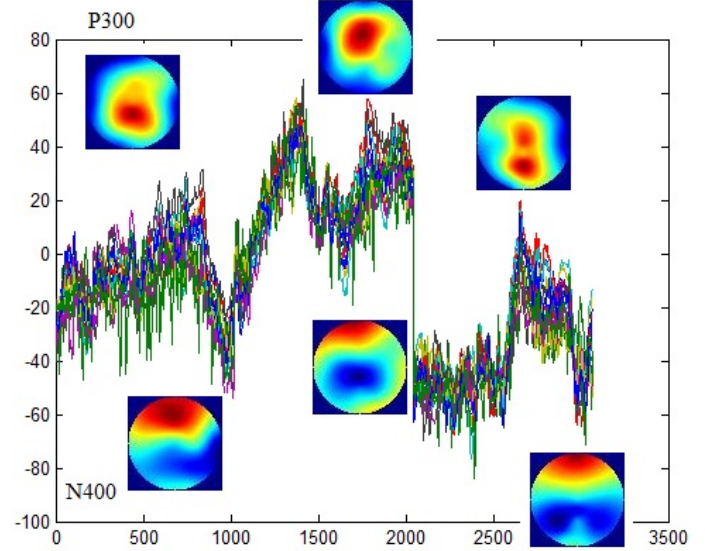
Toplam 440 eğitim imgesinin 324 adeti doğru sınıflandırılmış ve %73 lük başarıya ulaşılmıştır.

IV. TARTIŞMA


Görsel ve işitsel uyaranlar sonrasında OİP yanıtları hakkında yapılan çalışmaların tamamına yakını, deney tasarımının bilindiği durumlarda bileşenler arasındaki ilişkileri incelemektedir. Kişinin hangi anda dikkatinin yükseldiği, hangi anda dinlenme durumunda olduğunun ayrışmasını önemli olduğu durumlarda ise, karar vermek için gerekli olan sürenin en aza indirgenmesi önemlidir. Bu çalışma kapsamında 40 ms lik pencerelerinin zaman ortalaması alınarak elde edilen topografilerin kullanıldığı düşünüldüğünde, yüksek bir zamansal hassasiyetle durum sınıflandırılması yapıldığı düşünülebilir.

KAYNAKÇA

[1] West R, Alain C (2000) Effects of task context and fluctuations of attention on neural activity supporting performance of the Stroop Task. Brain Res, 873: 102-11.



Şekil 5: Eğitim sonrası test amaçlı kullanılan topografi örnekleri P300 ve N400 bileşenleri için gösterilmiştir. Üç farklı zaman penceresine ait 16 kanallı EEG verisi yanyana çizilmiştir.



Şekil 6: Test kümesini oluşturan 10 imgenin gerçek değerleri ve tahmin edilen değerleri belirtilmiştir.

- [2] Liotti M, Woldorff MG, Perez R ve ark. (2000) An ERP study of the temporal course of the Stroop color-word interference effect. Neuropsychologia, 38: 701-11.
- [3] Hanslmayr S, Pastötter B, Bäuml K H, Gruber S, Wimber M, W Klimesch, The Electrophysiological Dynamics of Interference during the Stroop Task, Journal of Cognitive Neuroscience, Vol. 20, No. 2, Pages 215-225
- [4] Duncan-Johnson, C. C., Kopell, B. S. (1981). The Stroop effect: Brain potentials localize the source of interference. Science, 214, 938-940.
- [5] MacLeod, C.M. (1991) Half a century of research on the Stroop effect:



an integrative review. Psychol. Bull., 109(2): 163–203.

- [6] Zhichuan Tang, Chao Li, Shouqian Sun, Single-trial EEG classification of motor imagery using deep convolutional neural networks, Optik - International Journal for Light and Electron Optics, Vol 130, Feb 2017, Pages 11-18
- [7] Johannes Müller-Gerking, Gert Pfurtscheller, Henrik Flyvbjerg, Designing optimal spatial filters for single-trial EEG classification in a movement task, Clinical Neurophysiology, May 1, 1999Volume 110, Issue 5, Pages 787–798
- [8] Yalin Song, Yaoru Sun, Zijian Wang and Hong Zhang, 2017. Classification of Single Trial EEG During Automatic Correction of Finger Movement. Journal of Software Engineering, 11: 54-59.
- [9] Y.U. Khan and F. Sepulveda, Brain–computer interface for single-trial EEG classification for wrist movement imagery using spatial filtering in the gamma band, Vol 4, IET Signal Processing, p510-517, 2010