

# Saklı Markov Modelleri ve Boyut İndirgemeye Dayalı bir Beyin-Bilgisayar Arayüzü Algoritması

## A Brain-Computer Interface Algorithm based on Hidden Markov Models and Dimensionality Reduction

Ali Özgür Argunşah<sup>1,2</sup>, Müjdat Çetin<sup>1</sup>

<sup>1</sup>Sabancı Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Tuzla, İstanbul, Türkiye

<sup>2</sup>Champalimaud Neuroscience Programme at Instituto Gulbenkian de Ciência, Oeiras, Portekiz

argunshah@igc.gulbenkian.pt, mjetin@sabanciuniv.edu

### Özetçe

Beyin-bilgisayar arayüzleri (BBA) bağlamında zihinde hareket canlandırma sürecinde toplanan EEG verilerinin sınıflandırılması problemini ele alıyoruz. Saklı Markov Modelleri (HMM) üzerine kurulu bir yaklaşım öneriyoruz. Yaklaşımımız özbağlanımlı parametrelere dayalı öznitelikleri temel bileşen analizi (PCA) tabanlı boyut indirgeme ile birlikte kullanması bakımından mevcut HMM yöntemlerinden farklıdır. Yaklaşımımızın etkinliğini genel kullanıma açık bir veri kümesi ve kendi laboratuvarımızda topladığımız veriler üzerinde, iki ve dört sınıflı problemlerdeki deneysel sonuçlar ile gösteriyoruz.

### Abstract

We consider the problem of motor imagery EEG data classification within the context of brain-computer interfaces. We propose an approach based on Hidden Markov models (HMMs). Our approach is different from existing HMM-based techniques in that it uses features based on autoregressive parameters together with dimensionality reduction based on principal component analysis (PCA). We demonstrate the effectiveness of our approach through experimental results for two and four-class problems based on a public dataset, as well as data collected in our laboratory.

### 1. Giriş

Uygulamalı nörofizyoloji alanında yeni sayılabilecek gelişmelerden biri Elektroensefalografi (EEG) tabanlı Beyin-Bilgisayar Arayüzü (BBA) sistemleridir. Bu sistemler, EEG sinyalinden otomatik olarak çıkartılan bazı özniteliklerin işlenerek motor fonksiyonlarını yerine getiremeyen Amiyotrofik Lateral Skleroz (ALS) ya da tetraplejili hastaların bilgisayar kontrollü sistemleri kullanabilmeleri için geliştirilen sistemlerdir.

EEG bir zaman serisi sinyalidir. EEG-tabanlı BBA araştırmalarının amacı bu zaman serisi sinyalinden çıkartılan öznitelikleri kullanan sinyal işleme ve örüntü tanıma algoritmaları geliştirerek kişilerin bazı hareketleri gerçekleştirmelerini

sağlamaktır. Motor bir hareketin zihinde canlandırılması sırasında EEG sinyalinin frekans bileşenleri zamanla değişmektedir [13, 7, 10]. Bu çalışmada kullanılan veri kümelerinde iki ve dört farklı hareketin zihinde canlandırılması deneyi yer almaktadır (Bölüm 3.1'e bakınız). Herbir farklı motor hareket için beyin motor kabuğunda farklı bir bölge etkin olmaktadır. Bu bölgeler ile EEG kayıt elektrotları arasında bir bağlantı olsa da bu bağlantı beyin dokularının sinyali beyin içerisinde dağıtmasından dolayı bire-bir değildir [3].

Kişiler, beyinlerine duysal bir girdi olmadığı ya da motor bir hareket gerçekleştirmedikleri zamanlarda beyin kabuğunun duysal ve motor hareketlerle ilgili bölümleri  $\mu$  ritmi olarak bilinen 8-12Hz civarında elektriksel salınımlar yaparlar [13].  $\mu$  ritmi hareket, harekete hazırlık ya da hareketin zihinde canlandırılması durumlarında azalır [10]. Bu azalma özellikle hareketi gerçekleştiren kol ya da bacağı kontra-lateral (çapraz) olan beyin bölgesinde gerçekleşir ve olaya ilişkin eşzamansızlık (ERD) olarak adlandırılır. Aynı şekilde artan ritim olaya ilişkin eşzamanlılık (ERS) olarak bilinir ve genellikle hareketin gerçekleşmesinden sonra görülür [10]. BBA cemiyeti, ERD ve ERS örüntülerinin tanımlanmaları için, doğrusal sınıflandırıcılar, yapay sinir ağları, doğrusal olmayan Bayes sınıflandırıcıları, en yakın komşu sınıflandırıcıları ve tüm bu sınıflandırıcıların farklı birleşimlerini [4, 5] kullanmışlardır. Bu çalışmada farklı beyin bölgelerine karşılık gelen elektrotlardan toplanan sinyallerdeki frekans yapısının değişimi HMMler kullanılarak modellenmiştir.

Saklı Markov modelleri (HMM) başta konuşma tanıma olmak üzere farklı birçok alanda kullanılmışlardır [11]. HMMler bir sinyal ya da örüntüdeki farklı durumlar arasındaki geçiş olasılıkları ve bu durumlara ilişkin öznitelik vektörleri arasındaki koşullu olasılıkları kullanırlar. HMMler iki sınıflı BBA problemlerinde zamansal serilerin [2, 8] ve ham EEG verilerinin [12] sınıflandırılmalarında kullanılmışlardır. BBA alanında henüz çok uygulama bulamamış olmalarına rağmen gelecek vaat ettikleri söylenebilir.

Bu çalışmada, AR öznitelikleri HMM sınıflandırıcıları ile birlikte bir BBA uygulamasında ilk defa kullanıldılar. AR öznitelikleri iyi birer frekans kestiricisi olmalarına rağmen yüksek boyutları nedeniyle HMM parametrelerinin

Bu çalışma 107E135 sayılı TÜBİTAK projesi, bir TÜBA-GEBİP ödülü, ve bir TÜBA lisansüstü bursu ile desteklenmiştir.

öğrenilmesinde problem olabilmektedirler. Bu sorunun üstesinden gelebilmek amacıyla temel bileşen analizi (PCA) ile AR öz niteliklerinin boyutlarını düşürdük. Sonrasında boyutları düşürülmüş bu öz nitelik vektörleri HMMler kullanılarak 2 ve 4-sınıflı birer BBA probleminin çözülmesinde kullanıldılar. Dört sınıflı çalışma BCI Competition IV-2a veri kümesi üzerinde gerçekleştirilirken iki sınıflı sonuçlar kendi kaydettiğimiz BBA deney verileri kullanılarak gerçekleştirildi. Sonuçlar HMM kullanan benzer BBA yöntemleri (bkz. Şekil 2) ve BCI Competition IV-2a veri kümesinde en iyi sonuçları veren algoritmalar ile karşılaştırıldı (bkz. Tablo 1).

## 2. AR-PCA-HMM Yaklaşımı

### 2.1. Özbağlanımlı öz nitelikler

AR parametre kestirimi EEG sinyalinde frekans kestirimi için kullanılan en önemli yöntemlerden birisidir.  $p$ . derece bir AR modeli,  $k$  numaralı elektrottaki EEG sinyali  $y_k(t)$ 'yi, şu şekilde ifade eder:

$$y_k(t) = a_{1,k}y(t-1) + a_{2,k}y(t-2) + \dots + a_{p,k}y(t-p) + E(t)$$

Burada  $a_{i,k}$ ,  $k$  elektrodundaki  $i$ . derece AR parametresini,  $E(t)$  ise sıfır ortalamalı ve sonlu değışintili beyaz gürültüyü ifade etmektedir. AR değışkenleri ile öz ilinti fonksiyonu arasında doğrudan bir ilişki vardır ve bu ilişki Yule-Walker denklemleri kullanılarak tersinir bir şekilde AR parametrelerinin kestirilmeleri için kullanılabilirler. Kullanılan her EEG kanalı için en küçük kareler kestirimi ile AR parametrelerini hesapladık. Parametreler her bir EEG tek denemesi için kayan pencereler içerisinde hesaplandılar. Dört EEG kanalı kullanıldı,  $C_3, C_4, C_z, P_z$ . Bu kanallar beyindeki motor hareket bölgeleri ile olan ilgilerinden dolayı seçildiler. Her bir deneme için öz nitelik matrisi  $F$  aşağıdaki gibi hesaplandı:

$$F = \begin{bmatrix} a_{1,C_3}(1), & \dots, & a_{1,C_3}(M) \\ \vdots & \ddots & \vdots \\ a_{p,C_3}(1), & \dots, & a_{p,C_3}(M) \\ a_{1,C_4}(1), & \dots, & a_{1,C_4}(M) \\ \vdots & \ddots & \vdots \\ a_{p,C_4}(1), & \dots, & a_{p,C_4}(M) \\ a_{1,C_z}(1), & \dots, & a_{1,C_z}(M) \\ \vdots & \ddots & \vdots \\ a_{p,C_z}(1), & \dots, & a_{p,C_z}(M) \\ a_{1,P_z}(1), & \dots, & a_{1,P_z}(M) \\ \vdots & \ddots & \vdots \\ a_{p,P_z}(1), & \dots, & a_{p,P_z}(M) \end{bmatrix}_{4p \times M}$$

Burada  $M$  kayan pencere sayısını belirtirken,  $a_{i,k}(m)$ ,  $m$ . penceredeki AR parametrelerini ifade eder. Bildirinin devamında  $F$  matrisinin her bir kolonu, veri kümesinin etiketli olması durumunda  $f_m^c$ , etiketsiz olması durumunda ise  $f_m$  olarak kullanılacaktır. Burada  $c$  sınıf etiketini belirtir ve  $m \in [1, \dots, M]$ ,  $c \in [1, \dots, 4]$  dir.

### 2.2. Temel Bileşen Analizi

PCA dikey doğrusal bir dönüşüm olup veri kümesini, dönüştürülen veri kümesi istatistiksel olarak ilintisiz olacak

şekilde, özuzay denilen yeni bir uzaya eşlemler.

Bu analizi uygulayacağımız  $f_m$ ,  $r = 4p$  boyutunda sıfır ortalamalı ve ortak değışinti matrisi  $\Sigma$  olan bir öz nitelik vektörü olsun. Özdeğerler ve özvektörler özayırıştırma ile hesaplanabilirler:

$$\Lambda_m = W_m^T \Sigma_m W_m$$

$W_m, \Sigma_m$  ortak değışinti matrisinin özvektörü,  $\Lambda_m$  ise karşılık gelen köşegen özdeğer matrisidir. Bu özvektörler temel bileşenler olarak da bilinirler. Özuzaya yapılacak olan dönüşüm şu şekilde gerçekleştirilir:

$$z_m = W_m f_m$$

Öz nitelik vektörünün boyutları özdeğerler sıralanıp karşılık gelen  $W_m$ 'nin ilk  $s$ ,  $s < r$ , kolonu kullanılarak gerçekleştirilebilir.

Her bir kayan pencere için ayrı bir özvektör hesapladık. Bunun için öncelikle dört EEG kanalını kullanarak her EEG tek denemesi için AR öz niteliklerini 2.1. bölümünde anlatıldığı gibi hesapladık. Daha sonra her kayan pencere için farklı sınıf verilerini  $G_m^n$  matrisinde art-arda sıraladık:

$$G_m^n = [ f_m^1, \dots, f_m^4 ]_{4.p \times 4}$$

burada  $n \in [1, \dots, N]$  ilgili tek deneme numarasını belirtirken  $N$  toplam tek deneme sayısıdır. Notasyon basitliğini koruyabilmek amacıyla bundan böyle  $f_m^c$ 'deki tek deneme indisindeki  $n$ 'ye olan bağımlılık gözardı edilecektir. Her denemede ilgili pencerelere karşılık gelen öz nitelik vektörleri art arda sıralanarak  $H_m$  matrisi oluşturuldu:

$$H_m = [ G_m^1, \dots, G_m^N ]_{4.p \times 4.N}$$

Her bir  $m$  kayan penceresi için  $f_m$  ortak değışinti matrisi şu şekilde hesaplandı,  $\hat{\Sigma}_m = H_m^T H_m$ . Daha sonra  $W_m, \hat{\Sigma}_m$  in özvektör matrisi olarak kestirildi.

Pencerelere özgü hesaplanmış olan  $W_m$  matrislerinin ilk  $s$  sırası  $W_m^s$  olarak gösterilmektedir ve her bir düşük boyutlu öz nitelik vektörünün hesaplanmasında şu şekilde kullanılmışlardır:

$$j_m^c = W_m^s f_m^c$$

Son olarak boyutları düşürülmüş öz nitelik vektörlerini art arda koyarak her bir sınıf için düşük boyutlu  $J_{egitime}^c$  vektörlerine ulaştık:

$$J_{egitime}^c = [ j_1^c, j_2^c, \dots, j_M^c ]_{s \times M}$$

Öğrenilmiş olan  $W_m^s$  matrisleri boyut düşürmek amacıyla etiketsiz olan test verileri üzerine uygulandı.

### 2.3. Saklı Markov Modelleri ve Öğrenme

Problemdeki sınıf sayısına göre her bir sınıf için ayrı bir HMM öğrenildi. Durumlara bağılı olan öz nitelik vektörlerinin koşullu olasılık dağılımları Gauss karışımları ile modellendi. Her bir model için iki farklı parametre takımı öğrenildi. İlk takım, HMM durum sayısı (NoS), Gauss karışımları sayısı (NoGM), AR model derecesi  $p$  ve temel bileşen sayısı  $s$ 'yi içeren *model derecesi parametreleri* dir. İkinci takım ise  $\lambda_c = \{A, B, \Pi\}$  ları içeren *model değışkenleri* olarak belirlendi. Burada  $A$  durum değışim olasılıklarını,  $B$  gözlem olasılık dağılımlarının ortalama ve değışintilerini ve  $\Pi$  başlangıç durum dağılımlarını belirtir (bkz. [11]).

Veri kümesini, iki sınıflı problem için ( $F_{egitim}^c$  (60%) ve ( $F_{test}^c$  (40%)) olmak üzere ikiye, dört sınıflı problemde ise literatürdeki diğer sonuçlarla karşılaştırabilmek amacıyla ( $F_{egitim}^c$  (40%), ( $F_{dogrulama}^c$  (30%)) ve ( $F_{test}^c$  (30%)) olacak şekilde üçe ayırdık.


Sabit bir model-derece parametre kümesi için eğitim verisi ile EM algoritması kullanılarak model parametreleri öğrenildi. İki sınıf verisinde, öğrenilen model parametreleri kullanılarak test verisi olası bazı model-derece parametrelerine göre sınıflandırıldı ve en yüksek doğru sınıflandırma olasılığını veren sonuçlar rapor edildi. Dört sınıflı veride, doğrulama verisi sınıflandırmasında en iyi sonuçları veren model-derece parametreleri öğrenildi ve sınıflandırıcılar test verisi üzerinde öğrenilmiş olan bu model-derece parametreleri kullanılarak denendi. Doğrulama ve test verisinden elde edilen sonuçlar Şekil 2'de görülmektedir.

### 3. Deneysel Sonuçlar

#### 3.1. Deneysel Düzenliği

Bu çalışmada iki farklı veri kümesi kullanıldı. İki sınıflı veri kümesi Sabancı Üniversitesi Yapay Görme ve Örneği Analizi laboratuvarı VPALAB EEG odasında 12 farklı denekten kaydedildi. Deneklerden ekranda gördükleri sağ ya da sol ok işaretine göre karşılık gelen işaret parmakları ile klavyedeki bir tuşa bastıklarını düşünmeleri (hayal etmeleri) istendi. Bu işlemin bir defa tekrarlanmasına bir tek deneme denilmektedir. Bu veri kümesinde her bir sınıf için 20 adet tek deneme yer almaktadır. Deneyin ayrıntıları BCI Competition IV-2a veri kümesindeki olduğuna benzerdir. Bu çalışmada kullandığımız ikinci veri kümesi olan BCI Competition IV-2a verisi 9 farklı kişinin EEG verisinden oluşmaktadır. Bu veri kümesinde dört farklı hareketin zihinde canlandırılması mevcuttur. Bunlar, sol el hareketinin düşünülmesi, sağ el hareketinin düşünülmesi, ayağın hareket ettirildiğinin düşünülmesi ve dil hareketinin düşünülmesidir. Farklı iki günde yapılan toplam 12 seansta EEG kayıtları yapılmıştır. Herbir seansta sınıf başına 12 adet tek deneme gerçekleştirilmiştir.

Deney sırasında denekler bilgisayar ekranı önünde rahat bir kollu sandalyeye oturtulmuşlardır.  $t = 0s$  anında ekranda bir artı işareti gösterilmiştir.  $t = 2s$  anında gerçekleştirilmesi istenilen zihinde canlandırılacak harekete yönelik bir yön işareti gösterilmiş ve bu işaret ekranda 1.25s süresince kalmıştır. Deneklerden 6. saniyenin sonuna kadar ilgili hareketi zihinlerinde canlandırmaları istenmiştir. Deney paradigması Şekil 1'de görülmektedir.




Şekil 1: Elektrot Konfigürasyonu ve Deneysel Paradigması

EEG kayıtları, uluslararası 10-20 EEG sistemine göre


dizilmiş 22 Ag/AgCl elektrot kullanılarak gerçekleştirilmiştir. Sinyaller, sol mastoid referans ve sağ mastoid toprak olacak şekilde tek kutuplu olarak kaydedildiler (bkz. Şekil 1). Sinyaller 250Hz de örneklendiler ve 0.5Hz ile 100Hz arasında süzgeçlendiler. Buna ek olarak 50Hz çentik süzgeç kullanıldı.

Dört sınıflı veri için, [1] ve [6] çalışmalarında da olduğu gibi ilk 8 deneğin verileri kullanılmıştır.


#### 3.2. Sonuçlar



(a) İki sınıf sonuçları



(b) Dört sınıf sonuçları



(c) Dört sınıf doğrulanmış sonuçlar

Şekil 2: 2 ve 4 sınıf sınıflandırma sonuçları

Şekil 2'de önerilen AR-PCA-HMM yaklaşımı ile AR-HMM, Hjorth-HMM ve AR-Mahalanobis yaklaşımlarının karşılaştırmaları verilmiştir. Şekil 2(a)'da iki sınıflı problem için farklı model parametreleri ( $s \in [2, 3, \dots, 10]$ ,  $p \in$

Tablo 1: AR-PCI-HMM ile BCI Competition IV-2a verisi üzerinde en iyi sonuçları veren sınıflandırıcıların karşılaştırılması.  $\kappa = (C \times PCC - 1)/(1 - C)$ . Doğru sınıflandırma olasılığı  $1/C$  ye yaklaştıkça  $\kappa$  sıfıra yaklaşmaktadır.  $C$  sınıf sayısını temsil ediyor.

Öznitelik / Sınıflandırıcı	$\kappa_{ortalama}$	S1	S2	S3	S4	S5	S6	S7	S8
AR-PCA / HMM	.65	.93	.91	.34	.36	.95	.01	.89	.81
FBCSP / Naive Bayes	.57	.68	.42	.75	.48	.40	.27	.77	.75
CSP / LDA-Bayes	.51	.69	.34	.71	.44	.16	.21	.66	.73
CSP / SVM-Voting	.30	.38	.18	.48	.33	.07	.14	.29	.49
CSP / LDA-SVM	.29	.46	.25	.65	.31	.12	.07	.00	.46
CSP / SVM	.28	.41	.17	.39	.25	.06	.16	.34	.45

[5, 6, ..., 15],  $NoS \in [1, 2, \dots, 5]$  ve  $NoGM \in [1, 2, 3]$  denenmiş ve en iyi sonuçlar karşılaştırılmıştır. AR-PCA-HMM yaklaşımının daha önce Obermaier ve ark. tarafından önerilen Hjorth-HMM yaklaşımından daha iyi sonuç verdiği görülmüştür. PCA'in kullanılmadığı AR-HMM durumunda, iki sınıflı problemde daha belirgin olmak üzere, Hjort öznitelikleri HMM ile daha yüksek başarımla elde etmişlerdir (bkz. Şekil 2(a) ve 2(b)). Şekil 2(c)' de 8 denekten 7'sinde önerilen yaklaşım en yüksek doğru sınıflandırma olasılıklarına erişmişlerdir. Tablo 1 de AR-PCA-HMM ile BCI Competition IV-2a<sup>1</sup> verisinde elde edilen en iyi sonuçlar Cohen'in  $\kappa$  katsayısı cinsinden karşılaştırılmışlardır. AR-PCA-HMM in burada da en iyi sonuçlara eriştiği görülmüştür.

#### 4. Vargılar

Bu çalışmada hareketin zihinde canlandırıldığı BBA problemlerinin çözümü için önce AR öznitelikleri kestirildi ve ardından bu özniteliklerin boyutları PCA kullanılarak azaltıldılar. Boyutları azaltılan bu özniteliklerle herbir sınıf için bir HMM öğrenildi. Bu çalışmanın temel amacı AR özniteliklerinin HMM sınıflandırıcıları ile birlikte kullanılabilirliklerini desteklemek olmuştur.

Sonuçlar, AR özniteliklerinin HMM sınıflandırıcıları için iyi birer öznitelik olduklarını ve AR öznitelik boyutunun azaltılmasının EEG sınıflandırmasında önemli olduğunu göstermektedir. Aynı dört sınıflı veri kümesi üzerinde gerçekleştirilen diğer çalışmalarla yapılan karşılaştırmalar, iyi bir frekans kestiricisi ile kullanıldıklarında HMM sınıflandırıcılarının dinamik yapıları ile diğer durağan sınıflandırıcılardan daha iyi sonuç verdiklerini göstermektedir.

Sonuçlar göstermektedir ki EEG sınıflandırma problemleri için dinamik sınıflandırıcılar durağan bir sınıflandırıcı olan Mahalanobis mesafe sınıflandırıcısına göre daha başarılıdır. Aynı şekilde AR özniteliklerinin HMMler ile daha önce önerilen Hjorth [9] özniteliklerinden daha iyi sonuçları görülmektedir.

<sup>1</sup>Bu çalışmada toplamda iki seans olan veri kümesinden yalnızca ilki kullanılmıştır

#### 5. Kaynakça

- [1] C. Brunner, R. Scherer, B. Graimann, G. Supp, and G. Pfurtscheller. Online control of a brain-computer interface using phase synchronization. *IEEE Trans. Biomedical Engineering*, 53(12):2501–2506, Ara. 2006.
- [2] F. Cincotti, D. Mattia, C. Babiloni, F. Carducci, S. Salinari, L. Bianchi, M. Mariani, and F. Babiloni. The use of EEG modifications due to motor imagery for brain-computer interfaces. *IEEE Trans. Neural Sys. and Rehab. Eng.*, 11(2):131–133, Haz. 2003.
- [3] J. Holsheimer and B. Feenstra. Volume conduction and EEG measurements within the brain: A quantitative approach to the influence of electrical spread on the linear relationship of activity measured at different locations. *Electroencephalography and Clinical Neurophysiology*, 43(1):52–58, 1977.
- [4] F. Lotte, M. Congedo, A. Lécuyer, F. Lamarche, and B. Arnaldi. A review of classification algorithms for EEG-based brain-computer interfaces. *Journal of neural engineering*, 4(2), Haz. 2007.
- [5] D. McFarland and J. Wolpaw. Sensorimotor rhythm-based brain-computer interface (BCI): feature selection by regression improves performance. *IEEE Trans. on Neural Systems and Rehab. Eng.*, 13(3):372–379, Eyl. 2005.
- [6] M. Naeem, C. Brunner, R. Leeb, B. Graimann, and G. Pfurtscheller. Seperability of four-class motor imagery data using independent components analysis. *Journal of Neural Engineering*, 3(3):208–216, 2006.
- [7] C. Neuper, G. Muller, A. Kubler, N. Birbaumer, and G. Pfurtscheller. Clinical application of an EEG-based brain computer interface: a case study in a patient with severe motor impairment. *Clinical Neurophysiology*, 114(3):399–409, March 2003.
- [8] B. Obermaier, C. Guger, C. Neuper, and G. Pfurtscheller. Hidden Markov models for online classification of single trial EEG data. *Pattern Recogn. Lett.*, 22(12):1299–1309, 2001.
- [9] B. Obermaier, C. Munteanu, A. Rosa, and G. Pfurtscheller. Asymmetric hemisphere modeling in an offline brain-computer interface. *IEEE Trans. on Systems, Man, and Cybernetics, Part C: Applications and Reviews*, 31(4):536–540, Kas. 2001.
- [10] G. Pfurtscheller, C. Neuper, G. Muller, B. Obermaier, G. Krausz, A. Schlogl, R. Scherer, B. Graimann, C. Keinrath, D. Skliris, M. Wortz, G. Supp, and C. Schrank. Graz-BCI: state of the art and clinical applications. *IEEE Trans. on Neural Systems and Rehab. Eng.*, 11(2):1–4, Haz. 2003.
- [11] L. R. Rabiner. A tutorial on hidden Markov models and selected applications in speech recognition. *Proc IEEE*, pages 257–286, 1989.
- [12] S. Solhjoo, A. M. Nasrabadi, and M. Golpayegani. EEG-based mental task classification in hypnotized and normal subjects. In *Engineering in Medicine and Biology Society, 2005. IEEE-EMBS 2005. 27th Annual International Conference of the*, pages 2041–2043, Oca. 2005.
- [13] J. R. Wolpaw, N. Birbaumer, D. J. McFarland, G. Pfurtscheller, and T. M. Vaughan. Brain-computer interfaces for communication and control. *Clin Neurophysiol*, 113(6):767–791, Haz. 2002.