

# EEG Verisinde Kanallar-Arası Zaman Uyumluluk Profilleri Kullanılarak Hayali Hareket Tanıma

## Imaginary Activity Recognition Using Inter-Channel Time Coherence Profiles in EEG Data

B. Orkan Olcay<sup>1</sup>, Murat Özgören<sup>2</sup>, Bilge Karaçalı<sup>1</sup>

<sup>1</sup>Elektrik ve Elektronik Mühendisliği Bölümü, İzmir Yüksek Teknoloji Enstitüsü, İzmir, Türkiye  
{bilalolcay, bilge}@iyte.edu.tr

<sup>2</sup>Tıp Fakültesi, Biyofizik Anabilim Dalı, Dokuz Eylül Üniversitesi, İzmir, Türkiye  
murat.ozgoren@deu.edu.tr

**Özetçe**— Bu çalışmada, elektrotlar arası zaman gecikmesi kullanılarak bir beyin-bilgisayar ara yüzü çalışması gerçekleştirilmiştir. Öznitelik olarak, seçilen referans kanal ile geriye kalan tüm kanalların çapraz kovaryansının mutlak değerinin en yüksek olduğu zaman gecikmeleri hesaplanmıştır. Çalışmada kullanılan 5 kişi içinden 3 kişinin sınıflandırma performansının %100'e yakın olmasının yanında bu kişilerin eğitim veri seti sayısının diğer iki kişiye göre oldukça düşük olması ve literatürde buna benzer çalışmaların azlığı, önerilen yaklaşımın geliştirilmeye açık olduğunu göstermektedir.

**Anahtar Kelimeler** — Beyin-Bilgisayar Ara yüzü; Çapraz-Kovaryans; Zaman Uyumluluğu; Fisher'in Doğrusal Ayırıcısı; BCI Competition-III.

**Abstract**—In this study, we have carried out a brain-computer interface study that uses time delays between electrodes. As features, we have calculated the time delays that maximizes the absolute value of the cross-covariance between the chosen reference channel and the remaining channels. Performance results of 3 out of 5 participants that were nearly at a %100 accuracy level along with a relatively smaller number of training data, and a lack of similar studies indicate that the proposed approach is open to the further improvements.

**Keywords** — Brain-Computer Interface; Cross-Covariance; Time Coherence; Fisher's Linear Discriminant; BCI Competition-III.

### I. GİRİŞ

Beyin-bilgisayar ara yüzü, beyin aktivitesindeki değişimleri, farklı türde veri ya da verileri kullanarak çeşitli sinyal işleme ve veri analiz yöntemleri ile tanımayı amaçlar. Farwell ve Donchin'in tasarlamış olduğu ilk beyin-

bilgisayar ara yüzü tasarımının ardından [1] pek çok araştırmacının dikkatini çekmiş ve birçok farklı amaç için kullanılmaya başlanmıştır. Rehabilitasyon, bilgisayar oyun sektörü gibi günümüzde popüler olan alanlarda beyin-bilgisayar ara yüzü sıkça adı geçer hale gelmiştir. Günümüzdeki çalışmalar da bu bağlamda, beyin-bilgisayar ara yüzünün performansını iyileştirmek ve kullanılabilirliğini artırmaya yönelik olmaktadır.

Beyin bilgisayar ara yüzü çalışmalarında kullanılan beyin yanıtlılıkları, 4 farklı grupta sınıflandırılabilir. Bunlar görsel uyarılma potansiyelleri, yavaş kortikal potansiyeller, P300 paradigması ve sensorimotor ritmidir [2]. Bu tip çalışmalarda, kişinin zihinsel aktivitesi elektroensefalografi (EEG), magnetoensefalografi (MEG), fonksiyonel yakın kızılötesi spektroskopisi (FNIRS), elektrokortikografi (EcoG), intra-kortikal sinirsel aktivite kaydı, fonksiyonel manyetik rezonans görüntüleme gibi veri toplama teknikleri aracılığı ile kayıt edilmektedir. Bunların içinde, hem zamansal çözünürlük hem pratiklik açısından EEG, pek çok araştırmacı tarafından tercih edilen bir yöntem haline gelmiştir. EEG ile kayıt edilen beyin aktivitesi, yukarıda söz edilen beyin bilgisayar ara yüzü katmanları kullanılarak sinirsel dünyadan dış dünyaya, kişinin herhangi bir iskelet-kas sistemi altyapısı kullanılmadan komut olarak aktarılmaktadır [3]. Sistemin başarımı, zihinsel aktivitedeki değişimlerin ne kadarının bu ara yüz tarafından doğru şekilde yorumlandığıdır. Beyin-bilgisayar ara yüzü tasarımlarında performansın nicel olarak değerlendirilmesi Wolpaw ve arkadaşları tarafından ortaya atılan bilgi transfer oranı (ITR) ile hesaplanmaktadır [4].

Beyinde hayali motor aktivite esnasında ve öncesinde oluşan aktivite değişimi (mu (8-13 Hertz) ve beta (13-32

Hertz) bandında senkronizasyon kaybı), gerçek motor aktivitesinde olduğu gibi kestirilebilir bir frekans bandı aralığında olduğundan, son yıllarda yapılan tüm çalışmalar kişiye özgü frekans bandı belirleme üzerinde yoğunlaşmıştır [5, 6]. Bunun yanı sıra, fonksiyonel manyetik rezonans görüntüleme tekniği sayesinde hayali ve gerçek motor aktivitesi esnasında yerel ERD/genel ERS fenomeninin görülmesi, araştırmacılar için zihinsel aktiviteyi tanımayı daha kolay hale getirmektedir [5]. Bu bilgi ile birlikte, araştırmacılar EEG aktivitesi üzerinden çeşitli uzaysal örüntü ayrıştırma metodu kullanarak, zihinsel aktivite tanımayı amaçlamışlardır [7].

Beyindeki süreçler karmaşık bir davranış sergiler [8]. Bu karmaşıklık içerisinde motor aktivitenin yanında pek çok hafıza ve duysal bilgi aynı anda ve beynin birçok farklı bölgesinde işlenmeye devam etmektedir. Bu kadar karmaşık bir yapıdan elde edilen EEG sinyalleri ile yüksek başarımlı tanıma yapma hedefi, araştırmacıları sinyalin uzaysal özniteliklerin yanı sıra, zamansal ve spektral özniteliklerini aynı anda kullanmaya itmiştir [9]. Fakat bu tip çalışmalar yüksek işlem yükü ve uzun eğitim süreçleri gerektirdiği için önerilen yöntemlerin kullanılabilirliği hala tartışılmaktadır.

Bununla birlikte, beyinde gerçekleşen olayın farklı kortikal bölgelerin uyumlu faaliyeti sonucu oluştuğu gerçeği, araştırmaların yönünü zaman, genlik ve faz uyumuna çevirmiştir. Son yıllarda kanallar arası faz uyumu çalışmalarının sayısı literatürde az olmakla birlikte [10, 11], bu tarz çalışmalarda umut verici sonuçlar alınmış, daha da önemlisi, beynin tümleşik çalışma teorisine uygun bir çerçevede kalınmıştır [12].

*BCI Competition III IVa* veri seti üzerinden yapılan bu çalışmada, sensorimotor aktivitenin kanallar arası en yüksek kovaryans değerini veren zaman gecikmeleri kullanılarak zaman uyumluluk vektörü oluşturulmuş ve bu vektörler Fisher'in doğrusal ayrıştırıcısı ile sınıflandırılma işlemi için kullanılmıştır. İkinci kısımda kullanılan veri seti ve tanıma metodu anlatılmıştır. Üçüncü kısımda elde edilen sonuçlar verilmiş, son kısımda ise elde edilen sonuçlar ve bu sonuçların ne anlama geldiği tartışılmıştır.

## II. MATERYAL VE METOD

Bu çalışmada *BCI Competition III IVa* EEG veri setinde bulunan sırasıyla aa, al, av, aw, ay olarak kodlanmış olan katılımcıların hayali motor aktivite gerçekleştirdikleri EEG verileri kullanılmıştır. Tablo I'de eğitim ve test verileri sayısı yapılan çalışma sonucu elde edilen sınıflandırma performansları ile birlikte verilmiştir. Bu 5 katılımcıdan, kendilerine verilen komut ile 3,5 saniye boyunca sağ el ya da sağ ayaklarını kullandıklarını hayal etmeleri istenmiştir. Katılımcılara rastgele sıra ve rastgele zaman aralıkları ile toplamda 280 adet komut gönderilmiştir. Bunların 140'ı sağ el 140'ı ise sağ ayak kullan komutudur. EEG verileri 10/20 düzeninde uluslararası kayıt sistemine uygun bir

şekilde 1000 hertzlik örnekleme frekansı ile toplanmıştır. Yaptığımız çalışmada ise aynı verinin 100 hertzlik sürümü kullanılmıştır. Mevcut verilere ek olarak, elektrot lokasyonları, komut gönderilme anı, komut gönderim sırası gibi ilgili diğer tüm detay bilgiler [13]'de bulunmaktadır.

Komutların gönderilme zamanları başlangıç noktası olarak alınarak algoritmamız için 3,5 saniyelik motor aktivitenin de tamamıyla gerçekleşip sonlandığı bir uyarın penceresi oluşturulmuş, öznitelik oluşturma ve sınıflandırma işlemi bu pencere içerisinde kalan EEG işareti üzerinden yapılmıştır. Şekil-1 ve Şekil-2'de sırasıyla sağ el ve sağ ayak hayali motor aktivitesi esnasında uyarın penceresi içerisinde kalan, Fp1/C3 ve Fp1/Cz kanallarından elde edilen işaretler mevcuttur.

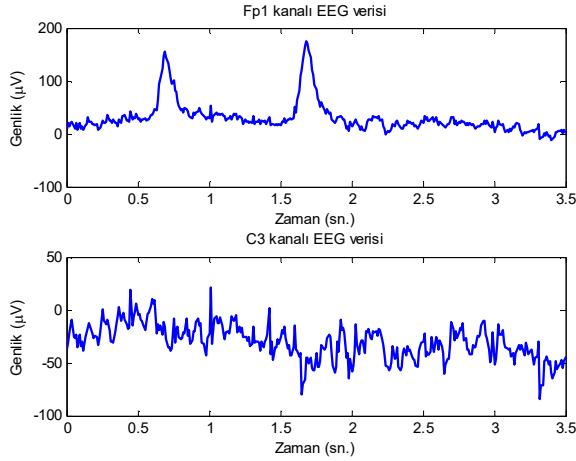
Sınıflandırma işleminden önce, zaman uyumluluk vektörü oluşturulmak için, zaman pencereleriyle bölünmüş olan 118 kanallı EEG veri kümesi içinden Fp1 kanalı referans kanal olarak seçilmiş ve geriye kanal 117 kanalı için, her bir kanal ile referans kanalın uyarın penceresi içinde kanal sinyalinin çapraz kovaryansının en yüksek olduğu zaman gecikmesi hesaplanmıştır. Matematiksel olarak bu gecikme,

$$\Delta_k = \operatorname{argmax}_{t \in [0 \ 3.5]} |E[(x_1(t) - m_{x_1})(x_k(t) - m_{x_k})]| \quad (1)$$

ile ifade edilmektedir. Yukarıda verilen Denklem (1)'de,  $x_1(t)$  referans kanalını,  $x_k(t)$  referans kanalı haricindeki, kovaryans işlemi için seçilen kanalı temsil etmektedir.  $m_{x_1}$  ve  $m_{x_k}$  sırasıyla referans ve seçilen herhangi bir kanalın uyarın penceresi içinde kalan EEG verisinin zaman üzerinden alınmış ortalamasıdır.  $E[.]$  ise beklenen değer operatörüdür ve zaman üzerinden alınan ortalamayı ifade etmektedir.

Denklem (1)'de verilen ifade yardımıyla her bir uyarın penceresi ve referans kanalı dışında geriye kanal her bir kanal için, çapraz kovaryansının mutlak değerinin en yüksek olduğu zaman gecikmeleri hesaplanarak 117 boyutlu bir öznitelik vektörü elde edilmiştir.

Yapılan çalışmada sınıflandırıcı algoritması olarak, kolaylığı ve işlem yükü bakımından en az kaynak tüketen yöntemlerden biri olması sebebiyle Fisher'in doğrusal ayrıştırıcısı (Fisher Linear Discriminant) tercih edilmiştir. FLD sınıflandırıcısı [14], temel olarak çok boyutlu öznitelik vektörlerini daha düşük boyutlu uzayda, daha az hata ile sınıflandırılacak doğrusal dönüşümü bulur. Bu dönüşüm sayesinde  $S_W$  ile gösterilen, farklı sınıflar içinde bulunan örneklerin dağılımlarının sapması küçülürken, yine aynı denklemde  $S_B$  ile gösterilen sınıflar arasındaki sapma büyümeye başlar. Matematiksel olarak bu bir eniyileme problemi olarak aşağıdaki şekilde ifade edilebilir;



**Şekil 1.** 'Sağ el kullan' komutu verildikten sonraki EEG verisi (üstte) Fp1 kanalının zamana göre değişimi, (altta) C3 kanalının zamana göre değişimi

$$\max_w J(w) = \frac{w^T S_B w}{w^T S_W w} \quad (2)$$


Yukarıdaki denklemde,  $w$  dönüşüm vektörünü vermektedir. Bu denkleme Rayleigh oranı adı verilir. Eniyilemeyi sağlayan dönüşüm vektörü;

$$w = (\Sigma_{sağ\ el} + \Sigma_{sağ\ ayak})^{-1} (\mu_{sağ\ el} - \mu_{sağ\ ayak}) \quad (3)$$

olarak bulunur ve FLD sınıflandırıcısı

$$f(x) = \text{sign}(w^T x + b) \quad (4)$$

olarak ifade edilir. Yukarıda geçen  $\Sigma_{sağ\ el}$  ve  $\Sigma_{sağ\ ayak}$  ayrıştırılmak istenen veri kümesinin kovaryans matrislerini,  $\mu_{sağ\ el}$  ve  $\mu_{sağ\ ayak}$  ortalama vektörlerini,  $b$  ifadesi eğitim kümesi üzerindeki yanlış sınıflandırmayı en aza indirmek üzere belirlenmiş olan sapmayı ifade eder.



**Şekil 2.** 'Sağ ayak kullan' komutu verildikten sonraki EEG verisi (üstte) Fp1 kanalının zamana göre değişimi, (altta) Cz kanalının zamana göre değişimi

Kişi	Eğitim	Test	% Perf.
aa	168	112	50.0
al	224	56	39.3
av	84	196	99.5
aw	56	224	100.0
ay	28	252	99.6

**Tablo 1.** BCI Competition III IVa Veri setinde bulunan Katılımcıların Eğitim-Test veri sayıları ve bunlar ile bulunan sınıflandırma performansı sonuçları

Elde edilen öznelikler sırasıyla eğitim verisi ve test verisi olarak FLD (Fisher's Linear Discriminant) sınıflandırıcısına verilmiştir.  $w$  ve  $b$  değerleri eğitim verisi üzerinden hesaplanarak kurgulanan sınıflandırıcı test verisine uygulanmış ve performans ölçümleri doğru sınıflandırma oranı ile yapılmıştır.

### III. SONUÇLAR

Yukarıda verilen bilgiler ışığında, elde edilen zaman uyumluluk vektörleri FLD sınıflandırıcı yardımıyla sınıflandırılmış ve sonuçlar Tablo-1 de verilmiştir. Tablo-1 ile verilen sınıflandırma performansına göre, aa ve al kişileri için doğru sınıflandırma yüzdesi şans seviyesinde (%50) çıkarken av, aw ve ay kişileri için %100 e yakın, ortalama olarak %99,7'lik bir başarıyı yüzde elde edilmiştir. Öte yandan veri setinde paylaşılan bu kişilerin eğitim ve test veri sayılarının birbirileri ile aynı olmadığı tabloda açıkça görülmektedir. Kişiler arasında av, aw ve ay katılımcılarının eğitim verisi sayılarının düşük olmasına rağmen, sınıflandırma performansının %100'e yakın olması, az sayıda eğitim verisinden, sağ el ve sağ ayak için beyindeki bu hayali hareketlere yönelik devinimlerin algoritmamız tarafından çabuk ve etkili bir şekilde öğrenildiğini göstermektedir.

Kullanılan bu veri setinde, kişilerin eğitim verisi sayılarının yüksekte düşüğe ve test veri sayılarının düşüğe yükseğe doğru gitmesi, algoritmamızın farklı sayıda eğitim-test verisi için, farklı kişilerde nasıl öğrenme yapabildiğini görmek için de idealdir.

Bunlara ek olarak, bu veri kümesinde verilen eğitim ve test verilerinin gerçek etiketleri elde edildikten sonra, algoritmamızın katılımcı bazında tanıma başarımının eğitim veri sayısına olan bağımlılığını görebilmek için deneysel bir kurgulama yapılmıştır. Kurguya göre 280 olan uyarın sayısının ilk %10 eğitim-son %90 test, ilk %20 eğitim-son %80 vb. olacak şekilde değiştirilerek 5 adımda ilk %50 eğitim-son %50 test oranlarına kadar denenmiştir.

	%10- %90	%20- %80	%30- %70	%40- %60	%50- %50
aa	71,03	74,11	77,04	50,00	57,14
al	61,51	63,39	63,78	47,62	47,86
av	88,49	93,75	99,49	99,40	100,00
aw	95,63	100,00	100,00	100,00	100,00
ay	99,60	99,55	64,80	57,74	77,86

**Tablo 2.** Bütün EEG verisinin farklı eğitim ve test yüzdeleri hali ile yapılmış olan sınıflandırma sonuçları

Tablo-2 de yukarıda belirtilen ilk 5 ayırım sonucu elde edilen (% eğitim- % test) sınıflandırma sonucu verilmiştir. Görülmektedir ki, Tablo-1’de düşük yüzdeli sınıflandırma gözlenen aa ve al kişileri, veri setleri ilk %10 eğitim-son %90 test olarak bölünüp sınıflandırmaya tabi tutulduğunda daha yüksek bir doğruluk yüzdesi ile sınıflandırılabilir. Bunun sebebi olarak, büyük olasılıkla, bu kişilerin belirli bir zaman sonra hayali motor aktivitesinden elde edilen EEG verisinde, kanallar arasındaki harekete özgü zaman gecikmesinin zihinsel yorgunluk, uykululuk, dikkat dağınıklığı, düşük sinyal/gürültü oranı gibi etkenlerden diğer katılımcılardan daha fazla etkilenmiş oldukları düşünülebilir.

#### IV. TARTIŞMA

Yapılan bu çalışmada *BCI Competition III* yarışması için sunulmuş olan herkese açık bir veri seti kullanılarak kanallar arası çapraz kovaryansın en yüksek olduğu zaman gecikmeleri seçilerek zaman uyumluluk vektörü oluşturulmuş, bu oluşturulan vektörler üzerinden Fisher’in doğrusal sınıflandırıcısı yardımı ile tanıma yapılmaya çalışılmıştır.

Elde edilen bu sonuçlar zaman uyumluluk profilinin farklı uyaran tiplerine özgü bir biçimde oluştuğunu ve beyinde bu bilginin işlenmesi için kortikal yapılarda, uyarana özgü zaman profillerinin meydana geldiğini göstermektedir. Dolayısıyla beyin-bilgisayar ara yüzü amaçlı anlık veri tanıma çalışmaları için farklı uyaranların farklı zaman uyumu profillerini meydana getirdiği gerçeği dikkate alınması gereken bir unsurdur.

#### KAYNAKÇA

- [1] L. A. Farwell and E. Donchin, "Talking off the top of your head: toward a zihinsel prosthesis utilizing event-related brain potentials," *Electroencephalography and clinical Neurophysiology*, vol. 70, pp. 510-523, 1988.
- [2] L. F. Nicolas-Alonso and J. Gomez-Gil, "Brain Computer Interfaces, a Review," *Sensors*, vol. 12, p. 1211, 2012.
- [3] J. R. Wolpaw, N. Birbaumer, D. J. McFarland, G. Pfurtscheller, and T. M. Vaughan, "Brain-computer interfaces for communication and control," *Clinical neurophysiology*, vol. 113, pp. 767-791, 2002.

- [4] J. R. Wolpaw, H. Ramoser, D. J. McFarland, and G. Pfurtscheller, "EEG-based communication: improved accuracy by response verification," *Rehabilitation Engineering, IEEE Transactions on*, vol. 6, pp. 326-333, 1998.
- [5] G. Pfurtscheller, C. Brunner, A. Schlögl, and F. L. Da Silva, "Mu rhythm (de) synchronization and EEG single-trial classification of different motor imagery tasks," *Neuroimage*, vol. 31, pp. 153-159, 2006.
- [6] G. Pfurtscheller and F. L. Da Silva, "Event-related EEG/MEG synchronization and desynchronization: basic principles," *Clinical neurophysiology*, vol. 110, pp. 1842-1857, 1999.
- [7] J. Müller-Gerking, G. Pfurtscheller, and H. Flyvbjerg, "Designing optimal spatial filters for single-trial EEG classification in a movement task," *Clinical neurophysiology*, vol. 110, pp. 787-798, 1999.
- [8] E. Başar, *Chaos in Brain Function: Containing Original Chapters by E. Başar and TH Bullock and Topical Articles Reprinted from the Springer Series in Brain Dynamics*: Springer Science & Business Media, 2012.
- [9] N. F. Ince, F. Goksu, A. H. Tewfik, and S. Arica, "Adapting subject specific motor imagery EEG patterns in space-time-frequency for a brain computer interface," *Biomedical signal processing and control*, vol. 4, pp. 236-246, 2009.
- [10] B. Hamner, R. Leeb, M. Tavella, and J. d. R. Millán, "Phase-based features for motor imagery brain-computer interfaces," in *Engineering in Medicine and Biology Society, EMBC, 2011 Annual International Conference of the IEEE*, 2011, pp. 2578-2581.
- [11] J.-P. Lachaux, E. Rodriguez, J. Martinerie, and F. J. Varela, "Measuring phase synchrony in brain signals," *Human brain mapping*, vol. 8, pp. 194-208, 1999.
- [12] E. Başar, "The theory of the whole-brain-work," *International Journal of Psychophysiology*, vol. 60, pp. 133-138, 2006.
- [13] G. Dornhege, B. Blankertz, G. Curio, and K.-R. Müller, "Boosting bit rates in noninvasive EEG single-trial classifications by feature combination and multiclass paradigms," *Biomedical Engineering, IEEE Transactions on*, vol. 51, pp. 993-1002, 2004.
- [14] R. O. Duda and P. E. Hart, "Pattern recognition and scene analysis," ed: Wiley, New York, 1973.