

EEG TABANLI BEYİN BİLGİSAYAR ARAYÜZLERİ

Önder Aydemir

Karadeniz Teknik Üniversitesi
Elektrik-Elektronik Mühendisliği
Bölümü
onderaydemir@ktu.edu.tr

Temel Kayıkçıoğlu

Karadeniz Teknik Üniversitesi
Elektrik-Elektronik Mühendisliği
Bölümü
tkayikci@ktu.edu.tr

ÖZET

Beyin bilgisayar arayüzü (BBA) kişilere bilgisayar gibi elektronik cihazlarla iletişim kurma imkanı veren yeni bir teknolojidir. Pratik olarak bu teknoloji kişilerin elektroensefalogram (EEG) adı verilen beyin dalgalarını kullanır. EEG tabanlı BBA sistemlerinde elektronik cihazlarla iletişimi sağlayacak çıkış komutları genelde 3 temel adımla elde edilir. Bu çalışmada bu üç adımı oluşturan ön işleme, öznitelik çıkarma ve sınıflandırma aşamaları üzerinde durulmuştur. EEG işaretlerinin sınıflandırılması için çokça başvurulan sınıflandırma algoritmalarından k-en yakın komşuluk (kNN) ve destek vektör makineleri (DVM) üstünlükleri ve kritik noktaları göz önüne alınarak karşılaştırılmalı olarak incelenmiştir. Bu çalışma BBA teknolojisine ilgi duyan araştırmacılar için bir inceleme yazısı niteliğindedir.

ABSTRACT

Brain computer interface (BCI) is a new technology that enables people communicate with electronic devices like computer without any movement. More practically, that technology uses people's brain waves which called electroencefalogram (EEG). In EEG based BCI systems output commands which provide to communicate with electronic devices are obtained generally in three steps. In this paper those three steps which are preprocessing, feature extraction and classification are discussed in detail. K nearest neighbor (kNN) and support vector machines (SVM) algorithms which are used very often to classify EEG signals are analyzed by comparing with each other considering their advantages and critical points. This paper provides a review of the BCI technology for researchers who are interested in that field.

Anahtar Kelimeler: Beyin Bilgisayar Arayüzü, Elektroensefalogram, Sınıflandırma, Öznitelik Çıkarma.

1. GİRİŞ

BBA, kişilerin kas sistemlerini bir başka deyişle motor sinir sistemlerini kullanmadan sadece

düşüncesi ile bir bilgisayarı, elektromekanik bir kolu ya da çeşitli nöroprotezleri kullanmalarını olanaklı hale getiren sistemlerdir. Özellikle bu sistemler felçli ve Amiyotrofik Lateral Sklerozis (ALS) hastalarının hayatlarına ışık tutabilmesi açısından oldukça önemli bir teknolojik gelişmedir.

Günümüzde BBA uygulamalarında EEG, tek hücre kayıtlamaları, fonksiyonel manyetik rezonans görüntüleme, yerel alan potansiyelleri, yakın kızılötesi spektroskopisi, elektrokortikografi, magnetoensefalografi gibi teknikler kullanılmaktadır. Bu teknikler içerisinde BBA sistemleri için genel olarak pratik olarak elde edilmesi ve uygulanmasının kolay olmasından dolayı EEG tercih edilmektedir.

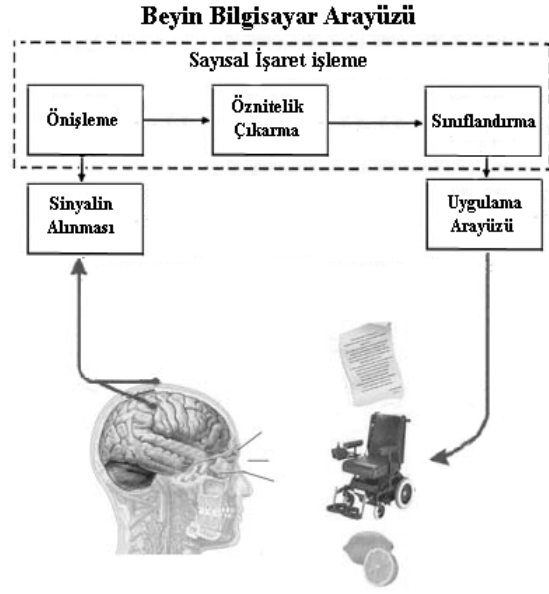
Elektroensefalogram (EEG) işaretleri beyin yüzeyinden veya saç derisi üzerinden elektrotlarla ölçülen düşük genlikli (tepeden tepeye 1-400 μ V) biyoelektrik işaretlerdir (acı vermemesi bakımından genelde bu işaretler saç derisi üzerinden alınmaktadır). Yapılan araştırmalar bu işaretlerde çok miktarda nörolojik bilgi saklandığını ortaya çıkarmaktadır. Son 15 yılda EEG işaretlerinin incelenmesi hız kazanmış, bu işaretlerle hem hasta tedavi yöntemleri geliştirilmekte hem de bu işaretler yardımı ile bir BBA oluşturularak elektronik cihazlarla haberleşme sağlanmaktadır.

EEG işareti geniş bir frekans bandına (0.5-100 Hz) sahip olmakla birlikte, klinik ve fizyolojik ilgi 0.5 ile 30 Hz arasına yoğunlaşmıştır. Bu frekans aralığı 4 frekans bandına ayrılmıştır. Bunlar:

1. Delta (δ) Dalgaları: Frekansları 0.5-4 Hz, genlikleri 20-400 μ V arasında değişir. Derin uyku, genel anestezi gibi beyin çok düşük aktivite gösterdiği durumlarda karşılaşılmaktadır.
2. Teta (θ) Dalgaları : Frekansları 4-8 Hz, genlikleri 5-100 μ V arasında değişir. Normal bireylerde; rüyalı uyku, orta derinlikte anestezi, stres gibi beyin düşük aktivite gösterdiği durumlarda karşılaşılmaktadır.
3. Alfa(α) Dalgaları: Frekansları 8-13 Hz, genlikleri 2-10 μ V arasında değişir. Uyanık durumdaki bireylerin; fiziksel ve zihinsel olarak tam dinlenimde bulunduğu, dış uyularının olmadığı, gözlerin kapalı olduğu durumlarda görülürler.
4. Beta (β) Dalgaları : Frekansları 13 Hz'den fazla olan işaretlerdir. Genlikleri 1-5 μ V arasında değişir.

Odaklanmış dikkat, zihinsel iş, duyuşal enformasyon işleme, uykunun hızlı göz hareketleri evrelerinde karşılaşılmaktadır. Beta dalgaları en yüksek aktivite düzeyine karşılık gelir.

EEG tabanlı BBA sistemlerinde bilgisayar gibi elektronik cihazlarla iletişimi sağlayacak uygun komutların üretilmesi, farklı düşünsel ve görsel durumlarda oluşan EEG işaretlerinin işlenmesine (öznitelik çıkarma) ve çıkarılan özniteliklere dayalı olarak sınıflandırılmalarına bağlıdır. Şekil 1’de EEG tabanlı bir BBA sisteminin temel işlem bileşenleri gösterilmiştir. Bu işlem bileşenleri bölüm 2, 3 ve 4’te ayrıntılı biçimde açıklanmıştır.



Şekil 1. BBA'nın temel işlem bileşenleri

Beynin elektriksel aktivitesinin keşfedilmesinden yaklaşık 100 yıl sonra ilk BBA araştırmaları 1973 ile 1977 yılları arasında Jacques Vidal tarafından sunulmuştur [1], [2]. Vidal çalışmalarında beyin sinyallerinin bir zihinsel protezi geliştirmek için nasıl kullanılabileceğini göstermiştir. BBA teknolojisi özellikle 1999 yılında yapılan kortikal nöronların direk olarak robotik bir kolu kontrol edebildiğini gösterir ilk deneysel çalışmadan sonra büyük bir aşama kat etmiştir [3]. Bu çalışmadan sonra bu alanda muazzam araştırmalar yapılmaktadır [4].

2. ÖN İŞLEME

Ele alınan işaretin hangi sınıfa ait olduğuna karar verebilmek için öncelikle eğitim verileri üzerinde incelemeler yapılarak farklı sınıflara ait EEG işaretlerinden öznitelikler çıkarılmalıdır. Öznitelik çıkarma işlemi BBA uygulamalarının en temel ve en zor konusunu oluşturur. Çünkü kaydedilen EEG işaretleri düşünsel durumda oluşan nörolojik bilgileri içermesinin yanında gürültü olarak isimlendirebileceğimiz bozucu kaynakları da içerir.

Birçok gürültü kaynağı içeren bir veri üzerinde matematiksel incelemeler yapmak oldukça zordur. Bu bakımdan bir ön işleme arabirimi ile EEG işaretlerine karışan gürültüler giderilmelidir.

EEG işaretlerinin genlikleri çok düşük mertebelerde olduğundan bu hassas işaretlere çeşitli gürültüler kolayca karışabilmektedir. Ölçüm yaparken oda içerisindeki ışığın açık veya kapalı olması ve çevrede elektromanyetik dalga yayabilecek cihazların bulunması gibi dış etkenlerden etkilendiği gibi kişinin gözünü kırpması, kalp atışları, kolunu sağa-sola hareket ettirmesi gibi fiziksel aktivitelerden de çok kolay etkilenebilmektedir.

Literatürde gürültüleri EEG işaretlerinden arındırmak için çeşitli yöntemler kullanılmaktadır. En yaygın olanları bağımsız bileşenler analizi [5], [6], [7] ve filtreleme (lineer ve lineer olmayan) [8], [9] teknikleridir. Dalgacık dönüşümü [10], [11], temel bileşenler analizi [12], kaynak dipol analizleri [13] gibi yöntemler de nörolojik bilgiyi kaybetmeden gürültü arındırma yöntemi olarak kullanılmaktadır. Literatürdeki çalışmalarda en fazla giderilmeye çalışılan gürültü kaynağı göz kırpmasından ileri gelen gürültüdür. Bu gürültü özellikle göze yakın ve oksipital bölgelere konumlandırılmış elektrotlardaki işaretlere karışır.

Gürültülerin yok edilmesinden başka bazı durumlarda başvuru ortalaması alma, eşik değeri belirleme, işaret iyileştirme gibi işlemler de ön işlemeyi oluşturmaktadır.

3. ÖZİNTELİK ÇIKARMA

Öznitelik çıkarma, farklı düşünce durumunda kaydedilen EEG işaretlerinin önemli özelliklerinin çıkarılıp öznitelik vektörünün elde edilmesi işlemidir. Örneğin BBA teknolojili bir tekerlekli sandalyenin kullanıcı aracını ileri götürmek istediği durumda EEG işaretleri nasıl bir örüntü oluşturuyor sorusunun cevabını bulmak bir öznitelik çıkarma işlemidir.

Öznitelik çıkarma işleminde çok farklı yöntemler kullanılabildiği için EEG işaretini tanımlayan farklı öznitelikler elde edilebilmektedir. Çıkarılan her öznitelik vektörü işareti tanımlayabilir fakat sınıflandırma aşamasında hiç biri yüzde yüz doğruluk vermeyebilir. Bundan dolayı, yüksek sınıflandırma başarımları elde etmek için farklı özniteliklerin birlikte kullanımı gerekli olmuştur. Bu şekilde çok sayıda öznitelik kullanan sınıflandırma işlemleri daha iyi sonuçlar vermektedir.

Çoklu elektrot kullanılarak kaydedilen EEG verileri incelenirken, hangi elektrot öznitelik çıkarma için daha uygundur konusu da önemlidir. Beynin farklı

bölgeleri farklı görevler için daha duyarlıdır. Örneğin dokunma duyuları beynin yankafa lobunda beden duyumu bölgesi adı verilen bölgeyle algılanıp yorumlanır. Bunun gibi koklama, işitme, hayal kurma, matematiksel işlemler yapma gibi farklı görevler beynin farklı bölgelerinde daha fazla etki yaratır. Dolayısıyla, çoklu elektrotlu EEG verilerinde tüm elektrotlardan (kanallardan) elde edilen verileri kullanmak yerine, yapılan uygulamaya göre beyinsel aktivitenin yoğun olduğu bölgelerden alınan verileri kullanmak hem sınıflandırma için çıkartılacak en iyi özneliğin bulunmasını, hem de sınıflandırma aşamasında karar verme süresinin kısaltmasını sağlar.

EEG tabanlı BBA alanında yapılan araştırmalardaki amaç, mevcut yöntemlerden daha yüksek sınıflandırma oranına ve beyin-bilgisayar arayüzleşme veri hızına sahip bir yöntem geliştirmektir. Literatürde bu konuda birçok yayın mevcuttur. Öznelik çıkarma işlemi bazen oldukça zaman alıcı işaret analizi gerektirebilmektedir. Mevcut BBA'lar çoğunlukla çıkış komutu üretmek için şu bilgileri kullanırlar: mü (8-12 Hz) ve/veya yüksek beta (18-26 Hz) ritim genlikleri gibi frekans domeni bilgileri, P300 ve yavaş kortikal potansiyelleri (YKP) veya DC potansiyeller gibi zaman domeni dalga formları [14], [15], izgel güç yoğunluğu (power spectral density) değerleri [16], [17] özbağlanımlı (autoregressive, AR) ve uyarlamalı özbağlanımlı parametreler [18], [19]. Eğitim verilerinin zaman domeni ortalamalarına bakarak farklı düşünce durumlarında kaydedilen işaretlerin potansiyellerinin birbirinden farklılık gösterip göstermemesine göre YKP'lerin kullanıp kullanılmayacağı hakkında bir fikir alınabilir. Yine eğitim verilerinin frekans domeni ortalamalarına bakarak hangi frekans bölgesinin (delta, teta, alfa, beta) farklılık gösterdiği incelenerek öznelik çıkarılabilir frekans bandı konusunda da bir öngörüle bulunmak mümkündür.

4. SINIFLANDIRMA

Farklı düşünsel ve görsel durumlarda kaydedilen EEG işaretlerini elde edilen öznelik vektörlerine göre sınıflandırma BBA teknolojisinde önemli bir konudur. İşaretin hangi sınıfa ait olduğuna karar verme hem hızlı hem de doğru olmalıdır. Literatürde birçok sınıflandırma yöntemleri mevcuttur. Bunlardan en çok kullanılanları destek vektör makineleri (support vector machines), k en yakın komşuluk (k nearest neighbor), doğrusal ayırtıcı analizi (linear discriminant analysis), sinir ağları (neural networks), bayes sınıflandırıcısı (bayesian classifier)'dir.

Aynı tür uygulamada değişik sınıflandırma algoritmaları farklı sonuçlar verebilmektedir [20]. Elde edilen öznelik vektörlerine en uygun


sınıflandırıcıyı seçebilmek için sınıflandırma yöntemlerinin özelliklerinin iyi bilinmesi gerekmektedir. Aşağıda BBA alanında sıklıkla kullanılan k en yakın komşuluk ve destek vektör makineleri yöntemlerinin özellikleri, üstünlükleri, kritik noktaları üzerinde durulmuş, performans analizleri incelenmiştir.

4.1. K EN YAKIN KOMŞULUK

KNN algoritması sorgu vektörünün en yakın k komşuluktaki vektör ile sınıflandırılmasının bir sonucu olan denetlemeli, oldukça basit bir öğrenme algoritmasıdır [21]. Buna göre; tanıma yapılacak öznelik vektörüne en yakın k komşu bulunur. Daha sonra bu k komşu en fazla hangi sınıfa ait ise, o sınıf tanıma sonucu olarak atanır. K sayısını belirlemenin en pratik yolu k'yı toplam eğitim örnekleri sayısının karekökünden daha az olarak seçmektir [22]. BBA uygulamalarında bu en yakın k komşular genellikle bir metrik uzaklık kullanılarak elde edilir. En yaygın kullanılan Öklidyen uzaklığına dayalı metriktir [23], [24]. KNN algoritmaları büyük boyutlu öznelik vektörlerinde etkin olmamakla [23], [25], [26] birlikte düşük boyutlu öznelik vektörleri ile etkin olabilmektedirler [20], [27].

4.2. DESTEK VEKTÖR MAKİNELERİ

1960'ların sonlarında V. Vapnik tarafından bulunan istatistiksel bir algoritma olan DVM [28] özellikle EEG işaretlerinin sınıflandırılması aşamasında sıklıkla kullanılır ve geleneksel metotlardan çok daha iyi sonuçlar vermektedir. Yapısal risk minimizasyonu prensibi etrafında formüle edilmiştir ve beklenen riskin üst sınırını küçükmeye çalışır. Şekil 2'de verilen iki ayrı kümeyi birbirinden ayırmak için sonsuz sayıda optimal olmayan hiperdüzlem çizilebilir. Ancak DVM bu iki kümeyi ayırmak için maksimum marjini (en yakın eğitim noktalarının uzaklığı) sağlayan optimal hiperdüzlemi arar.



Şekil 2. Maksimum marjinli hiperdüzlem

Seçilen kernel fonksiyonuna göre doğrusal ve doğrusal olmayan sınıflandırma biçimleri vardır. BBA uygulamalarında çoğunlukla Eşitlik 1’de verildiği biçimde radyal tabanlı kernel (RTK) çekirdek fonksiyonu kullanılır. DVM’de σ değeri ve düzenleme parametresi en iyi sınıflandırma performansı elde edilecek şekilde elle ayarlanabilmektedir.

$$K(x, y) = \exp\left(\frac{-\|x - y\|^2}{2\sigma^2}\right) \quad (1)$$

DVM, uygulamasının hızlı olması ve özellikle yüksek boyutlu öznitelikler için çok iyi sonuçlar vermesinden dolayı BBA alanında sıkça başvurulan bir sınıflandırma yöntemidir. DVM de kNN gibi sınıflandırma işlemi sırasında öznitelik vektörlerin zamansal bilgilerini dikkate almaz bu bakımdan statiktirler. Diğer taraftan DVM sınıflandırıcısında eğitim kümesindeki küçük değişimler sınıflandırma performansını etkilemez bu bakımdan kararlılık özelliği vardır. Sınıflandırma işlemlerinde karşılaşılan bir zorlukta aşırı eğitim (overtraining) durumudur. Bu durumda eğitilen ağ eğitim örneklerini mükemmel olarak uygunlaştırır fakat test setindeki örneklerde doğru sonuçlar vermeyebilir. DVM’de düzenleme parametresi ile aşırı eğitim engellenebilir ve çok iyi sonuçlar elde edilebilir.

5. SONUÇLAR ve TARTIŞMA

EEG işaretleri yapısı gereği sürekli değişim gösteren oldukça karmaşık işaretler olduğundan sağlıklı yorumlanmaları matematiksel yöntemlerle analizlerine bağlıdır. Çok miktarda bilgi içerdikleri gün geçtikçe yapılan çalışmalarla ortaya çıkmakta olan EEG işaretleri, özellikle tıpta teşhis ve uygulanan tedavilerin başarımlarının izlenmesinde kullanıldığı gibi, insanoğlunun hayatına farklı teknolojilerle de gireceği kesindir. EEG uygulamalı teknolojiye atılan adımlardan biri olan BBA sistemleri halen geliştirilme aşamasındaki sistemlerdir. BBA konusu Ülkemizdeki üniversiteler de dahil olmak üzere dünyada bir çok üniversite tarafından çeşitli seviyelerde incelenen oldukça popüler bir araştırma konusudur. Araştırmalar sonucunda dünya nüfusunda göz ardı edilemeyecek kadar yüksek sayıdaki felçli ve ALS hastaları için hayatlarını daha kaliteli yaşayabilme olanağı sunulabilecektir. Özellikle güvenli, acı vermeyen ve kullanımının kolay olması gibi avantajlarının yanında sınıflandırma başarımındaki yetersizlik, veri bit hızının yavaş olması, etkin öznitelik vektörlerinin bulunmasının zaman alması bu alanda dikkat çeken olumsuzluklardır.

Tablo 1. DVM ve kNN sınıflandırıcılarının özellikleri

	Doğrusal DVM	RTK DVM	kNN
Doğrusal	X		
Doğrusal olmayan		X	X
Ayıraç	X	X	X
Statik	X	X	X
Kararlı	X	X	
Kararsız			X
Yüksek boyut dayanıklılığı	X	X	
Düzenleme parametresi	X	X	

İşaret gruplarını birbirinden ayırabilecek etkin bir öznitelik çıkarma yöntemi bu grupları sınıflandırmada da önemli bir rol oynamaktadır. Etkin özniteliklerde de ancak bir ön işleme aracı birimi ile nörolojik bilgiyi kaybetmeden gürültüden tamamen arındırılmış EEG işaretlerini kullanmak sureti ile elde edilebilir. EEG tabanlı BBA’larda sınıflandırma yöntemi olarak düşük boyutlu öznitelik vektörleri için kNN, büyük boyutlu öznitelik vektörleri için DVM algoritmaları sınıflandırmada başarılı sonuçlar vermektedir. Dolayısıyla uygun öznitelik vektörleri için uygun sınıflandırma algoritmasının seçimi çok önemlidir. Tablo 1’de DVM ve kNN sınıflandırıcılarının özellikleri tablo halinde verilmiştir.

Yukarıda da değinildiği gibi farklı düşünsel ve görsel uygulamalarda kaydedilmiş EEG işaretlerinden öznitelik çıkarma işlemi çok önemlidir. Öznitelik çıkartımı için literatürde birçok matematiksel yöntem mevcuttur. Her yöntem her uygulamada iyi sonuç vermeyebilir. Yapılan uygulamaya has matematiksel analizlerle, o uygulamaya ait öznitelik(ler) aranmalıdır. Diğer taraftan farklı insanlardan aynı uygulamaya ait EEG işaretleri de insan fizyolojisi gereği aynı olmayacağından, bulunacak öznitelik(ler) kişiden kişiye de farklı sonuçlar verecektir. Yapılacak çalışmalarda tüm bunların dikkate alınması çalışmanın sağlıklı temellere dayandırılması açısından önemlidir.

KAYNAKLAR

- [1] Vidal, J. J., ‘Direct brain–computer communication’, Ann. Rev. Biophys. Bioengng, 2, 1973, 157–158.
- [2] Vidal, J. J., ‘Real-time detection of brain events in EEG’, IEEE Proc., 65, 1977, 633–664.
- [3] Chapin, J. K., Moxon, K. A., Markowitz, R. S., ve Nicolelis, M. A., ‘Real-time control of a robot arm using simultaneous recorded neurons in the motor cortex, Nature Neurosci., 2, 1999, 664–670.

- [4] Lebedev, M. A., ve Nicoletis, M. A. L., 'Brain-machine interfaces: past, present and future', *Trends in Neurosci.*, 2006, 29(9).
- [5] Xue, Z., Li, J. ve Li, S., 'Using ICA to Remove Eye Blink and Power Line Artifacts in EEG', *Proceedings of the First International Conference on Innovative Computing, Information and Control*, Vol:3, 2006, pp 107-110.
- [6] Nezhadarya, E. ve Shamsollahi, M. B., 'EOG artifact removal from EEG using ICA and ARMAX modeling', *ICBME 2005, Singapore*, 2005.
- [7] Barbati G., Porcaro C., Zappasodi F., Rossini, P.M., Tecchio F., 'Optimization of an independent component analysis approach for artifact identification and removal in magnetoencephalographic signals', *Clinical Neurophysiology*, 115, 2004, pp.1220-1232.
- [8] He, P., Wilson, G. ve Russell, C., 'Removal of ocular artifacts from electroencephalogram by adaptive filtering', *Medical and Biological Engineering and Computing*, vol. 42, 2004, pp 407-412.
- [9] Shoostari, P., Mohamadi, G., Ardekani, B. M. ve Shamsollahi, M. B., 'Removing Ocular Artifacts from EEG Signals using Adaptive Filtering and ARMAX Modeling', *Proceedings Of World Academy Of Science, Engineering And Technology*, Vol:11, 2006, pp 277-280.
- [10] Kumar, P. S., Arumuganathan, R., Sivakumar, K. ve Vimal, C., 'A Wavelet based Statistical Method for De-Noising of Ocular Artifacts in EEG Signals', *IJCSNS International Journal of Computer Science and Network Security*, VOL.8 No.9, 2008, pp 87-92.
- [11] Browne, M., ve Cutmore, T. R., 'Low-probability event-detection and separation via statistical wavelet thresholding: an application to psychophysiological denoising', *Clin. Neurophysiol.*, vol. 113, no.9, 2002, pp. 1403-1411.
- [12] Lagerlund, T. D., Sharbrough, F. W., ve Busacker, N. E., 'Spatial filtering of multichannel electroencephalographic recordings through principal component analysis by singular value decomposition', *J. Clin. Neurophysiol.*, vol. 14, no.1, 1997, pp. 73-82.
- [13] Berg, P., ve Scherg, M., 'A multiple source approach to the correction of eye artifacts', *Electroencephalogr. Clin. Neurophysiol.*, vol. 90, no.3, 1994, pp 229-241.
- [14] Wolpaw, J. R., McFarland, D. J., Neat, G. W. ve Forneris, C. A., 'An EEG-Based Brain-Computer Interface for Cursor Control', *Electroencephalogr. Clin. Neurophysiol.*, vol. 78, 1991, pp 252-259.
- [15] Guger, C., Ramoser, H. ve Pfurtscheller, G., 'Real-Time EEG Analysis with Subject-Specific Spatial Patterns for a Brain-Computer Interface (BCI)', *IEEE Trans. Rehab. Eng.*, vol. 8, 2000, pp 447-456.
- [16] Chiappa, S. ve Bengio, S., 'HMM and IOHMM Modeling of EEG Rhythms for Asynchronous BCI Systems', *European Symposium on Artificial Neural Networks (ESANN)*, 2004, pp199-204.
- [17] Millan, J. R. ve Mourino, J., 'Asynchronous BCI and Local Neural Classifiers: An Over View of the Adaptive Brain Interface Project', *IEEE Trans. Neural Syst. Rehabil. Eng.*, 11 2003, pp159-61.
- [18] Penny, W. D., Roberts, S. J., Curran, E. A. ve Stokes, M. J., 'EEG-Based Communication: a Pattern Recognition Approach', *IEEE Trans. Rehabil. Eng.*, 8: 2000, pp 214-5.
- [19] Pfurtscheller, G., Neuper, C., Schlogl, A. ve Luggner, K., 'Separability of EEG Signals Recorded During Right and Left Motor Imagery Using Adaptive Autoregressive Parameters', *IEEE Trans. Rehabil. Eng.* 6, 1998, pp 316-25.
- [20] Lotte, F., Congedo, M., Lecuyer, A., Lamarche, F. ve Arnaldi, B., 'A Review of Classification Algorithms for EEG-Based Brain-Computer Interfaces', *Journal Of Neural Engineering*, R1-R13, 2007.
- [21] Duda, R. O., Hart, P. E. ve Stork, D. G., '*Pattern Classification*', 2nd edition, Wiley, NY, 2001.
- [22] Rosa, J. L. A. ve Ebecken N. F. F., 'Data Mining for Data Classification Based on the KNN-Fuzzy Method Supported by Genetic Algorithm', *Lecture Notes In Computer Science*, issue: 2565, 2003, pp 126-136.
- [23] Blankertz, B., Curio, G. ve Muller, K. R., 'Classifying single trial EEG: towards brain computer interfacing' *Adv. Neural Inf. Process. Syst. (NIPS 01)* 14 2002, pp 157-64.
- [24] Lan, T., Erdogmus, D., Adami, A. Mathan, S., ve Pavel M., 'Channel Selection and Feature Projection for Cognitive Load Estimation Using Ambulatory EEG', *Computational Intelligence and Neuroscience*, Vol: 2007, Article ID 74895, 2007.
- [25] Muller, K. R., Krauledat, M., Dornhege, G., Curio, G., ve Blankertz, B., 'Machine learning techniques for brain-computer interfaces', *Biomed. Technol.* 49, 2004, pp 11-22,.
- [26] Schlogl, A., Lee, F., Bischof, H. Ve Pfurtscheller, G., 'Characterization of four-class motor imagery EEG data for the BCI-competition 2005', *J. Neural Eng.* 2, L14-22, 2005.
- [27] Borisoff, J. F., Mason, S. G., Bashashati, A., ve Birch, G. E., 'Brain-computer interface design for asynchronous control applications: improvements to the If-asd asynchronous brain switch', *IEEE Trans. Biomed. Eng.* 51, 2004, pp 985-92.
- [28] Vapnik, V., *Statistical Learning Theory*, Wiley, 1998.