

EEG Tabanlı Beyin-Bilgisayar Arayüzü Sistemlerinde Sınıflandırmayı Etkileyen Faktörler

Factors that Affect Classification Performance in EEG based Brain-Computer Interfaces

Ali Özgür Argunşah, Ali Baran Çürüklü, Müjdat Çetin, Aytül Erçil

Yapay Görme ve Örüntü Analizi Laboratuvarı,
Mühendislik ve Doğa Bilimleri Fakültesi, Sabancı Üniversitesi
argunshah@su.sabanciuniv.edu, baranc@sabanciuniv.edu, mctetin@sabanciuniv.edu, aytulercil@sabanciuniv.edu

Özetçe


Bu çalışmada Elektroensefalografi (EEG) tabanlı Beyin-Bilgisayar Arayüzü (BBA) sistemlerinde sınıflandırmayı etkileyen faktörlerden bazıları incelenmiştir. Bu incelemeler bir EEG tabanlı BBA sistemine olan P300 heceleme sistemi üzerine özelleştirilmiştir. P300, bir uyarana karşısında beyinin o uyarana bir tepki olarak ürettiği ve uyarandan yaklaşık 300ms sonra oluşan fizyolojik bir sinyaldir. Bu sinyal oluştuğu anda süregelen EEG içerisinde yalnızca birkaç mikro voltluk bir potansiyel değişim yaratır. Yaratılan bu değişimin çok yüksek olmaması P300 sinyalinin diğer olası fizyolojik gürültü kaynaklarından (düz ve çizgili kasların hareketleri, göz kapaklarının kırılması veya beyin içindeki farklı aktivite varlığı) etkilenmesine yol açar. Bu nedenle uyarının farklı zamanlarda tekrar edilmesi ile elde edilen P300 tepki sinyallerinin ortalaması alınarak aktivitenin varlığı gösterilir. Bu çalışmada çok kanaldan alınan EEG verilerinin iki farklı şekilde kullanılması ile bu iki yöntemin farklı frekans aralıklarındaki davranışları incelenmiş ve yöntemlerden elde edilen çıktılar ile bir Destek Vektör Makinesi (DVM) kullanılarak sınıflandırma yapılmıştır. Önerilen yöntemin klasik yöntemlere göre daha yüksek sınıflandırma performansı olduğu görülmüştür.

Abstract

In this paper, some of the factors that affect classification performance of EEG based Brain-Computer Interfaces (BCI) is studied. Study is specified on P300 speller system which is also an EEG based BCI system. P300 is a physiological signal that represents a response of brain to a given stimulus which occurs right 300ms after the stimulus onset. When this signal occurs, it changes the continuous EEG some micro volts. Since this is not a very distinguished change, some other physiological signals (movement of muscles and heart, blinking or other neural activities) may distort this signal. In order to understand if there is really a P300 component in the signal, consecutive P300 epochs are averaged over trials. In this study, we have been tried two different multi channel data handling methods with two different frequency windows. Resulted data have been classified using Support Vector Machines (SVM). It has been shown that proposed method has a better classification performance

1. Giriş

BBA sistemleri dış dünya ile ilişkilerini çevresel sinir sistemlerini kullanarak kuramayan insanlara bu imkânı sunmayı hedefleyen sistemlerdir [7,10]. Biz bu çalışmada bir EEG tabanlı BBA olan P300 heceleme sistemini inceledik. Süregelen EEG sinyali içerisinde P300 bileşeninin ayırt edilmesinde kullanılan en bilinen yöntem Oddball paradigmasıdır. Denekten yüksek olasılıklı standart uyarılar arasında rasgele sunulan düşük olasılıklı hedef uyarılara yanıt vermesi istenmektedir. Örneğin iki farklı tonda ses sinyalimiz olsun. Saniyede bir defa bu sinyallerden bir tanesinin verildiğini düşünelim. Bu iki sinyalin gerçekleşme olasılıkları birbirlerinden farklı olsun. Düşük olasılıklı yani dikkat edilen uyarana karşı uyarandan yaklaşık 300 ms sonra oluşan pozitif dalga P300 olarak adlandırılmaktadır. P300 bileşeni hedef olmayan standart uyarana karşı oluşmamaktadır. Şekil 1'de iki farklı kanal (elektrot) için içerisinde P300 bulunan ve bulunmayan EEG sinyallerin ortalama alınmış halleri gösterilmektedir. Tekrarlanan olayların ortalaması alındığında uyarana karşı verilen beyin yanıtları gözlenebilmektedir. Ortalama alınarak elde edilen P300 sinyalleri farklı elektrotlarda farklı dalga şekillerine sahip olabilir [6]. Bununla birlikte şekilleri farklı olsa da tepe yaptıkları zaman değerlerinin yaklaşık olarak eşit oldukları görülmektedir [6]. P300 sınıflandırmasındaki amaca bağlı olarak bu elektrotların tek bir tanesi veya çok sayıda elektrottan alınan değerler farklı birleşimlerde kullanılabilirler. Bu çalışmada 1 ile 10 arasında farklı miktardaki elektrotların iki farklı şekilde düzenlenmesi ile elde edilen öznitelik vektörlerinin iki farklı frekans penceresinde P300 sınıflandırmasına etkileri incelenmiş ve elde edilen sonuçlar benzer çalışmalar [1,2,3,11] ile karşılaştırılmıştır.



Şekil 1. P300 Potansiyelinin 1 sn lik zaman dilimindeki örüntüsü (genlik yatay ekseninde çevrilerek çizilmiştir): Sürekli çizgi hedef, kesikli çizgi hedef olmayan uyarana karşı beyinde üretilen potansiyel. A) Pz elektrotundan, B) Cz elektrotundan alınan kayıt

2. P300 Heceleme Sistemi

A	B	C	D	E	F
G	H	I	J	K	L
M	N	O	P	Q	R
S	T	U	V	W	X
SPC	DOT	Y	Z	?	NEW LINE
1	2	3	4	5	EXIT

Şekil 2. P300 heceleme matrisi. Örneğin 'P' harfini yazmak istediğimizde 'P' harfinin bulunduğu satır veya sütun yandığı anlarda süregelen EEG sinyali içerisinde P300 dalga formu oluşur. Bu Şekil kaynak 1'den alınmıştır.

P300 heceleme sistemindeki amaç, dış dünya ile iletişim kuramayan insanların (örneğin ALS ve Tetrapleji hastaları) düşüncelerini yazıya dökmelerine imkân vermektir. Bu sistem ilk defa Farewell ve Donchin tarafından [1] öne sürülmüştür. Denek Şekil 2'de görülmekte olan bilgisayar ekranında beliren 6x6 lık harf matrisini görecektir. Harf matrisinin kolon ve sütunları denek beyinde P300 sinyalini oluşturmak amacıyla belli hızlarda ve rasgele olarak yanıp sönmeye başlarlar. Örneğin şekildeki gibi 'P' harfinin yazdırılmak istendiğini düşünelim. Denekten 'P' harfine ait sütun ve satırın kaç defa yanıp söndüğünü sayması istenir. Matris üzerinde 6 sütun ve 6 satır olduğundan dolayı bir tekrarda toplam 12 adet yanıp sönmeye işlemi gerçekleşir. Bu 12 yanıp sönmeye sürecinde hedef harfimize karşılık 2 adet P300 ve diğer satır ve sütunlara karşılık gelen 10 adet de P300 olmayan EEG sinyali bulunur. P300 heceleme sistemi, P300 olan ve olmayan EEG sinyallerinin ikili bir sınıflandırma algoritması ile sınıflandırılması ile kullanıcının istediği harfleri sırasıyla yazarak kelimeler ve cümleler oluşturmasını sağlar. Bu ikili sınıflandırmanın başarılı ve hızlı bir şekilde yapılabilmesi yazı yazma hızını etkiler [4,10,11]. Giriş bölümünde bahsettiğimiz gibi aynı

uyaran tekrarlanıp, verilen beyin yanıtları ortalandığında, tekrar sayısının artmasına paralel olarak sınıflandırma başarımı da artar. Ancak tekrar sayısı arttıkça bir harfin seçilebilmesi için gereken süre de artmaktadır. Hedeflediğimiz nokta en az tekrarlama ile en yüksek sınıflandırma başarımını sağlamaktır. Tekrar sayısını arttırmak dışında sınıflandırma performansını etkileyen bir diğer kavram da kullanılan EEG kanalı sayısını arttırmaktır.

Çalışmanın bundan sonraki bölümünde tekrar ve kanal sayısına bağlı olarak oluşturulan iki farklı özneliktik vektörü açıklanacak ve köşe frekansları farklı iki adet 3. derece Butterworth süzgeç ile süzgeçlenen bu özneliktik vektörlerinin sınıflandırma üzerindeki etkileri incelenecektir.

3. Yöntem

Çalışmada P300 heceleme sistemi veri analizi için 'BCI Competition III' [5] veri kümesindeki A denekinin kayıtları kullanılmıştır. Bu 85 harflik bir kümedir. Denek ikinci bölümde anlatılan işlemleri 85 harf için ayrı ayrı gerçekleştirmiştir. Deney sırasında deneye dikkat etmesi gereken harf her bir harf kaydının öncesinde söylenerek, belirtilen harfe ait satır ve sütunların kaç defa yandığını sayması istenmiştir [1,2,3,11]. Bu şekilde her harf için 15 defa tüm matris tekrarlanmıştır. Her tekrarda 12 yanıp sönmeye gerçekleştiğinden toplamda 180 adet içerisinde P300 olan ya da olmayan EEG sinyal parçası kaydedilmiştir.

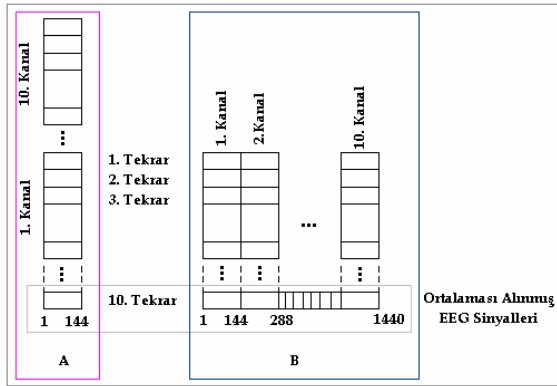
3.1. Süzgeçleme

P300 sinyallerinin sınıflandırma öncesi süzgeçlenmesi ile 50Hz'lik şehir şebekesi gürültüsünden ve P300 ile ilgisi olmadığına inanılan yüksek frekanslı EEG bileşenlerinden arındırılmasıyla daha yüksek sınıflandırma başarısı sağlanacağı düşünülmektedir [2,3]. P300 ün bellek ve dikkat süreçleri ile ilgili olduğu hipotezi de düşünüldüğünde yüksek frekanslı bileşenlerden kurtulmak mantıklı bir yaklaşım olarak görünmektedir. Bununla beraber süzgeçleme sırasında kaybettiğimiz bilginin yararlı olup olmadığı da başka bir sorudur.


3.2. Ortalama

Birden fazla tekrar ile elde edilen sinyallerin ortalanması ile elde edilen P300 sinyalinin sınıflandırma başarımını pozitif yönde etkilediğinden bahsetmiştik. Sınıflandırma için kullanılacak EEG sinyalinin birden fazla kanaldan elde edilmesi durumunda farklı kanallardaki bilginin nasıl bir şekilde kullanılacağı sorusu akla gelmektedir. P300 heceleme sisteminde sınıflandırmayı konu alan benzer çalışmalarda [2,3,10,11] Şekil 3B'de gösterilen yöntem kullanılmıştır. Bu yöntemde her kanal için ikinci bölümde bahsedilen izlek izlenir. Sonrasında her bir kanal için elde edilen ortalanmış veriler ucuca eklenerek uzun bir özneliktik vektörü yaratılır. Bu yöntem ile örneğin bu veri kümesinde, örnekleme frekansı 240 Hz olup 600 ms lik pencerelerde çalıştığımızdan dolayı elimizde 144 nokta uzunluğunda bir özneliktik vektörü olur. Bir kanal üzerinden bu 144 noktalı farklı zamanlardaki parçacıklar ortalandığında yine 144 noktalı bir özneliktik vektörüne ulaşılmaktadır. Analiz için 10 kanal kullanırsak eğer, özneliktik vektörümüzün uzunluğu $144 \times 10 = 1440$ nokta olacaktır. Yaratılan bu vektör sınıflandırıcıda kullanılır.

Bizim burada gerçekleştirdiğimiz yeni yöntem Şekil 3A’da da görülen bütün kanalların önce kendi içlerinde sonrasında da ortaya çıkan ortalanmış vektörlerin birbirleri ile ortalamaları alınarak gerçekleşir.



Şekil 3. A) Kanalların önce kendi içlerinde tekrar sayısına göre, sonra da bütün kanallardaki ortalanmış tekrarların birbiriyle ortalanması (önerilen yöntem) B) Kanalların kendi içlerinde tekrar sayısına göre ortalandıktan sonra yan yana eklenerek uzun bir öznitelik vektörü oluşturulması (klasik yöntem)



Şekil 4. İli ayrı kanalın etkileşiminden oluşabilecek Kanallardaki latans farklılıklarının toplam P300 sinyaline etkileri. Dalga modelleri, Şekil 1’de 300 ms etrafındaki dalga şekline göre yapılmıştır. Burada ortalama alınmamış, yalnızca toplamlar gösterilmiştir.

Bu durumda elimizdeki öznitelik vektörümüzün uzunluğu 144 nokta olacaktır. Farklı kanallarda ortalanmış sinyallerin birbirleri ile ortalamalarının alınmasındaki mantık P300 teorisinde yatmaktadır [6]. Farklı kanalların üst üste ortalanması sonucu oluşabilecek etkileri anlatan basit bir model Şekil 4’de gösterilmiştir. Kanallar arası latans farkı arttıkça sinyal zaman düzleminde kayacak ve kanallar üzerinden yapılan ortalamanın performansının düşmesine

neden olacaktır. Hoffman ve Polich [6] frontal, central ve parietal elektrotlar arasındaki P300 latans farkının kadın ve erkeklerde farklı olmakla birlikte Oddball paradigması altında 20ms’den fazla olmadığını göstermişlerdir. Çalışmada incelediğimiz P300 heceleme sistemi de Oddball paradigması üzerine kuruludur. 600 ms’lik sinyal parçasının 144 noktaya tekâmül ettiğini düşünecek olursak 20 ms’lik latans farklı yaklaşık 5 sinyal noktasına karşılık gelir. Bu durumda birbirlerinden 5 nokta Latans farkına sahip olan sinyallerin ortalaması sonucunda elde edilen P300 bileşeninin genişliği Şekil 4A’da belirtilen sinyal modeli gibi olacaktır.

4. Sınıflandırma

Süreğen EEG içerisinde anlık uyarılara yanıt olarak üretilen P300 aktivitesinin var olup olmadığını anlamak ikili bir sınıflandırma problemidir. Uyarının verildiği andan itibaren EEG sinyalinin ilk birkaç yüz mili saniyelik bölümü bu tip sınıflandırma problemlerinde kullanılan standart bir seçimdir [1,2,3,4,5]. Bu çalışmada, seçilmiş EEG sinyal parçacıkları farklı öznitelik vektörleri oluşturacak şekilde düzenlenmiş ve bir Destek Vektör Makinesi (DVM) [8] kullanılarak sınıflandırılmışlardır. Bu yöntemin kullanılmış olmasının sebebi daha önce aynı veri kümesi üzerinde yapılan çalışmalarda yüksek başarımlar sağlamış olmasıdır [3]. İkili bir sınıflandırma yapmanın en basit bir en iyi çoklu düzlem yaratmaktır. Örüntü analizi algoritmaları bir takım eniyileme ölçütüne göre sınıflar arasındaki bir çoklu düzlem bulmaya çalışır. Bu düzlem bulunduğu, daha sonra bir test verisi üzerinde öngörü yapmak mümkündür. Bu eniyileme işleme birden fazla çoklu düzlem ile gerçekleştirilebilir. Mümkün olan en ayırt edici çoklu düzlemi bulmak için en yüksek sınır ölçütü, eniyileme içerisine eklenir. DVM nin davranışı düzenleme değişkeni C ve bant genişliği σ ile ilgilidir. İyi sonuçlar elde edilebilmesi için bu değişkenlerin doğru seçilmesi kritiktir. Bu çalışmada daha önceden en iyi sonuçları verdiği gösterilmiş değerler kullanılmıştır ($C = 20.007$, $\sigma = 27.359$) [3].


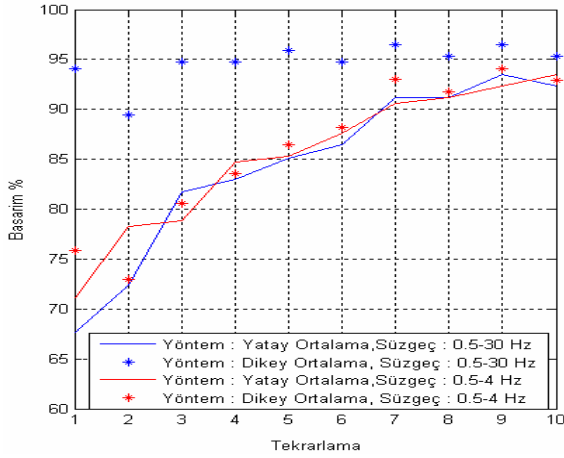
5. Sonuçlar ve Yorumlar

1. Tekrar sayısı arttıkça her iki ortalama yönteminde de 0,5–4 Hz bandında sınıflandırma performans artıyor (Şekil 5A). Yüksek frekans bandında ise önerilen yöntem ve klasik yöntem arasında belirgin bir farklılık olduğu görülmektedir.
2. Kanal sayısı arttıkça klasik yöntem için düşük frekanslı bileşenler, önerilen yöntemde ise yüksek frekanslı bileşenler sınıflandırmada daha önemli rol oynuyor (Şekil 5B).
3. Tekrarlama sayısı sabit tutulduğunda önerilen yöntem, eklenen her kanal için klasik yöntemde göre daha yüksek başarımlar sağlıyor (Şekil 5B).

Sonuçlara baktığımızda 1. sonucun beklenen bir sonuç olduğunu görüyoruz. Tekrar sayısındaki artışın sınıflandırma üzerindeki etkilerinden önceki bölümlerde bahsetmiştik. Bu tip deneylerde standart olan 4 elektrot (F_z, C_z, P_z, O_z) kullanıldığı zaman yüksek frekansta sınıflandırma performansını belirleyen değişkenin tekrar sayısı değil de elektrot sayısı olduğu görülüyor. Buda bize elektrot sayısının yeterince yüksek olduğu durumda tek deneyde bile yüksek sınıflandırma başarısı elde edebileceğimizi gösteriyor.

2. sonuç önceden öngörülmemiş ilginç bir sonuçtur. Zaman serisi şeklindeki sinyallerde, aynı uzunluktaki sinyallerin birbirleriyle ortalandığında sonuçta oluşan yeni sinyalde yüksek frekanslı bileşenlerin azalması gerektiğini öngörebiliyoruz. Bu durumda klasik yöntemin yüksek frekanslı bileşenleri bastırabilmesi için yeterince üst üste gelen sinyali ortalayamamasından dolayı bu işlem için ek bir süzgeçlemeye ihtiyaç duyulmaktadır. Önerilen yöntemde ise bu işlem zaten yüksek sayıdaki ortama alınan sinyal miktarı ile sağlandığı gibi yüksek frekanslarda olabilecek muhtemel yararlı sinyalin de (örneğin, yüksek frekans bileşenli bilişsel dikkat süreçleri) kullanılabilmesine olanak sağlamaktadır.

3. sonuç gösteriyor ki klasik yöntemin başarımı kanal sayısı arttıkça artmaktadır fakat bu yöntemde hangi kanalların kullanılması gerektiği kritiktir. Zira 3 kanaldan 10 kanala çıkılmasına rağmen başarımlar yalnızca %5 artmaktadır.



Şekil 5. Sınıflandırma Sonuçları. Sonuç grafiğinde klasik yöntem 'Yatay', önerilen yönteme ise 'Dikey' ortalama adı verilmiştir. Şekil 6'da üstteki bölümde kanal sayısı 4 olarak belirlenmiş ve tekrarlamaya sayısının değişiminin etkileri gözlemlenmiştir. Şekil 6'da altta kalan grafikte ise tam tersi olarak tekrarlamaya sayısı 4 ile sabit tutularak kanal sayısındaki değişimin sınıflandırma performansına katkıları incelenmiştir.

Yukarıda yapılmış olan analizde de görüldüğü gibi önermiş olduğumuz dikey ortalama yöntemi ile P300 heceleme sisteminde, tekrar sayısı bir defaya kadar indirildiğinde bile, yani olası en küçük değere indirildiğinde, yüksek sınıflandırma performansı elde edilebilmiştir. Bu sonuçlar ışığında devam edeceğimiz ilerideki çalışmalarımızda öncelikle sistemin 4 elektrottan daha az, yani 2 ve 3 sayıda elektrot ile performansını inceleyeceğiz. Bununla birlikte farklı latanslardaki kanalların içerdikleri bilgiyi daha etkili bir biçimde kullanabilmenin yolları araştırılacaktır. Böyle bir araştırma farklı sayı ve topolojideki elektrotlardaki P300 örüntülerinin daha ayrıntılı analiz edilmeleriyle mümkün olabilecektir.

6. Kaynakça

- [1] L. A. Farwell, E. Donchin, "Talking off the top of your head: toward a mental prosthesis utilizing event-related brain potentials", *Electroencephalogr. Clin. Neurophysiol.* vol. 70, no. 6, pp. 510-523, 1988
- [2] U. Hoffmann, G. Garcia, J.M. Vesin, K. Diserens and T. Ebrahimi, "A Boosting Approach to P300 Detection with Application to Brain-Computer Interfaces", *Proceedings of the IEEE EMBS Conference on Neural Engineering*, 2005.
- [3] M. Kaper, P. Meinicke, U. Grosskathoefer, T. Lingner, H. Ritter, "Support Vector Machines for the P300 Speller Paradigm", pp. 1073-1076, 2004
- [4] Donchin, E., Spencer, K.M., Wijensinghe, R. The mental prosthesis: Assessing the speed of a P300-based brain-computer interface. *IEEE Trans. Rehab. Eng.* 8:174-179, 2000.
- [5] B. Blankertz, K.R. Müller, G. Curio, T. M. Vaughan, G. Schalk, J. R. Wolpaw, A. Schlögl, C. Neuper, G. Pfurtscheller, T. Hinterberger, M. Schröder, and N. Birbaumer, "The BCI Competition 2003: Progress and Perspectives in Detection and Discrimination of EEG Single Trials *IEEE Trans. Biomed. Eng.* vol. 51, no. 6, 2004.
- [6] L.D. Hoffman, J. Polich, "P300, handedness, and corpus callosal size: gender, modality, and task", *Int. J. Psych. Physio.*, 31, pp. 163-174, 1999.
- [7] J. R. Wolpaw, N. Birbaumer, D. J. McFarland, G. Pfurtscheller, and T. M. Vaughan, "Brain-computer interfaces for communication and control," *Clin. Neurophysiol.*, vol. 113, pp. 767-791, 2002.
- [8] C.-C. Chang and C.-J. Lin. (2001) LIBSVM: A Library for Support Vector Machines [Online]. Available: <http://www.csie.ntu.edu.tw/libsvm>
- [9] S.J. Luck "An Introduction to Event Related Potential Technique", MIT Press, 2005.
- [10] G. Pfurtscheller and C. Neuper. "EEG-Based brain computer interfaces" in Niedermeyer E. and Da Silva F. L. *Electroencephalography, basic principles, clinical applications and related fields.* Fifth Edition. 1265-1271. 2005.
- [11] E. W. Sellers. "A P300 Based Brain Computer Interface: Testing an Alternative Method of Communication", Ph.D. Thesis, Department of Psychology, University of South Florida, 2004.