

P300 Tabanlı Beyin Bilgisayar Arayüzü Sistemlerinde Kullanılan Uyarı Sürelerinin Derin Öğrenme Yöntemi ile Karşılaştırılması

Comparing the stimulus time of the P300 Based Brain Computer Interface Systems with the Deep Learning Method

Ali Osman SELVİ¹, Abdullah FERİKÖĞLU², Derya GÜZEL³

¹Department of Computer Technology, Bilecik Şeyh Edebali University Bilecik, Turkey
aliosman.selvi@bilecik.edu.tr

²Electrical and Electronic Engineering, Sakarya University of Applied Sciences Sakarya, Turkey
af@sakarya.edu.tr

³Faculty of Medical, Sakarya University Sakarya, Turkey
deryaguzel@sakarya.edu.tr

Özetçe— İnsanlar Beyin Bilgisayar Arayüzü (BBA) sistemleri yardımı ile düşünme ve odaklanma yeteneklerini kullanarak bilgisayar ortamına komut üretebilmektedir. Bu sistemlerin bir kısmı P300 sinyalleri kullanılarak tasarlanmaktadır. Elektroensefalografi (EEG) sinyali bileşenlerinden olan P300 sinyali uyarandan yaklaşık 300ms sonra oluşan pozitif defleksiyonlu potansiyeldir. Unity üzerinde hazırllanmış yazılım yardımı ile bir bilgisayar kullanılarak iki farklı senaryoyu katılımcıların takip etmesi istenmiştir. Çalışma 6 katılımcı üzerinde uygulanmıştır. Bireylerin EEG sinyalleri EMOTIV EPOC+ cihazı ile kayıt altına alınmıştır. Bu çalışmada BBA sistemlerinin temel unsurlarından olan uyarı zamanları derin öğrenme yöntemi kullanılarak kıyaslanmıştır. Görevlerde uyarı arası geçiş süresi 125 ile 250 milisaniye olarak seçilmiştir. Derin öğrenme ile yapılan sınıflandırında her iki uyarı arası geçiş süresi eğitim verilerinde %100 başarı ile sonuçlanmıştır. Test verilerinde 125 milisaniye uyarı arası geçiş %80, 250 milisaniye uyarı arası geçiş %40 başarı elde etmiştir.

Anahtar Kelimeler— Elektroensefalografi; Beyin Bilgisayar Arayüzü ;Derin Öğrenme;P300 ; Emotiv.

Abstract— With the help of Brain Computer Interface systems, people can generate commands to the computer environment by using their ability to think and focus. Some of these systems are designed using P300 signals. One of the components of the electroencephalography (EEG) signal is the positive deflection potential of approximately 300ms after the stimulus. The participants were asked to follow two different scenarios by using a computer with the help of the software prepared on Unity. The study was performed on 6 participants. In this study, stimulus time which is one of the basic elements of BBA systems was compared by using deep learning method. Transition time between stimulus in tasks was chosen from 125 to 250 milliseconds. In the classification made with deep learning, the transition time between the two stimuli resulted in 100% performance in the training data. In test data, the 125 millisecond transition time achieved 80% performance. In test data, the 250 millisecond transition time achieved 40% performance.

Keywords— Electroencephalography; Brain Computer Interface; Deep Learning; P300; Emotiv.

I. GİRİŞ

EEG işaretleri kafatası üzerinden sensörler aracılığı ile alınan farklı genlik ve frekansa sahip sinyallerdir. Bu konu üzerinde elde edilen çalışmalarla EEG verisinin birçok bilgi içeriği düşünülmektedir. EEG işaretlerinin farklı frekans yapısında ve düşük genlikli olması EEG verisi içerisinde özelleştirme çökertmekte ve özellikle farklı genliklerdeki sinyallerin farklı frekanslarda ortaya çıkmasına neden olmaktadır [1].

Teknolojik gelişmelerin EEG işaretinin analizine yönelik kullanılması klinik teşhislerde EEG işaretlerinin kullanımını yaygınlaştmıştır. EEG işaretlerinin farklı yöntem ve tekniklerle analiz edilmesi etkin değerlendirme yapabilmeye olanak sağlamamaktadır. Önceki çalışmalarla EEG işaretlerinin analizinde sinyalin frekans genlik ve şekillerine göre sınıflandırılmalar yapılmıştır [2].

BBA sistemleri insanların düşünme ve odaklanma yeteneklerini kullanarak bilgisayar ortamına komut üretebilmesini sağlayan sistemlerdir. BBA kullanan bireyler bilgisayar ortamı ile kurabildikleri bu etkileşim sayesinde farklı donanım ve yazılımları kontrol edebilmektedirler[3].

EEG işaretleri kayıt altına alınırken beyin organının oluşturduğu sinyallere ek olarak farklı bir çok gürültü ve sinyal de kayıt altına alınmaktadır. EEG verileri belirli bir amaca yönelik uygulama için incelenirken istenmeyen gürültü ve sinyaller işaretin içerisinde bozucu etki oluşturmaktadır. Bozucu etkiler insan vücudunu kaynaklı ve dış ortam kaynaklı olmak üzere ikiye ayrılmaktadır[4]. Bozucu sinyaller gürültü olarak isimlendirilmektedirler. Bu işaretler veriden filtrelenerek çıkartılabilen gibi yine filtrelenerek veri içerisinde ayırt edilip kullanılabilirler. EEG işaretleri

îçerisindeki istenmeyen bileşenlerin etkilerinin azaltılması genellikle farklı band geçiren filtreler yardımcı ile sağlanır [5].

EEG sinyalleri üzerinde BBA konusunda birçok çalışma bulunmaktadır. Bu çalışmaların bazıları EEG işaretleri içerisindeki P300 sinyallerine odaklanmaktadır. [6-7] P300 sinyalleri EEG işaretinde verilen uyarandan yaklaşık 300 ms sonra oluşan pozitif defleksiyonlu potansiyeldir [8-9].

Bu çalışmada Unity üzerinde hazırlanmış 2x2 P300 görsel matrisi 6 bireye 2 farklı görev şeklinde uygulanmıştır. Matris standart harf ve karakterlerden oluşan heceleme matrisinden farklı olarak renkli resimler ile oluşturulmuştur. Katılımcıya verilen görevlerde uyarının verildiği süreler ile dinlenme süreleri farklılık göstermektedir. EEG verisi toplama sürecinde Emotiv EPOC+ cihazı kullanılmıştır. Katılımcılardan alınan veriler ön filtreleme ve öznitelik çıkarma işlemlerinden sonra MATLAB ortamında hazırlanan yazılım ile derin öğrenme yöntemi kullanılarak sınıflandırılmıştır. Çalışmada kullanılan P300 matrisi devam eden çevrim dışı ve çevrim içi BBA çalışmalarında kullanılmaya yönelik tasarlanmıştır. Bu çalışma ile devam eden BBA çalışmalarında kullanılmak üzere görevlerde katılımcılara verilen uyaraların sürelerinden en uygun olanı belirlenmiştir.

II. MATERİYAL VE YÖNTEM

A. Katılımcılar

Çalışmaya 6 sağlıklı yetişkin (yaşları 20 – 37 arasında) gönüllü katılmıştır. Sakarya Üniversitesi Tıp Fakültesi Etik Kurulu onayından geçen deney protokolü hakkında katılımcılara bilgilendirme yapılmıştır. Bütün katılımcılara deney protokolünün detayları ile ilgili bilgilendirilmiş gönüllü olur formu imzalatılmış ve verilmiştir.

B. EEG Veri Kaydı

Çalışmada EEG ham verilerini bilgisayara kayıt altına alan Emotiv firmasının EPOC+ EEG kayıt cihazı kullanılmıştır (Şekil 1). EEG cihazı 14 kanal ile veri kaydı yapabilmektedir. Cihazda kafa taşı üzerinde AF3, AF4, F3, F4, FC5, FC6, F7, F8, T7, T8, P7, P8, O1, O2 noktalarında sensörler bulunmaktadır. Emotiv EPOC+ cihazı gerçek zamanlı veri kaydetmek için Emotiv Xavier TestBench yazılımı kullanılmaktadır [10].



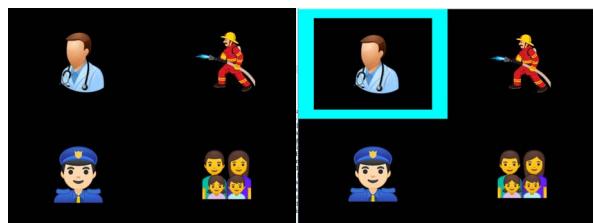
Şekil. 1. Emotiv EPOC+ Cihazı[10].

Kayıt altına alınan EEG verilerinin genlik aralığı 1-100 μ V (tepeden tepeye), frekans bandı ise 0,5 – 100 Hz arasındadır. EEG işaretlerinin değerlendirilmesinde kullanılan frekans bandı 0-35 Hz aralığıdır. EEG işaretlerinin frekans, faz ve

genlikleri periyodik olmadıklarından dolayı sürekli değişir [11 – 15].

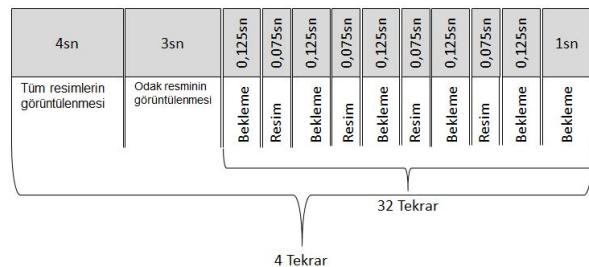
C. P300 Görsel Uyarı Matrisi

Katılımcılara Şekil 2 de ekran görüntüsü verilen siyah zemin üzerinde renkli resimlerin yerleştirilmesi ile oluşturulan 2x2 boyutlarında P300 matrisi gösterilmiştir. Uyarı matrisin gösterilmesi için bireye yaklaşık 50 cm uzaklıktaki 22 inch boyutlarında LCD monitör kullanılmıştır.

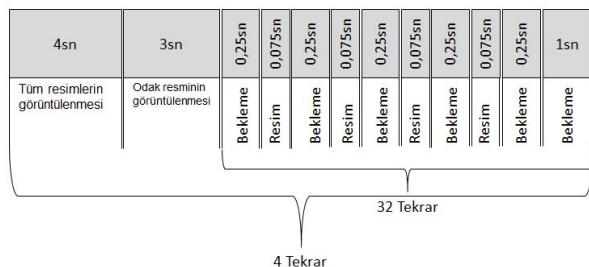


Şekil. 2. P300 Uyarı Matrisi

Unity platformu üzerinde hazırlanan uyarayı ile katılımcılara 2 farklı görev uygulanmıştır. Görevlerde katılımcıların sırası ile odaklanması istenen resimler farklı uyarı arası geçiş süreleri ile gösterilmiştir. Birinci görevde uyarı 75 milisaniye ekranda kalırken 125 milisaniyelik bir uyarı geçiş süresi kullanılmıştır. İkinci görevde ise uyarı süresi yine 75 milisaniye ekranda kalırken uyarı arası geçiş süresi 250 milisaniye olarak kullanılmıştır. Şekil 3 ve Şekil 4 de katılımcıya verilen görevlerin süre tablosu verilmiştir.



Şekil. 3. 125 ms Uyarı Arası Geçiş Süresi Görevi

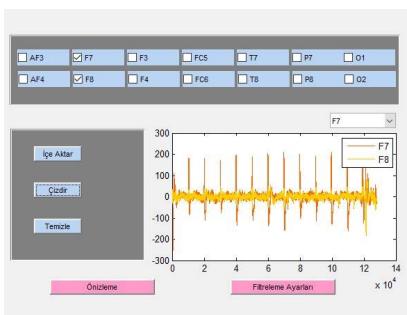


Şekil. 4. 250 ms Uyarı Arası Geçiş Süresi Görevi

D. EEG sinyallerini filtrelenmesi

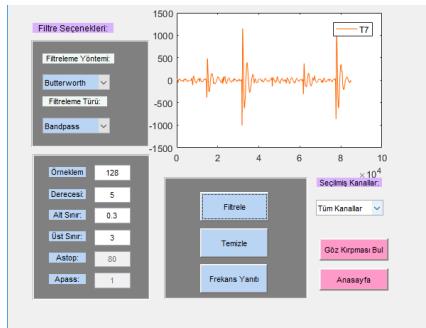
Emotiv Xavier TestBench yazılımı ile bilgisayar ortamına kaydedilen EEG verileri MATLAB ortamına aynı platform üzerinde hazırlanmış GUI tasarımlı ile aktarılmıştır.

Şekil 5 de gösterilen menü yardımcı ile edf formatında kaydedilmiş EEG verisinin denkleştirilerek sınıflandırma matrisi oluşturulmuştur.



Şekil 5. EEG Verilerinin MATLAB ortamına aktarılması[16]

EEG işaretinin içerisindeki anlamlı bir sinyal çıkarmak için işaretin genlik ve frekans bileşenleri üzerinden incelenmesi gerekmektedir. EEG işaretin yapısı itibarı ile içerisinde birçok sinyal bileşeni barındırmaktadır. EEG işaretin içerisindeki kullanılmayacak olan frekans bileşenlerinin çıkarılması gerekmektedir. Şekil 6 da görülen menü yardımcı ile seçimi yapılan kanalların üzerinde temel filtreleme işlemleri gerçekleştirilmiştir [16].



Şekil 6. EEG Verilerinin Filtrelenmesi[16]

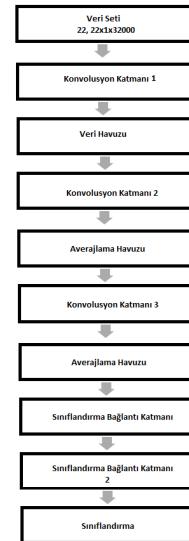
Derin öğrenme üzerinde sınıflandırma sonuçları karşılaştırmak üzere iki farklı veri seti için 6 katılımcıdan alınan P300 içeren ve P300 içermeyen EEG verileri O1 ve O2 kanalları seçilerek hazırlanmıştır.

E. EEG verisinin Derin Öğrenme ile sınıflandırılması

Konvolusyonel Sinirsız Ağlar (CNN) bilgisayarlı sınıflandırma ve kestirim gibi problemlerde kullanılmak üzere geliştirilmiş çok katmanlı yapay sinir ağlarının özel bir derin öğrenme modelidir. Yapısında konvolusyon, havuzlama ve tam bağlı gibi spesifik görevleri olan ayrı katmanları barındırır. Bunlar birbirini takip edecek şekilde dizilerek CNN oluşturulur. Bu yapının ilk kısımlarında öznitelik çıkartım

işlemleri gerçekleştirilirken sınıflandırma işlemi ise son katmanlarda gerçekleştir [17-18].

Bu çalışmada P300 olan EEG verilerini sınıflandırmak için 3 CNN katmanı, 3 havuzlama işlemi ve tam bağlı katman olmak üzere toplamda 5 katmanlı bir CNN mimarisi oluşturulmuştur. Oluşturulan CNN yapısına ait akış şeması Şekil 7'de görülmektedir



Şekil 7. Kullanılan Konvolusyonel Sinirsız Ağ mimarisi

Çalışmada, denkleştirme ve filtreleme işlemleri uygulanan iki farklı uyaran geçiş süresi içeren EEG veri setleri P300 sinyallerinin kestirimini yapabilmek üzere ayrı olarak derin öğrenme algoritmasına uygulanmıştır. Yapılan eğitimde P300 sinyali içeren O1 ve O2 kanal verilerini barındıran 12 veri ile P300 sinyali içermeyen 10 adet veri, veri setinin tamamını oluşturmuştur. P300 sinyali içeren veri setinin %50 si Eğitim %25 i onaylama ve %25 i test için kullanılmıştır. P300 Sinyali içermeyen EEG veri setinin %60 i eğitim %20 si onaylama ve %20 si test için kullanılmıştır.

MATLAB ortamında yapılan derin öğrenme eğitimleri sonucunda birinci veri seti için eğitim ve test verilerinin sınıflandırma sonuçları Şekil 8 de, ikinci veri seti için sınıflandırma sonuçları Şekil 9 da verilmiştir.

Training Accuracy Confusion Matrix			Testing Accuracy Confusion Matrix			
Output Class	Target Class		Output Class	Target Class		
	A	N		A	N	
A	6 50.0%	0 0.0%	100% 0.0%	3 60.0%	1 20.0%	75.0% 25.0%
N	0 0.0%	6 50.0%	100% 0.0%	0 0.0%	1 20.0%	100% 0.0%
	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	50.0% 50.0%	80.0% 20.0%

Şekil 8. Birinci veri seti için Eğitim ve Test Sonuçları



Şekil. 9. İkinci veri seti için Eğitim ve Test Sonuçları

III. DENEYSEL SONUÇLAR VE TARTIŞMA

Bu çalışmada P300 sinyali içeren ve içermeyen EEG işaretleri üzerine çalışılmıştır. Katılımcılara uygulanan görevlerde uyaran arası bekleme süreleri farklı tutarak devam eden çalışmalarında uygun sürenin belirlenmesi amaçlanmaktadır. Sınıflandırma sonuçlarına göre 125 milisaniyelik bekleme süresinin başarım oranının 250 milisaniye bekleme süresi başarım oranından %40 farklı daha iyi sonuç verdiği görülmüştür.

Sınıflandırmada başarının artması için katılımcı sayısını ve sınıflandırma öncesi öznitelik çıkarımının başarımı pozitif yönde etkileyeceği düşünülmektedir.

KAYNAKLAR

- [1] Güler I., Kiyimik M.K., Akin M., Alkan A., 2001. AR Spectral Analysis of EEG Signals By Using Maximum Likelihood Estimation. Comp in Biology and Medicine, 31: 441-450J. Clerk Maxwell, A Treatise on Electricity and Magnetism, 3rd ed., vol. 2. Oxford: Clarendon, 1892, pp.68-73.
- [2] Alkan A., 2006. Eeg İşaretlerinin Ayrıntırılması, Altuzay Yöntemlerinin Kullanılması, Journal Of Yaşar University, 1(3), pp. 211-21.
- [3] Wolpaw, R. J., Birbaumer, N., McFarland, D. J., Pfurtscheller, G. ve Vaughan, T. M., Brain-Computer Interfaces for Communication and Control, Clinical Neurophysiology, 113 (2002) 767-791. Savelainen A., An Introduction to EEG Artifacts, Independent research projects in applied mathematics, 2010.
- [4] Savelainen A., An Introduction to EEG Artifacts, Independent research projects in applied mathematics, 2010.
- [5] ÖZMEN, N.G., "Beyin Bilgisayar Arayüzü için Farklı Zihinsel Aktiviteler Esnasında Oluşan EEG İşaretlerinin Analiz Edilmesi ve Sınıflandırılması", Doktora Tezi, KTÜ Fen Bilimleri Enstitüsü, Eylül, 2010.
- [6] Sævarsson, S., Kristjánsson, Á., Bach, M., & Heinrich, S. P. (2012). P300 in neglect. Clinical Neurophysiology, 123(3), 496-506.
- [7] Sambeth, A., Maes, J. H. R., & Brankač, J. (2004). With long intervals, inter-stimulus interval is the critical determinant of the human P300 amplitude. Neuroscience letters, 359(3), 143-146.
- [8] McPherson DL. Long Latency auditory evoked potentials. In: Stein L, editor. Late potentials of the auditory system. Evoked potentials series. San Diego-London: Singular Publishing Group;1996.p. 7-23.
- [9] Luck SJ. An introduction to the event related potential technique. First Edition. USA, MIT Press,2005.
- [10] <https://www.emotiv.com/epoc/> erişim tarihi 02.01.2017.
- [11] Yıldız M., "Uyku Evrelerinin EEG İşaretleri Kullamlarak Sınıflandırmasında Yeni Bir Yaklaşım", Doktora Tezi, Sakarya Üniversitesi Fen Bilimleri Enstitüsü, Sakarya 2009.
- [12] YAZGAN E., KORÜREK M., Tıp Elektroniği, İTÜ Elektrik – Elektronik Fakültesi Ofset Baskı Atölyesi, İstanbul, 1996.
- [13] OROPEZA E., CYCON H.L., JOBERT, M., "Sleep Stage Classification Using Wavelet Transform and Neural Network", TR-99-0038, Marc 30, 1999.
- [14] VAN HESE, P., PHILIPS, W., De KONINCK, J., VAN de WALLE, R., LEMAHIEU, I., "Automatic Detection of Sleep Stages Using the EEG", 2001 Proceeding of the 23rd Annual EMBS International Conference, İstanbul, Turkey, October 25-28, 2001.
- [15] TATUM, W.O., Handbook of EEG Interpretation, Demos Medical Publishing, 1 edition, New York, July 1, 2007.
- [16] Selvi, A. O., Ferikoğlu, A., Güzel, D., & Karagöz, E. (2017, October). Design and implementation of EEG signal based brain computer interface for eye blink detection. In Computer Science and Engineering (UBMK), 2017 International Conference on (pp. 544-548). IEEE.
- [17] LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. nature, 521(7553), 436.
- [18] Tabar, Y. R., & Halıcı, U. (2016). A novel deep learning approach for classification of EEG motor imagery signals. Journal of neural engineering, 14(1),016003.