

Hayali Motor Hareketleri Tabanlı BBA Sistemlerinde Yarı GÜdümlü Uyarlama Semi-supervised Adaptation of Motor Imagery Based BCI Systems

İsmail Yılmaz*, Sümeyra Demir*, Tolga Taşdizen*[†] Müjdat Çetin*,
*Mühendislik ve Doğa Bilimleri Fakültesi, Sabancı Üniversitesi, İstanbul, Türkiye
Email: {yilmaz, sumeyra, tolga, mcetin}@sabanciuniv.edu
[†]Electrical and Computer Engineering Department, University of Utah, Utah, USA
Email: tolga@sci.utah.edu

Özetçe —Beyin Bilgisayar Arayüzü (BBA) sistemlerinde kullanılan elektroensefalografi (EEG) sinyallerinin durağan olmayan yapısı bu tip sistemlerin günlük hayatta uzun süreli kullanımlarında problemlere neden olmaktadır. Karşılaştığımız bir diğer problem ise etiketli verinin az miktarda olduğu durumlardan kaynaklanmaktadır. Bu çalışmada, bahsedilen iki problemi yarı güdümlü öğrenme bakış açısıyla, BBA sistemini kullandığımız sınıflandırıcının çıktısı olan etiketlerle güncelleyerek çözmeyi öneriyoruz. Hayali motor hareketleri tabanlı BBA sistemi için toplanan EEG sinyallerinden çıkarılan öznitelikler, Doğrusal Ayırtaç Analizi (DAA) ve Destek Vektör Makinesi (DVM) ile sınıflandırılmıştır. Yarı güdümlü öğrenme ile yapılan uyarlamada, uyarlama yapılmayan sınıflandırıcılara göre yaklaşık %4 iyileşme görülmüştür. Etiketli veri kümesinin büyümesi ile iyileşme miktarında azalma tespit edilmiştir. Zaman içinde değişen sinyaller için yapılan uyarlamada da %4 oranında iyileşme görülmüştür.

Anahtar Kelimeler—BBA, EEG, uyarlama, hayali motor hareket

Abstract—One of the main problems in Brain Computer Interface (BCI) systems is the non-stationary behavior of the electroencephalography (EEG) signals causing problems in real time applications. Another common problem in BCI systems is the situation where the labeled data are scarce. In this study, we take a semi-supervised learning perspective and propose solving both types of problems by updating the BCI system with labels obtained from the outputs of the classifier. To test the approach, data from motor imagery BCI system are used. Attributes extracted from EEG signals are classified with Linear Discriminant Analysis (LDA) and Support Vector Machines (SVM). With respect to the static classifiers, accuracy was improved approximately 4% using the proposed adaptation approach in the case of a training dataset. Even though the difference between the performance of static and adaptive classifiers decreases as the size of training data increases, the accuracy of our proposed adaptive classifier remains higher. The proposed approach has also improved the performance of a BCI system around 4% in the case of non-stationary signals as well.

Keywords—BCI, EEG, adaptivity, motor imagery

Bu çalışma TÜBİTAK tarafından 111E056 sayılı araştırma projesi ve bir yurt içi doktora sonrası araştırma bursu ile desteklenmiştir.

978-1-4673-7386-9/15/\$31.00 ©2015 IEEE

I. GİRİŞ

Merkezi sinir sistemi ve omurilik gibi bölgelerdeki motor sinir hücrelerinin zarar görmesiyle, felç gibi bireylerin çevreleriyle iletişim kurmalarını kısıtlayacak ya da tamamen ortadan kaldıracak rahatsızlıklar oluşmaktadır. Beyin-Bilgisayar Arayüzü (BBA) çalışmaları, bu tip motor nöron bozuklukları olan hastalara beyin ile bilgisayar arasında kas hareketi kullanmadan iletişim kanalı oluşturma fikrini taşır. BBA sistemlerinin temelini oluşturan elektroensefalografi (EEG) sinyalleri, kafa derisi üzerinden ölçülerek işlenir ve kullanıcının ihtiyaç duyduğu işlevi açığa çıkarmak için yorumlanır [1].

BBA çalışmalarında önemli yaklaşımlardan biri de hayali hareket sinyallerinin kullanımınıdır. Yüzeysel ölçüm yöntemleriyle toplanan hayali motor hareket sinyallerine sağ ve sol kol hareketleri örnek olarak gösterilebilir. Toplanan bu sinyallerden çıkarılan öznitelikler kullanılarak kişinin hareket isteği sağ ya da sol kol olarak sınıflandırılır. Daha sonra çevrimiçi çalışmalarda sınıflandırıcı sonuçları yardımıyla ekranda imleç hareket ettirme gibi deneyler tasarlanmıştır. Ancak sinyaller; kayıt sırasındaki kalibrasyon ölçümü ve çevrimiçi çalışmalar arasındaki farklılık, elektrotların deney sırasındaki hareketi, jel kuruması, kullanıcının odaklanamama ve yorgunluk durumları gibi sebeplerden durağan olamazlar [2]. EEG’deki durağan olmama hali sınıflandırma çalışmalarını zorlaştırmaktadır [3]. Bu problemi çözmek için literatürde BBA sistemini sinyallerdeki değişimlere uyarlayacak farklı metotlar önerilmiştir. Hasan ve arkadaşları [4], çalışmalarında Gauss karışım modelini ilgili DAA sınıflandırıcısını uyarlamak için kullandı. Buradaki Gauss karışım modeli içindeki ortalama ve ortak değişinti değerleri üzerinde güncelleme yaparak DAA sınıflandırıcısını oluşturup sınıflandırıcının parametrelerini belirlemişlerdir. Blumberg ve arkadaşları da [2] DAA sınıflandırıcısının ortalama ve ortak değişinti değerlerini güncelleyerek hayali motor hareketleri üzerinde çalışmışlardır. Vidaurre ve arkadaşları ise bilgi matrislerinin tahmini uyarlama yöntemi (ADIM) ile çevrimiçi güncellenen sınıflandırıcılar üzerinde çalıştılar [5], [6]. Chavarriaga ve Falkenstein de çalışmalarında kullanıcının sistemdeki hatayı algılaması ile

beyinde oluşan potansiyelleri (error-related potentials, ErrP) kullanarak uyarılma üzerinde çalışmışlardır [7], [8].

Uyarılma, sınıflandırıcının gelen veriye göre kendini, parametrelerini güncellemesini temel alır. Uyarılma ile birlikte sınıflandırıcı performansı geliştirilir. Uyarılma yöntemleri güdümlü öğrenme, güdümsüz öğrenme, yarı güdümlü öğrenme olmak üzere sınıflandırılabilir. Güdümlü öğrenme ile uyarılan sınıflandırmalarda sınıf etiketlerinin bilinmesi gerekir, ancak bu yaklaşım gerçek hayatta sınıf etiketleri olmayan veri ile karşılaşıldığında yetersiz kalacaktır. Güdümsüz öğrenme kullanılan uyarılmalarda ise veri etiketleri kullanılmamaktadır, bu da sınıflandırma yanlış sonuç verdiğinde sistemin yanlış yapmasına neden olabilir [9]. Buna karşılık küçük bir miktar etiketli veri ile büyük bir miktar etiketsiz verinin kullanıldığı yarı güdümlü öğrenme uyarılma için etkili bir alternatif olabilir [10].

Biz bu bildiriye, iki sınıflı hayali motor hareketleri bulunan veri kümesinde, kullanıcının hayali motor hareketlerinin frekans bantlarındaki güç yoğunluğunu öznitelik olarak seçtik. Farklı zamanlama pencerelerindeki verileri ve sınıflandırıcının çıktısı olan etiketleri kullanarak uyarladığımız iki farklı sınıflandırıcı ile EEG sinyallerinin durağan olmama durumlarında kayda değer iyileşmeler elde ettik.

Bildirinin 2. bölümünde kullandığımız veriler ve yöntemler açıklanırken, 3. bölümde deneysel sonuçlara yer verilmektedir. Son olarak, 4. bölümde bu çalışmada ulaştığımız vargılar ve devam etmekte olan çalışmalarımız anlatılmaktadır.

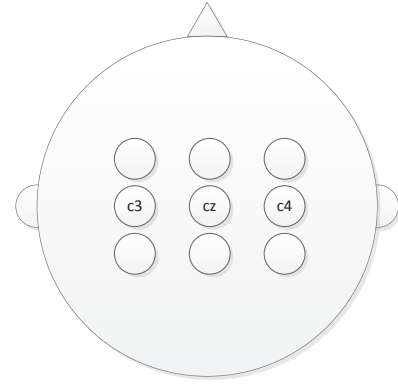
II. VERİLER VE YÖNTEMLER

A. VERİ KÜMESİ 1

Bu çalışmada kullanılan 1. veri Graz Teknik Üniversitesi'nin Biyomedikal Mühendisliği Enstitüsü Tıp Bilişim Bölümü tarafından BCI Competition 2003 yarışması için toplanmıştır. Bu veri, 25 yaşındaki sağlıklı bir kadın denekten kol dayama yeri olan rahat bir sandalyede otururken alınmıştır. Deneğin görevi ekranda gördüğü geri bildirim çubuğunu hayali sol ve sağ el hareketleri aracılığıyla kontrol etmektir. Deneyde 140 eğitim, 140 test olmak üzere 280 sinama grubu vardır. Her sinama grubunun uzunluğu 9 saniyedir. Sinama gruplarının ilk 3 saniyelik hazırlık periyodundan sonra sol ya da sağ gösteren bir ok işareti ekranda belirir. Bundan sonraki 6 saniyede hayal etme gerçekleştirilir. EEG sinyali, 10-20 elektrot yerleşim düzenindeki C3, Cz, C4 kanallarından 128 Hz ile örneklenmiştir. Kanal dizilimi Şekil 1'den incelenebilir. Detaylar için [11] bakılabilir.

B. VERİ KÜMESİ 2

Bu çalışmada kullanılan 2. veri ise Graz Teknik Üniversitesi'nin Beyin Bilgisayar Arayüzleri Laboratuvarı çalışanları tarafından BCI Competition 2005 yarışması için toplanmıştır. Bu EEG veri, 3 kullanıcının her birinden farklı zamanlarda gerçekleştirilen 3 oturumda toplanmıştır. Çalışmalarımızda, aynı deney düzeneğinde toplanan "s4" ve "x11" kullanıcılarının durağan olmayan veri kullandık. Bu deneklerin görevi ekranda gördükleri topu, hayali sol ve sağ el hareketleri aracılığıyla hedef bölgeye yönlendirmektir. "s4" ve "x11" kullanıcılarının her birinin sinama grup sayısı 1080'dir. Her sinama grubunun uzunluğu 9 saniyedir. 4 ile 7 saniyeler arasında



Şekil 1: EEG Kanal Dizilimi

geri bildirim gözlemlenir. 10-20 elektrot yerleşim düzenindeki C3 ve C4 kanallarından 125 Hz ile örneklenen EEG sinyalinin kanal dizilimine Şekil 1'den bakılabilir. Detaylar için [12] bakılabilir.

C. ÖZNETELİK BULMA

Bu çalışmada öznitelik çıkarımı için alfa (8Hz-13Hz), beta (14Hz-18Hz), sigma (18Hz-30Hz) frekans bantlarındaki güç değişimlerinden yararlandık. Bu değişimleri duyumotor ritimleri analiz etmek için kullandık. Bu frekans bantlarındaki spektral güç yoğunlukları kullanıcının hayali motor hareket isteğini gösterdiklerinden [13] bu çalışmada öznitelik olarak kullanıldılar.

D. UYARLAMA METODU

Bu aşamada, yarı güdümlü öğrenme uygulaması olarak, BBA sistemini, kullandığımız sınıflandırıcının çıktısı olan etiketlerle güncelleyerek EEG sinyalini topladıkça uyarlıyoruz. Burada, eğitim verilerinin az olması ve EEG sinyallerinin durağan olmaması durumlarında 2 farklı uyarılma yaklaşımı izledik.

Eğitim verilerinin az olduğu problem ile ilgili uyarılma-mamızda Blumberg'in önerdiği uyarılma yönteminden yola çıkarak [2] Şekil 2'de gösterilen güncelleme yaklaşımını kullandık. Şekil 2'de görüldüğü gibi öncelikle eğitim verileri ile sınıflandırıcı öğrenilir. Daha sonra test verisinden bir grup veri alınıp oluşturulan sınıflandırıcı ile test edilerek tahmini etiketler oluşturulur. Tahmini etiket oluşturma işlemi için her döngüde sıradaki test grup verisi kullanılır. Tahmini etiketler oluşturulduktan sonra sınıflandırılan test verisi grubu, tahmini etiketlerle eğitim verisine eklenir. Test verisindeki tüm gruplar bitene kadar bu döngü devam eder. Burada anlatılan yöntem matematiksel olarak aşağıdaki gibi ifade edilebilir:

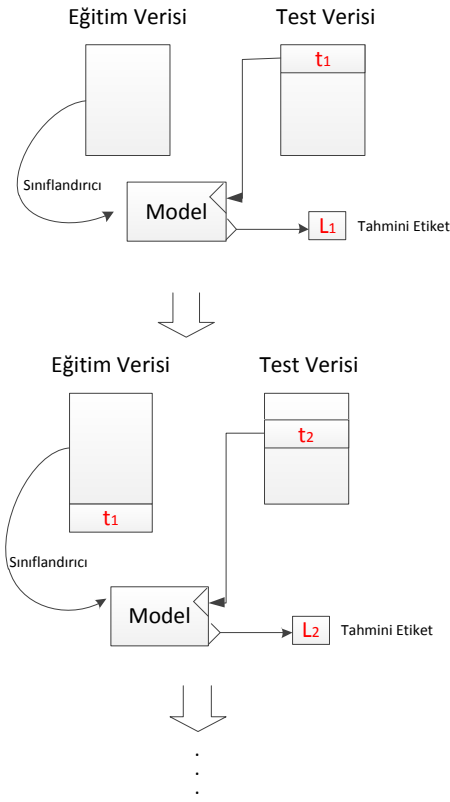
$$M^{i+1} = f_{classifier}(Tr_{n \times m}^{i+1}, Tr_{n \times 1}^{i+1}) \\ = f_{classifier}(Tr^i \cap T(t), Tr_L^i \cap M^i(T(t))) \quad (1)$$

Burada "M" sınıflandırıcının oluşturduğu etiketlere, "Tr_L" ise eğitim verisinin etiketlerine karşılık gelmektedir.

Sınıflandırıcı fonksiyonu olarak kullanılan " $f_{classifier}$ "'ın giriş değerlerinden "Tr" eğitim verisini, "T(t)" ise test verisini göstermektedir. Denklemdeki sütun bazlı ekleme işlemini ifade etmek için kullanılan " \sim " işleci aşağıdaki gibi örneklendirilebilir:

$a = [a_1 \ a_2 \ \dots \ a_n]^T$ ve $b = [b_1 \ b_2 \ \dots \ b_n]^T$ şeklinde tanımlanan matematiksel ifadelerde ekleme işleci kullanıldığında $a \sim b = [a_1 \ a_2 \ \dots \ b_1 \ b_2 \ \dots]^T$ sonucu elde edilir.

EEG sinyallerinin durağan olmaması durumuyla ilgili uyarlamamızda ise Blumberg' in çalışmasına benzer bir güncelleme yaklaşımında bulunduk. Burada, kullanıcıların farklı test verileri ile yaptığımız deneylerde, Şekil 2'den farklı olarak sınıflandırıcının bulunduğu etiketlerle eğitim veri kümesinin sonuna ekleme yaparken, eğitim veri kümesinin başından da eklenen veri miktarı kadar veri silinerek sınıflandırıcıyı durağan olmayan veriye uyarladık.




Şekil 2: Uyarlama Metodu Şeması

III. DENEYSEL SONUÇLAR


Bu bildiriye çalışmamızın, ilk deneyinde birinci veri kümesini kullanarak eğitim verisinin az olduğu durumda yarı güdümlü öğrenme ile uyarlama yaptık; sınıflandırıcı sonuçlarında dikkate değer iyileşmeler gördük. İlk olarak toplamda sınama grup sayısı 140 olan eğitim verisinin 15 tanesini, başlangıç eğitim verisi olarak kullandık. Daha sonra sınıflandırıcının bulunduğu etiketlerle eğitim veri kümesini büyütürken sınıflandırıcının zaman içinde eklenen veriye uyarlanmasını inceledik. Başlangıç eğitim verisindeki sınama

grubu sayısını 15 yerine 20 olarak deneyi tekrarladık ve bu işlemi eğitim veri sınama grubu sayısı 70 olana kadar artırarak sonuçları inceledik.

Şekil 3 ve Şekil 4'te giderek büyüyen eğitim verilerinde Doğrusal Ayırtaç Analizi (DAA) ve Destek Vektör Makinesi (DVM) sınıflandırıcılarının sonuçlarını görmekteyiz. Bu grafiklerde yatay eksen eğitim verisinin deneyin başındaki boyutunu sınama grup sayısı cinsinden gösterirken, dikey eksen sınıflandırıcının ortalama doğruluk değerini yüzde olarak göstermektedir. Burada uyarlama kullanmadan yapılan sınıflandırma işleminin sonuçları ile, uyarlama kullanıldığı sonuçları kıyaslanmıştır. Uyarlama metodunda tahmini etiketlerle ya da test verisinin gerçek etiketleri ile modellerimizi güncellediğimiz iki farklı durumu inceledik. Elde ettiğimiz sonuçlardan yola çıkarak eğitim verisi ne kadar az ise sınıflandırıcı sonuçlarındaki iyileşme oranının o kadar yüksek olduğunu söyleyebiliriz. Ayrıca gerçek etiket kullanımındaki iyileşmenin tahmini etiket kullanımındaki iyileşmeye göre daha iyi olduğu görülebilir. Tahmini etiketler yerine gerçek etiket kullanımı ile uyarlama yaparak elde edeceğimiz en yüksek iyileşme oranını da göstermiş oluyoruz. Elbette gerçek etiket normal şartlar altında ulaşılabilir bir bilgi olmayabilir.



Şekil 3: Etiketli verinin az miktarda olduğu durum (DAA)



Şekil 4: Etiketli verinin az miktarda olduğu durum (DVM)

İkinci deneyde, sistemin yarı güdümlü öğrenme ile zaman içinde değişen sinyallere uyarlanmasında veri kümesi 2 bölümünde anlattığımız durağan olmayan veri kullandık. Burada her kullanıcıdan 3 farklı zamanda veri alındığı için veri her kullanıcı için 3 bölüme ayrılmıştır. Bir kullanıcıdan alınan ilk verinin yarısı 1. seans (s1), ondan sonra alınan veri 2. seans (s2) ve en son alınan veri de 3. seans (s3) diye isimlendirdik. Burada s1 kümesini ("s4" kullanıcısı için 155 sinama grubu, "x11" kullanıcısı için 180 sinama grubu) eğitim verisi olarak, s2 ("s4" kullanıcısı için 355 sinama grubu, "x11" kullanıcısı için 358 sinama grubu) ile s3 ("s4" kullanıcısı için 305 sinama grubu, "x11" kullanıcısı için 355 sinama grubu) veri kümelerini ise ayrı ayrı test verileri olarak kullandık. Bu deneyde amaç; ilk gün veri kaydedildikten sonra takip eden günlerde eğitim ve kalibrasyona zaman ayırmadan, eldeki veri ile sistemi çalıştırıp zaman içinde gelen veriye sınıflandırıcının adapte olmasını sağlamaktır.

Tablo I ve Tablo II'de uyarlanmanın durağan olmayan sinyaller üzerindeki etkisini, Doğrusal Ayırtaç Analizi (DAA) ve Destek Vektör Makinesi (DVM) sınıflandırıcısı ile her kullanıcı için gözlemledik. Tablo I'de s4, Tablo II'de x11 kullanıcı verilerinin deneysel sonuçları yer almaktadır. Burada da uyarlama kullanılmadan yapılan sınıflandırmaya işleminin sonuçları ile, uyarlama kullanıldığında sonuçlar kıyaslanmış ve beklendiği üzere gerçek etiket kullanımındaki iyileşmenin tahmini etiket kullanımındaki iyileşmeye göre daha iyi olduğu gözlemlenmiştir.

Eğitim-Test	Sınıflandırıcı	Uyarlamasız	Tahmini Etiket	Orijinal Etiket
s1-s2	DAA	67.10	69.85	71.86
s1-s3	DAA	66.75	68.78	70.50
s1-s2	DVM	67.49	69.91	71.58
s1-s3	DVM	67.18	69.01	73.91

Tablo I: Zaman içinde değişen sinyaller için uyarlama sonuçları (s4)

Eğitim-Test	Sınıflandırıcı	Uyarlamasız	Tahmini Etiket	Orijinal Etiket
s1-s2	DAA	70.39	72.09	77.18
s1-s3	DAA	83.35	84.53	85.63
s1-s2	DVM	70.87	73.57	76.84
s1-s3	DVM	83.86	85.24	86.06

Tablo II: Zaman içinde değişen sinyaller için uyarlama sonuçları (x11)

IV. VARGILAR

Bu çalışmada tasarlanan hayali motor hareket deneyinde, etiketli verinin az olduğu veya zamana göre değişiklik gösteren EEG sinyallerinin olduğu durumlarda sınıflandırıcıların elde ettiği etiketleri kullanması ile yapılan yarı güdümlü uyarlama yönteminin başarımı incelenmiştir. Etiketli verinin oldukça küçük olması halinde, uyarlanan sınıflandırıcının uyarlama yapılmayan statik sınıflandırıcıya göre %5 oranında daha doğru sonuçlar elde ettiği görülmüştür. Etiketli verinin büyümesi ile aradaki fark azalmış, fakat uyarlanan sınıflandırıcı daha iyi bir performans göstermeye devam etmiştir. Bu deneylerde uyarlanmanın verinin gerçek etiketi ile yapılması halinde gözlemlenen iyileşmeye de yer verilmiştir. Gerçek etiketler kullanılarak yapılan güncelleme ile en başarılı uyarlamaya ulaşılabileceği

düşünülmektedir. Bu da bize uyarlama ile ulaşılabileceğimiz nihai noktayı işaretlemesi açısından önemlidir. Deneyler BBA deneylerinde sıkça kullanılan DAA sınıflandırıcısı ve daha karmaşık bir sınıflandırıcı olan DVM sınıflandırıcısı ile gerçekleştirilmiş ve her iki durumda da yapılan uyarlanmanın performans artışına neden olduğu gözlemlenmiştir. BBA deneyinin farklı günlerde kaydedilmesi nedeniyle EEG sinyalinin zaman içinde değişmesinin beklendiği veri kümesinde yapılan uyarlamalarda %4 civarında iyileşme görülmüştür.

Bundan sonraki çalışmalarımızda, gerçek zamanlı bir BBA sisteminde kullanıcının sistemdeki hatayı algılaması ile EEG sinyalinde oluşan potansiyelleri (ErrP) kullanarak uyarlama yapmayı planlıyoruz. Bu araştırmalarda, bu makalede sunduğumuz tahmini etiket ile güncellenen sınıflandırıcı sonuçlarının üzerine çıkarak gerçek etiket kullanımındaki sonuçlara biraz daha yaklaşmayı bekliyoruz.

KAYNAKÇA

- [1] 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, no. 6, pp. 767–791, 2002.
- [2] J. Blumberg, J. Rickert, S. Waldert, A. Schulze-Bonhage, A. Aertsen, and C. Mehring, "Adaptive classification for brain computer interfaces," in *Engineering in Medicine and Biology Society, 2007. EMBS 2007. 29th Annual International Conference of the IEEE*. IEEE, 2007, pp. 2536–2539.
- [3] S. D. Power, A. Kushki, and T. Chau, "Intersession consistency of single-trial classification of the prefrontal response to mental arithmetic and the no-control state by nirs," *PLoS one*, vol. 7, no. 7, p. e37791, 2012.
- [4] B. A. S. Hasan and J. Q. Gan, "Hangman BCI: An unsupervised adaptive self-paced brain-computer interface for playing games," *Computers in biology and medicine*, vol. 42, no. 5, pp. 598–606, 2012.
- [5] C. Vidaurre, A. Schlogl, R. Cabeza, R. Scherer, and G. Pfurtscheller, "A fully on-line adaptive BCI," *Biomedical Engineering, IEEE Transactions on*, vol. 53, no. 6, pp. 1214–1219, 2006.
- [6] —, "Study of on-line adaptive discriminant analysis for EEG-based brain computer interfaces," *Biomedical Engineering, IEEE Transactions on*, vol. 54, no. 3, pp. 550–556, 2007.
- [7] R. Chavarriaga and J. del Millán, "Learning from EEG error-related potentials in noninvasive brain-computer interfaces," *Neural Systems and Rehabilitation Engineering, IEEE Transactions on*, vol. 18, no. 4, pp. 381–388, 2010.
- [8] M. Falkenstein, J. Hoormann, S. Christ, and J. Hohnsbein, "Erp components on reaction errors and their functional significance: a tutorial," *Biological psychology*, vol. 51, no. 2, pp. 87–107, 2000.
- [9] T. J. Zeyl and T. Chau, "A case study of linear classifiers adapted using imperfect labels derived from human event-related potentials," *Pattern Recognition Letters*, vol. 37, pp. 54–62, 2014.
- [10] Y. Li, C. Guan, H. Li, and Z. Chin, "A self-training semi-supervised SVM algorithm and its application in an EEG-based brain computer interface speller system," *Pattern Recognition Letters*, vol. 29, no. 9, pp. 1285–1294, 2008.
- [11] B. Blankertz, K. Muller, G. Curio, T. M. Vaughan, G. Schalk, J. R. Wolpaw, A. Schlogl, C. Neuper, G. Pfurtscheller, T. Hinterberger *et al.*, "The BCI competition 2003: progress and perspectives in detection and discrimination of eeg single trials," *Biomedical Engineering, IEEE Transactions on*, vol. 51, no. 6, pp. 1044–1051, 2004.
- [12] A. Schlögl, F. Lee, H. Bischof, and G. Pfurtscheller, "Characterization of four-class motor imagery EEG data for the BCI-competition 2005," *Journal of neural engineering*, vol. 2, no. 4, p. L14, 2005.
- [13] E. Koyaş, M. Saraç, A. Erdoğan, M. Çetin, and V. Patoğlu, "Control of a BCI-based upper limb rehabilitation system utilizing posterior probabilities (BBA tabanlı üst uzuv rehabilitasyon sisteminin sonsal olasılık değerleri kullanılarak kontrolü)," 2013.