

# BEYİN BİLGİSAYAR ARAYÜZÜ İÇİN DVM MAKİNE ÖĞRENME YÖNTEMİ KULLANILARAK EEG VERİLERİNDEN SAĞ VE SOL EL HAREKET DÜŞÜNCELERİNİN TESPİTİ

Murat KAYA<sup>1</sup>, Mustafa CÖMERT<sup>2</sup>, Yuriy MISHCHENKO<sup>3</sup>

<sup>1</sup>ug.murat.kaya@toros.edu.tr, <sup>2</sup>mcomert@mersin.edu.tr, <sup>3</sup>yuriy.mishchenko@gmail.com

<sup>1</sup>Toros Üniversitesi, Bilgisayar Mühendisliği Bölümü, Mersin, Türkiye

<sup>2</sup>Mersin Üniversitesi, Elektrik Elektronik Mühendisliği Bölümü, Mersin, Türkiye

<sup>3</sup>İzmir Ekonomi Üniversitesi, Biyomedikal Mühendisliği Bölümü, İzmir, Türkiye

## Özet

Beyin-bilgisayar arayüzleri (BBA) insan beyni ile bilgisayar arasında kurulan doğrudan iletişim yollarını oluşturur. BBA verimli protezler ve iletişim teknolojileri gibi alanlarda kullanılırken, günümüzde insanların cihazlarla doğrudan iletişim kurmasına olanak sağlamaktadır. Bu çalışmada, uyarlanmış taşınabilir bir Epoc Emotiv EEG başlığı ve makine öğrenme metotlarından biri olan destek vektör makineleri kullanılarak, EEG verilerinden sağ ve sol el hareketlerinin düşüncesini tespit edebilecek bir BBA sistemi tasarlanmıştır. Uygulanan BBA, tek olay bazında çalışarak yaklaşık olarak %80 doğrulukla, sağ/sol hareket düşüncesinin ayrılmasını sağladı. Önerilen BBA yöntemi, eylemi belirtmek için iki olay kullanıldığında %90-95 doğrulukla çalışıp zihinsel süreçlere bağlı harici cihazların kontrolünü sağlayabilmektedir.

**Anahtar Kelimeler:** EEG, DVM, BBA, MAKİNE ÖĞRENMESİ, ERP, SİNYAL İŞLEME

## A BRAIN-COMPUTER INTERFACE DETECTION OF RIGHT AND LEFT HAND MOVEMENT IMAGERIES FROM EEG DATA USING THE SVM MACHINE LEARNING METHOD

## Abstract

Brain-computer interface (BCI) is a direct communication channel between computer and human brain. BCI can be used as a part of prosthesis and communication technologies, allowing severely disabled people to communicate with machines directly via BCI. In this study, a BCI system is designed that can detect mental imagery of right and left hand movements from EEG data, by using a modified portable Epoc Emotiv EEG headset and the Supported Vector Machines which one of machine learning method. Designed BCI system is found to have approximately 80% accuracy per single imagery event, for separating right and left hand movement imageries. Thus proposed BCI system can offer 90-95% accuracy if used with two imagery events, sufficient for enabling the BCI control of external devices.

**Key Words:** EEG, SVM, BCI, MACHINE LEARNING, ERP, SIGNAL PROCESSING

## 1. GİRİŞ

Beyin-bilgisayar arayüzü (BBA) temel nörobilimdeki son uygulamaların özel bir ilgi alanını oluşturmaktadır. BBA, zihinsel süreçler ile ilgili olarak nöral aktiviteye doğrudan dayanan insan-bilgisayar iletişimi için yeni arayüzler geliştirmeyi amaçlayan modern bir araştırma alanıdır. BBA araştırmalarının bir bölümü, operatörün yalnızca beyindeki nöral aktiviteye dayanan direkt iletişim ve kontrol metotları geliştirmek üzerine yoğunlaşmaktadır. Diğer bir bölümü, yapay algılayıcılar ile toplanan görüş veya duyum değerleri için algılayıcı verisi ile beyindeki nöral sistemleri doğrudan edinerek fonksiyonel olmayan duyu organlarının eksikliklerini gideren yöntemlerin üzerine yoğunlaşmaktadır.

İlk BBA çalışmaları, 1960-1970'li yıllarda Fetze ve arkadaşları tarafından, bireyler üzerinde yapılan deneylerde beyindeki belirli nöron aktivitesinin anlamlandırılabilmesi gösterilmiştir [1]. Benzer şekilde, 1960'lı yıllarda bireyin bir uyarıcıya dikkat verdiğinde uyarıcı geldikten 300-500 ms sonra cevaben beyin yan lobun elektroensefalografi (EEG) sinyalinde görünen büyük bir pozitif sapma keşfedilmiştir [2]. Bu olay-ilişkili potansiyel (event-related potential, ERP) olarak adlandırılan buluş kullanılarak, tamamen felçli insanlardan “evet-hayır” diye ayrılan sinyalleri algılayabilmek için 1980-1990 yılları arasında bir yöntem önerilmiştir. P300-çözücü (P300 decoder) diye adlandırılan bu yöntem, bireye alfabe harflerini sırayla gösterip birey tarafından dikkat verilen harfleri P300 kullanılarak belirlenip, birey tarafından niyetlenen kelimeleri ve cümleleri ortaya çıkartabilmiştir [3], [4].

Modern BBA araştırmalarında dönüm noktası, 2000-2005 yılları arasında, maymunların sensörimotor korteksinde yerleştirilen 16-64 mikro-elektrot dizisi (Micro-Electrode Array, MEA) kullanarak bir sanal robot koluyla “erişme ve tutma” denemeleri olmuştur [5]–[7]. Maymunlar, bir meyve suyu ödülü ile teşvik edilerek ve görsel geri besleme kullanılarak sanal bir elin kontrolünü sağlamıştır [6]. Nöral aktivite ile harici çalıştırıcı kontrolünün yapılabilirliğini göstermesi dışında, BBA işlemi esasında fonksiyonel kortikal organizasyonunun değiştiği keşfedilmiştir. Daha sonraki çalışmada [8], maymunun motor korteksindeki nöronların aktivitelerini görüntüleyerek uzuvların hareketi olmadan gerçek yapay çalıştırıcının hareketlerinin kontrol edilebileceği gösterilmiştir. Kortekste temel sinirsel simgelerin BBA öğrenmesine cevaben hızlı değiştiği de ortaya çıkartılmıştır. Bunu takip eden çalışmada, benzer bir BBA sistemi kullanılarak maymun gerçek robotik el ile kendi kendini besleyebilmiştir [9]. Bu deneylerde maymun, motor korteksindeki nöral aktiviteyi kullanarak gerçek manipülatörün üç boyutlu hareketlerini kontrol edebilmiştir. Bu çalışmalarda, nöral aktivite analizi amacıyla, Popülasyon Vektörü Analizi (Population Vector Analysis, PVA) olarak adlandırılan yöntem uygulanmıştır. Bu yöntemde, beyin-içi MEA kullanılarak maymunun motor korteksinde gerçek zamanlı izlenen bir nöral popülasyonundaki nöron hücrelerinin ateşleme hızları, şu izlenen nöronların bireysel tercih edilen yönleri ile ağırlıklandırılıp toplanmıştır ve bu şekilde manipülatörün gereken hızı belirtilmiştir. Bu araştırma yönünün en yüksek başarısı, 2012'de Pittsburgh Üniversitesinde gerçekleştirilen benzer MEA BBA kullanılarak tetraplejik bir felçli insanın robot kolu kullanarak kendi kendini besleyebilmesi olmuştur [10]. Günümüzde benzer MEA BBA ile 2 yıllık veri toplama sonrası 96 elektrot kullanılarak analiz edilen bir deneyin uçak kontrolü gözlemlenmiş ve bunun sonucunda protez bir kol geliştirmek yerine BBA sisteminin doğrudan çözücü aracılığıyla bilgisayar iletişimine uygunluğu gösterilmiştir [11].

İnvaziv teknikler için çok önemli olan bir dezavantaj, mikro-elektrot dizilerinin beyinde yerleştirilmesi için ciddi cerrahi müdahale gerekliliğidir. Ayrıca, BBA sinyalini sağlayan mikro-elektrot dizileri etrafındaki dokulara zarar verip yara dokusu oluşturulmasına sebep olur. Bu problem, invaziv BBA yöntemlerinde algılayıcının sinyal kalitesinin zamanla düşürmesine yol açar. Bu durumda, sinyal gürültü oranını yeniden artıracak mikro-elektrotların tekrar yerleştirilebilmesi için yeni cerrahi müdahale gerektirmektedir.

Noninvaziv teknikler arasında, elektromiyografi (EMG), çevresel sinirlerden iskelet kaslarına ulaşan elektriksel sinyali kaydetmede kullanılan en kolay nöral aktivite görüntüleme yöntemidir. EMG, doğrudan motor nöronlarının aktivitesine dayalı olması sebebiyle hem yüksek sinyal çözünürlüğü hem de özgünlük sağlar. Örneğin, EMG bir elektromekanik kol kontrolü için, kol ve avuç içi hareketlerini kontrol eden sinirlerdeki sinyalleri bu şekilde doğrudan kullanabilir [12]. Ayrıca EMG, nöral aktiviteyi çevresel sinirlerden hatta tenin yüzeyinden de kayıt edebilir (surface EMG veya sEMG). sEMG, parmak hareketlerinin kontrolü için metot araştırıp pratik bir robotik el protezi yapılmasına öncülük etmiştir [13], [14]. Bu yöntemle kontrol edilebilen el protezleri ticari olarak da hayata geçirilmiştir [15]–[18]. Fonksiyonel manyetik tınlama görüntüleme (fMRI), beyin farklı alanlarında kan akımı değişikliklerine dayanan üç boyutlu nöral aktivite görüntüleme tekniğidir. Aktif beyin alanlarında yüksek seviyede enerji gereksiniminden kaynaklanan oksijen tüketimi ve dolayısıyla kan akışı artmaktadır (hemodinamik cevabı) [19]. Son yıllarda, fMRI BBA araştırmalarında önemli ilerlemeler sağlanmıştır. 2007'de Pittsburgh beyin aktivite yorumlama yarışında [20] sanal gerçeklik çevrelerinde oyun oynayan deneklerin durumunu takip etmek için fMRI BBA örnekleri alınmıştır.

Yarısta bu amacı yüksek doğrulukla sağlayan fMRI BBA yöntemleri ortaya çıkmıştır. fMRI sinyalinin kullanarak denek tarafından izlenen görsel görüntüleri elde edebilen yöntemler de geliştirilmiştir [21], [22].

Noninvaziv tekniklerinin arasında BBA tasarımında en fazla elektroansefalografi (EEG) görüntüleme tekniği kullanılmaktadır. EEG görüntüleme, beyindeki nöronların elektriksel aktivitesi tarafından üretilen elektrik potansiyel değişikliklerinin kafatası yüzeyinden ölçülmesine dayanır. EEG’de ölçülen elektrik sinyali, kafatası kemiklerinin yanı sıra dokulardan elektrotlara geçmek durumundadır. Bu nedenle EEG görüntülerinin uzay çözünürlüğünün kötüdür. Buna karşın EEG’nin zaman çözünürlüğü çok yüksektir (1-10 milisaniye). EEG Bireyin sağ ve sol el hareketi düşüncelerini kullanan ve bilgisayar ekranı üzerinde imlecin iki boyutlu hareket kontrolünü sağlayan bir EEG BBA yöntemi Mcfarland ve arkadaşları tarafından gösterilmiştir [23]. Sözü geçen kontrol için, sağ ve sol beynin sensörimotor alanları tam üzerine yerleştirilen standart 10/20 sisteminin C3 ve C4 EEG elektrotlarının sinyalindeki  $\alpha$  (alfa, 8-12Hz) ve  $\beta$  (beta, 13-30Hz) ensefalografik ritimlerinin genliği kullanılmıştır. Bu şekilde elde edilen EEG sinyali için, kafatasının sağ ve sol tarafındaki elektrotlar arasında yukarıdaki frekans bantlarında spektral güç farkı ölçülmüştür. Bu ölçümlerde, imlecin iki boyutlu hareketinin hızı doğrusal bir modele uyarlanmıştır. Bireyin  $\alpha$  ve  $\beta$  frekanslarını temsil eden EEG sinyali, imleci sola sağa veya yukarıya aşağıya hareket ettirebilmiştir. Bu tarz BBA, Sensörimotor Ritim Modülasyon (SMR) BBA’leri olarak nitelendirilir. Bu tip BBA yöntemlerinde, bireyin beyninin sağ ve sol tarafında sensörimotor EEG ritimlerinin modülasyon edilmesiyle harici cihaza bilgi iletilebilmektedir. 2010 yılda Mcfarland ve arkadaşları benzer yöntemi kullanarak üç boyutlu sanal hareketin kontrolünü de göstermişlerdir [24]. Bu çalışmalardan ortaya çıkan görüşe göre, bireyler beynin sensörimotor ritimlerinin kontrolünü öğrenebilir, BBA kontrolü ve iletişimini de doğrudan öğrenebilmektedir [25].

SMR BBA yöntemlerinin uygulanabilmesi için ana dezavantaj, bireylerin eğitim sürecinin çok uzun (1 aydan fazla) olması görülmüştür. Bu sınıktan dolayı yeni EEG BBA çalışmaları, uzun sensörimotor ritim kontrolü eğitimi yerine kısa BBA ölçümleme oturumu getirmeye başlamıştır. Bu çerçeveyi kullanan bir çalışmada, 34 kanallı EEG cihazı kullanılarak imleç hareketleri EEG sinyaline doğrusal model uygulanmıştır. Üretilen imlecin yörüngeleri ve doğru imlecin yörüngeleri arasında 0,5-0,7 ilişim sağlanabildiği gösterilmiştir. Ayrıca bu şekilde tahmin edilen imlecin hareketlerinde %50-80 aralığında doğruluğa ulaşılmıştır [26].

Sürekli imleç hareketlerini kontrol etmek için imleç hızlarının EEG sinyalinden doğrusal bir modelle hesaplanmasına bir alternatif yaklaşımı, sağ/sol el, ayak hareketi gibi düşünceleri ayrı tarifler olarak kullanan ve bunları makine öğrenme yöntemleri yardımıyla EEG verilerinden tespit eden EEG BBA yöntemleri oluşturmaktadır. Özellikle, Berlin Beyin-Bilgisayar Arayüzleri projesinin amaçları arasında bireyin öğretimini gerektirmeyen, “doğal” nöral EEG sinyali kullanan ve BBA kontrol sinyalleri makine öğrenme yaklaşımları ile ortaya çıkartan EEG BBA yöntemlerinin geliştirilmesi bulunmaktadır [27], [28]. Bu araştırma grubunun çalışmalarında, 128 elektrot yüksek yoğunluklu EEG cihazı ve Linear Discriminant Analysis (LDA) makine öğrenme yöntemi kullanılmıştır. Bu yöntemin yardımıyla EEG sinyalinden bireylerin sağ/sol el ve ayak hareket düşünceleri tespit edilmiştir. Yukarıda bahsi geçen üç zihinsel durumun %80-90 doğrulukla belirlenebildiği aktarılmıştır [28]. Günümüzde dört motor hayalini sınıflandırmada 5 gönüllünün katıldığı bir çalışmada çok katmanlı yapay sinir ağları, kesikli dalgacık dönüşümü, k-en yakın komşuluk ve radyal baz fonksiyon ağları yöntemlerinin birleşimi ve karşılaştırılmasının test edildiği bir çalışmada seçili kanallarda ortalama %86.61, tüm kanallarda ise %78.37 doğruluk değerine ulaşılmıştır [29].

Yukarıdaki formattaki BBA iletişimi için doğrusal diskriminantlar (LDA) ve destek vektör makinelerinden karmaşık Yapay Sinir Ağlarına kadar birçok BBA veri analizi yöntemi incelenmiştir. Bu çalışmalar bir özet makalesinde kapsamlı olarak incelenmiştir [30]. Bu çalışmaya göre BBA uygulamalarında iki ile beş arasında zihinsel durumun %80-90 doğrulukla tespit edilebildiği görülmektedir. İletişim için kullanılacak zihinsel eylemler olarak sağ/sol el parmakları ve ayak hareketi, 3 boyutlu geometrik şekil sanal dönüşü ve matematiksel hesaplama işleri değerlendirilmiştir [31]–[34].

Daha yeni EEG BBA yöntemi, görsel çağrışında durağan durum potansiyeli (Steady State Visual Evoked Potentials, SSVEP) kullanan EEG BBA yöntemidir. SSVEP, 3,5-90 Hz frekansla gösterilen görsel uyarıcılara karşılıklı gelen beynin görsel korteksi üzerinde gelişen aynı frekansta bir EEG tepkisidir. SSVEP’nin önemli tarafı, 30 Hz üstünde olan ve dolayısıyla normalde gözle görünemeyen sinyallerin de SSVEP üzerinde izlenebilmesidir. Örneğin, bireye gösterilen görsel uyarıcı farklı frekanslarda ayarlanarak bireyin görsel korteksindeki tepkisi EEG ile izlenebilmektedir [35]–[37].

Son yıllarda uzaktan robot kontrolü, tekerlekli sandalye kontrolü ve felçli insanlar için bilgisayar arayüz kontrolü gibi yukarıdaki EEG BBA yöntemlerinin çeşitli pratik uygulamaları olarak ortaya konulmuştur. Sensorimotor ritim modülasyonu kullanılarak EEG BBA uzaktan kontrollü bir oyuncak robot geliştirilmiştir [38]. Benzer şekilde uzaktan

robot kontrolü için, EEG BBA motor olaya-ilişkin-potansiyellerine bağlı iki-aşamalı EEG sinyal sınıflandırma sistemi önerilmiştir [39]–[41]. İlerleyen çalışmalarda, felçli bireyler için yönetme kolu, fare ve göz takip sistemi kullanan ve robotik veya bilgisayar kontrolünü sağlayan yardımcı sistemleri geliştirilmiştir [42]–[46].

Başka bir seri uygulamalı BBA çalışmaları robotik tekerlekli sandalyenin kontrolü üzerine yoğunlaşmıştır. Tekerlekli sandalyenin kontrolü için SMR BBA kullanılan sistemde, 64 kanallı EEG cihazı ve LDA yöntemi ile kelime oyunundan hareket düşünceleri çıkarılarak tekerlekli sandalye kontrol edilmiştir [47]. DVM yöntemi ile C3/C4 elektrotlarındaki EEG sinyallerine yoğunlaşmış ve %80-90 doğrulukla hareket düşünceleri ayırt edilerek tekerlekli sandalye kontrol ettirilmiştir [48]. Aynı amaçla Kullback-Leiber uzaklığı kullanılarak EEG elektrotları ve sinyal frekansları ön-seçilerek, motor hareket düşünceleri LDA yöntemi yardımıyla tespit edilmiş, tekerlekli sandalye %80-90 doğrulukla yönlendirilmiştir [49]. Başka bir çalışmada, tekerlekli sandalye kontrolü için SSVEP BBA uygulandığında bireye, sağ-sol ve yukarı-aşağı gibi işaretler gösterilip ayrı frekansla aydınlatılmıştır, SSVEP yöntemi kullanılarak bireyin hangi işarete baktığı belirlenmiş olup tekerlekli sandalyeyi %85-95 doğrulukla kontrol edebileceği belirtilmiştir [50], [51]. Hedefe yönelim üzerine en kısa rota, en hızlı rota bulma algoritmalarının gelişmesi üzerine tekerlekli sandalye kontrolünü navigasyona bırakan bir sistem geliştirilmiştir [52].

Protez birey uzuvlarının, medikal, insan uzuvlarının dayanamayacağı ağır yükteki işler ve eğlence sektörlerinde kullanılabilmesi için hibrit asistan uzuvlar geliştirilmiştir [53]. Benzer şekilde gündelik yaşamda sıklıkla ihtiyaç duyulan kupa bardağına erişme ve tutma, bir şeyleri yemek için doğru pozisyonlarda erişme ve yaklaşırma gibi hareketler için hibrit BBA geliştirilmiştir [54]. Bu gelişmelerle beraber alt, üst uzuv kontrolünü sağlayan BBA' leri fiziksel rehabilitasyona dahil edilmiştir [55], [56]. Felç sonrası el ve bilek kaslarının motor kontrollerini yenileme üzerine zayıf kasları geliştirmenin el ve bilek fonksiyonlarının tekrar kazanılmasını sağlayabileceği gösterilmiştir [57], [58].

Bu hem temel hemde pratik uygulamalar açısından önemli gelişmelerle ilgili maalesef Türkiye'de çok az sayıda kaynak bulunmaktadır. Bu durum BBA alanında Türkiye'deki gelişmeleri ciddi şekilde engellemektedir. Bu görüşe göre bu çalışmamızın bir ana amacı, bir basit BBA sisteminin geliştirilmesini ayrıntılı şekilde açıklayıp ulusal BBA çalışmaları hem donanım hem de yazılım geliştirilmesi açısından destekleyecek bir Türkçe kaynak sağlamaktır. Diğer bir amacımız ise BBA çalışmalarına ve tarihçesine kapsamlı bir şekilde açıklayan bir ulusal kaynak sağlamaktır. Söz konusu çalışmamızda, DVM makine öğrenme yöntemi ve portatif Epoc Emotiv EEG cihazı kullanılarak sağ ve sol el hareket düşüncelerini ayırt eden bir EEG BBA sisteminin geliştirilmesi açıklanmıştır. Uyguladığımız BBA sisteminde sağ ve sol el hareket düşünceleri tek olay bazında %80-85 doğrulukla ayırt edilip, kontrol sinyali üretmek için iki ve daha çok kez tekrarlanan düşünce kullanıldığında %90-95 doğrulukla zihinsel süreçlerle hariç cihazı kontrol edilebilmektedir. Bahsi geçen sistemi geliştirmek için kullanılan donanım ve yazılım yöntemleri aşağıdaki bölümlerde ayrıntılı olarak açıklanmaktadır.

## 2. YÖNTEM

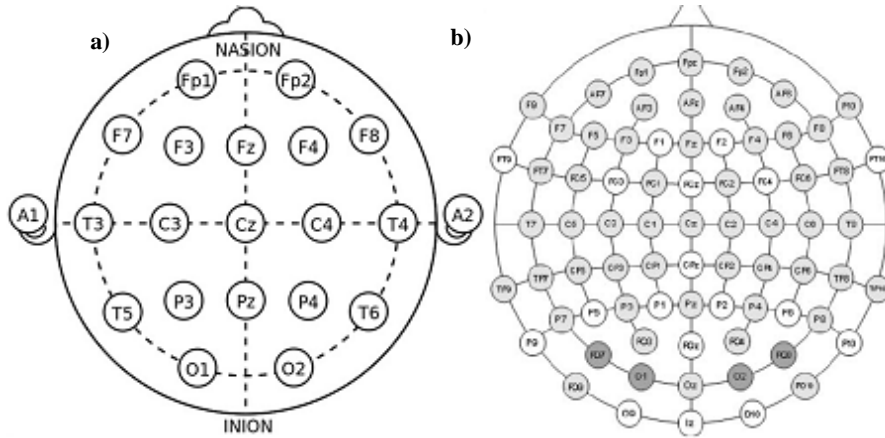
### 2.1. Donanım

Yapılan çalışmamızda uyarlanmış Emotiv Epoc portatif EEG cihazı kullanılmıştır. Orijinal Epoc cihazının yapısı, bir sabit plastik şapka üzerine yerleştirilmiş 18 EEG elektrodundan oluşur. Bu elektrotların 2 tanesi plastik kapakla kapalı şekilde kullanılır ve toprak seviyesini belirtmek için kulak arkasına yerleştirilir. Ayrıca 10/20 sistemin P3 ve P4 noktasına yerleşen iki tane referans elektrotları, cihazın diğer elektrotlarının ölçebileceği düşük seviyede elektrik akımı geçmesini sağlar. Bu 4 elektrot, EEG sinyali elde etmek için kullanılmaz. Buna göre Epoc cihazı tam olarak 14 adet ayrı EEG kanalına sahiptir. Epoc cihazı, 128 Hz örnekleme frekansı ile, 0,5128 mikro Volt çözünürlükle ham EEG veri sağlayabilmektedir [59]. Epoc cihazı yardımıyla elde edilen EEG sinyalinin Sinyal-Gürültü Oranı (SNR), 10-40 Hz frekans aralığında 5-10 dB, 5-10 Hz frekans aralığında 10-15 dB ve 1-5 Hz frekans aralığında 15-30 dB olarak tarafımızdan ölçülmüştür. Ayrıca, Epoc cihazı 50 Hz frekansında çentik filtresine sahiptir. Bu şekilde Epoc cihazı EEG sinyali 1-40 Hz frekansında ölçüm için uygun olup, 1-10 Hz arası EEG sinyalleri için yüksek hassasiyetli olarak görülmektedir.


Emotiv Epoc cihazı, ıslak EEG elektrotları kullanır. Cihazın hazırlanma süresinde, süngerimsi elektrotları serum fizyolojik veya lens suyu ile birkaç damla veya doğrudan ıslatıldıktan sonra monte edilebilir. Serum fizyolojik iyonik bir sıvı olduğundan süngerler, elektrotlar cihaza bağlı olmadan ıslatılmalıdır. EEG cihazının kafatası üzerine yerleşiminde, elektrotların yüzeye iyi oturmasına dikkat edilmelidir. Özellikle P3/P4'deki referans elektrotları gerek varsa parmakla biraz bastırılabilir. Bu süreçte Emotiv bonesinin kafatası üzerinde doğru yerleşimi çok önemlidir. İzole elektrotların kulağın arkasındaki kemiğin üzerine, en öndeki AF3 ve AF4 elektrotların kullanıcının gözlerinden 3-5

cm (2-3 parmak) yukarı yerleştirilmesi gerekmektedir. Elde edilen elektrot yerleşim düzeni, Emotiv kontrol paneli yazılımı kullanılarak kontrol edilebilir. Emotiv kontrol paneli yazılımı, montajda olan tüm elektrotların eşdeğer dirençlerini, siyah, kırmızı, kahverengi, sarı ve yeşil renk yelpazesinde göstererek yüksekte düşüğe temsil etmektedir. Bu yelpaze yaklaşık olarak 50 Kohm altına denk gelir. Yeşil veya sarı renkler eşdeğer dirençlerin veri elde etme için uygun olduğunu gösterir. Eşdeğer direnç ölçümlerinin başlaması için, P3/P4 referans elektrotların kafaya bağlı olması gerekir. Bu nedenle, Epoc montajının yerleşimi sağlamaya çalışırken, referans elektrotlarının yerleşimine öncelikli öneme sahiptir. Bununla birlikte, elektrot-deri arasındaki eşdeğer direnç yüksek olduğu takdirde ilgili elektrotlarından ham EEG sinyali elde edilir ve kaydedilebilir, fakat bu durumda ilgili elektrotların sinyal-gürültü oranı düşük olup iyi EEG sinyal kaydı elde edilememektedir.

Orijinal montajında Epoc cihazı, BBA çalışmalarında en çok kullanılan sensör motor korteks alanı için yeterli elektrot kanal sayısına sahip değildir. İlgili bölgelerden EEG verilerini alabilmek için, Epoc montajın montaj edilmesine ihtiyaç vardır. Bu çalışmada ilgili uyarılama işlemi, esnek kumaş malzeme ile uluslararası 10/20 elektrot yerleşimi göz önünde bulundurularak geliştirilen EEG bonesi tasarlanarak gerçekleştirilmiştir. EEG uluslararası 10-20 sistemine göre en az 19 EEG kanallı kullanılmaktadır. Uluslararası 10-20 sistemi ile elektrotları yerleştirmek, tüm saçlı derinin aynı şekilde kaplanmasını sağlar. Bu sistem baş üzerindeki kemik işaret noktaları arasındaki uzaklıkları kullanır, başı boydan boya ve toplam uzunluklarının %10 veya %20'si kadar olan aralıklarla bölünen bir çizgi sistemi yaratır. Elektrotlar ise bu çizgi sisteminin kesişme noktalarına yerleştirilir. 10-20 sistemi simetrik ve aynen yinelenen bir elektrot yerleşimi olanağı sağlar. Bu sistem esnek olup ek elektrot yerleştirme olanağı veren bir sistemdir. Yoğun elektrot yerleşimlerinde ise oran 10-10 ya da 10-5 olarak azaltılarak elektrot sayısı artırılır ve yerleşim sıkılaştırılır (Şekil 1).



Şekil 1 a) Uluslararası 10-20 EEG yerleşimi. (International 10-20 placement) b) Yoğunlaştırılmış EEG yerleşimi (Dense EEG arrangement)




Şekil 2 Uyarlanan Epc elektrot montajımız (Modified Epc electrode cap)

Bahsi geçen modifikasyonu uygulamak için, söz konusu cihazın orijinal plastik şapkası tarafımızdan açılmış ve elektrotlar dışarı çıkartılıp yeni düzende bağlanmıştır ve elektrotları kaplayan yalıtkanları çıkarılmıştır. Orijinal Emotiv elektrot kablolarının yeterince uzun olmaması ve iç dirençlerinin yüksek olması nedeniyle yeniden kablolama yapılması gerekmektedir. İç dirençleri daha düşük olan atlama kabloları standart 2,54 mm erkek soket kullanılarak, mikroişlemci tarafında da standart 2,54 mm dişi soketler ile karşılandı (Şekil 2 ve Şekil 3).



Şekil 3 a) Orijinal Epc cihazı (Original Epc EEG device) b) Mikro kontrolcü için erkek soket kullanılarak uyarlanmış Epc cihazı (Modified Epc device with male sockets from microcontroller)

Elektriksel değişiklikler yapıldıktan sonra, elektrotlar esnek kumaş ve düğme iliği kullanılarak ikincil pedlere oturtuldu. Pedler çitçit yardımı ile şapkaya yerleştirildi. Bu sayede yeni EEG şapkası başa geçirilirken elektrotların hareket etmesi veya çıkması engellendi (Şekil 4).



Şekil 4 a) Çıt çıtlı pedler (Snap pads) b) Dişi mikro kontrolcü soketli bone (Bonnet with female microcontroller sockets)

Selefinden farklı olarak yeni şapkada ilikli pedler yerine şapka üzerine doğrudan ilik açılmıştır. Ayrıca elektrotların kablo yerleşimi eski şapkada ve cihazın orijinalinde yan kısımda olması nedeniyle iliklerin sıkıştırılması ve başa takılması sırasında ortaya çıkan hareket sonucu lehim bölgelerinde meydana gelen kopmaların önüne geçebilmek için, elektrot yalıtkanının üst kısmında delik açılarak denenmiştir. Ancak elektrot kapağının kırılmasına sebep olduğundan söz konusu Eloc elektrodunun modifikasyonu önerilmemektedir.

Bu modifikasyon süreci sırasında; ince ve zayıf olan orijinal Eloc elektrot kabloları için ısı ayarlı bir havya kullanılması, ayrıca Elektrotların gürültü ve karışmış sinyallere neden olmasının önüne geçebilmek için makaron kullanılarak yalıtılması gerekmektedir. Elektrotların sünger petlerin sıkışması ve dönmesinden kaynaklı olarak bone kafaya yerleştirilirken yerinden çıkma sorunu şapka üzerine ilik ve çıt çıtlı pedlerin kullanımı ile çözüldü. Şapkaya yerleştirilen uzatılmış elektrot kablolarına ve soketlemeye sahip Eloc cihazı kullanan kişinin boynuna takıldı.

## 2.2. Yazılım

Uyarlanmış Eloc cihazının gerçek zamanlı ham verileri kullanılarak bir BBA sistemin uygulanması için tarafımızdan iki tane yazılım geliştirilmiştir. Birinci yazılım, Eloc cihazından veri elde etmek için, ikinci yazılım ise BBA algılama modeli yaratmak için kullanılmıştır.

Ham veri elde etme yazılımımız, Emotiv yazılım paketinde bulunan “logger” isimli örnek kullanılarak “Emologger” isimli bir Matlab nesnesi olarak tasarlanmıştır. Emologger programımızın kodu bu makalenin ekinde verilmiştir. İlgili yazılım 3 kısımdan oluşmakta ve yapısı aşağıda özetlenmektedir. Söz konusu nesnenin 1. kısmı, Emotiv Eloc “Research” lisanslı yazılım paketinde bulunan edk.dll Emotiv dinamik bağlantı kütüphanesini kullanarak EmoEngine’den ham EEG verilerini elde etmekle sorumludur. Ardından edk.dll kütüphanesinin fonksiyonlarına Matlab programında bulunan “loadlibrary” Matlab fonksiyonu kullanılarak erişim sağlanabilir. Emologger nesnesinden ham veri elde etme işlemi, “connect”, “wait\_data”, “get\_data” ve “close” özel metotları kullanılarak gerçekleştirilir.

Emotiv Engine’deki ham veri elde etme işlemi edk.dll bağı ile başlatılır. Sonrasında veri kontrol işaretçisi oluşturulur ve veri önbelleği başlatılır. Önbelleği gösteren veri kontrol işaretçisi periyodik olarak güncelleştirilerek, önbelleğe yeni gelen ham EEG verilerinin kullanıcı programına kopyalanabilmesini sağlar. Bu sıraya göre Emologger yazılımının ilk aşamasında, Emologger’in “connect” metodu kapsamında “EE\_EngineConnect” fonksiyonu kullanılarak EmoEngine ile bağlantı kurmakta, sonrasında EmoEngine’nin veri önbelleğini ve Eloc cihazındaki olaylar ve verilere erişmek için gereken EEEEvent, EEDataHandle nesnelere, EE\_DataCreate ve EE\_EmoEngineEventCreate fonksiyonları kullanılarak tanımlanır. Ham veri elde etmek için EEEEvent nesnesine aslında gerek yoktur. EEEEvent nesnesi

EmoEngine'deki olayları kullanıcı programına iletir ve ham veri elde edilmesi hiç bir olay kullanmadan, EmoEngine'nin veri önbellegi periyodik olarak sorgulanarak ta gerçekleştirilebilir. Fakat EEEEvent nesnesi Epoc cihazının bağlı olup olmadığı ve veri iletmeye hazır olup olmadığını kontrol etmek için gereklidir. İlgili işlem, yani

Epoc cihazının hazır olmasının beklenmesi, Emologger'in "wait\_data" metodunda uygulanır. Bu metod, Emologger nesnesi EEEEvent yoluyla "EE\_UserAdded" olayı gelene kadar belirli bir süre döngü içerisinde bekler.

Emologger'ın "get\_data" metodu yeni gelen veriyi bir dizi değişkenine kopyalar. İlgili işlem, ilk önce edk.dll'inin EE\_DataUpdateHandle fonksiyonunu kullanarak veri kontrolcüsünün iç değişkenini güncelleştirir, sonra edk.dll'in EE\_DataGet fonksiyonunu kullanarak veriyi bir Matlab veri işaretçisi ile "output" isimli değişkeninin içerisine kopyalar. Her bir kanal için EE\_DataGet fonksiyonu kullanılarak, söz konusu kanalın EmoEngine'nin dokümantasyonunda belirtilen özel alfabetik isminin verilmesi ile o kanalın yeni verilerinin kopyalanması gerekmektedir.

Emologger'in son "close" fonksiyonu, deney bittikten sonra edk.dll kütüphanesinin değişkenlerinin temizlenmesini ve EmoEngine'nin bağlantısının kesilmesini sağlar.

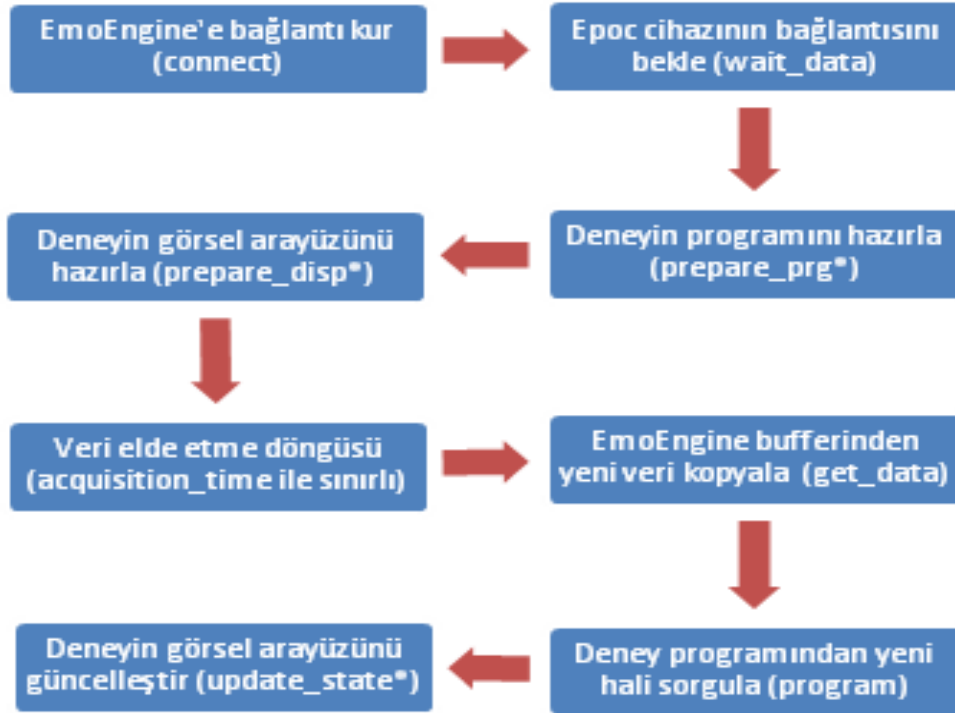
Emologger nesnesi, Epoc cihazı kullanan BBA deneyleri için temel nesne olarak tasarlanmıştır. Yani, bu modeli kullanacak herhangi yeni bir BBA deneyi için, Emologger nesnesinden türetilmiş bir Matlab nesnesi yaratılabilir. Bu Matlab nesnesi, Emologger nesnesinin temel ham veri elde etme kapasitesini kullanıp deney ile ilgili arayüzü ve gereken ek işlemleri ekleyebilir. Bu işlem öngörülüp, Emologger nesnesinin 2. kısmında "prepare\_prg", "prepare\_disp" ve "update\_state" metodları yaratılmıştır. Bu metodlar yeni BBA deneylerinin arayüzlerinin Emologger nesnesinden türetilmesini destekler. Emologger'in kendi "run" fonksiyonundan çağırılır ve türetilmiş nesne üzerinden uygulanır. Prepare\_prg metodu, BBA deneyi için bir deney program veri yapısı oluşturur. Deney program veri yapısı bir dizi biçimindedir, bu dizinin elemanları "cueLength" saniyede uygulanacak her bir anda deney arayüzünün gerekli halini belirtir. Mesela, "cueLength=1" ve deney programı 10 elemanlı dizi olduğu zaman, BBA deneyi için 10 saniyelik bir program tanımlayacak, bu programın t. elemanının t. saniyenin BBA arayüzü halini (mesela sağ hareket uyarıcısı göster, sol hareket uyarıcısı göster şeklinde) belirtecektir. Emologger, deneyin geçen zamanına göre deneyin "program" dizisinden ilgili hal değerini okuyarak BBA arayüzüne uygulanması gereken hal değerini "run" fonksiyonundan "update\_state" metodunu çağırarak uygulamaktadır.

BBA deneyinde program başlamadan önce, herhangi bir görsel arayüz oluşturulması gerekirse "Prepare\_disp" metodu ilgili işlemi gerçekleştirir. Bu metotta yeni görsel pencere veya görsel arayüz elemanları çizdirilebilir.

"Update\_state" metodu, deneyin arayüzünün zaman içerisinde güncelleştirilmesinden sorumludur. "Update\_state" metodu her çağırıldığında, deneyin geçtiği zamana göre deneyin programında belirtilen hal değeri gönderilip deneyin arayüzünün güncelleştirilmesini buna göre sağlar.

Emologger nesnesinin 3. kısmı, daha önce de sözü edilen public "run" metodudur. "Run" metodu, "connect" metodu kullanılarak EmoEngine ile bağlanır (**Şekil 5**). Sonrasında "wait\_data" metodu çağırılır. "prepare\_prg" ve "prepare\_disp" çağırılır. Döngü içinde belirli zamana kadar "get\_data" metodu kullanılarak ham veri elde edilir ve deneyin "program" dizisine, geçtiği zamana göre deney arayüzünün hali belirtilir ve "update\_state" metodu çağırılarak güncelleştirilir.





Şekil 5 Emologger ana veri elde etme metodu (Flow chart of Emologger's main data acquisition method)

Emologger programımız ve ondan türetilmiş BBA deney nesneleri aşağıdaki şekilde çalıştırılabilmektedir;

```
emo=emologger2(1500);
```

```
o=emo.run;
```

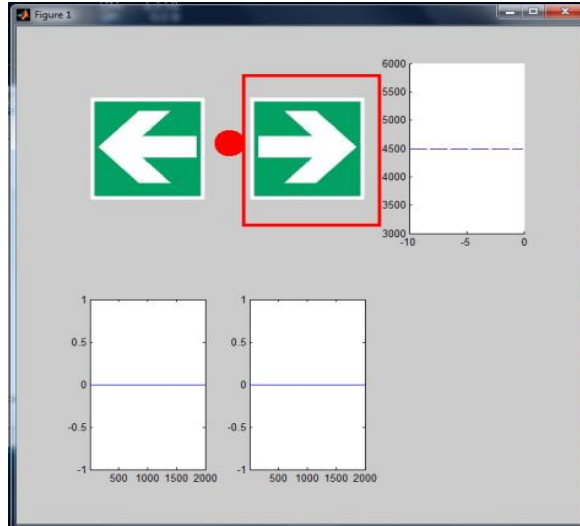
Burada 1500 sabiti, Emologger'in çalışma süresi (saniye olarak); "o" değişkeni, elde edilmiş verilerin tutulduğu Matlab nesnesidir. "o" nesnesi, "id" isimli kaydın ayrı bir alfa numerik belirticisi, "nS" değişkeni elde edilmiş EEG örnek toplam sayısı, "sampFreq" değişkeni cihazın örnekleme frekansı (donanımda belirtilen sabit 128 Hz), "marker" değişkeni - her bir veri örneğine karşılık gelen BBA deneyinin o anki arayüzünün değeri, "data" değişkeni - kanal çarpı zaman şeklinde olan ham EEG veri örneklerini içeren dizinin, alt alanlarına sahiptir. Emologger veya ondan türetilmiş deney nesnesinin geri dönen verilerin biçimi **Tablo 1**'de belirtilmiştir.

Geliştirilen yazılım, Emologger nesnesinin temel ham veri elde etme modelini kullanıp, Emologger temel modellerine sağ/sol BBA modeli ile ilgili görsel arayüzü sağlamaktadır (**Şekil 6**).

Tablo 1. Emologger veya ondan türetilmiş deney nesnesinin geri dönülen verilerin biçimi

“O” emologger sonuç değişkeninin yapısı:	
id	Veri kaydının özgün numarası
nS	Veri kaydından elde edilmiş örnek sayısı
sampFreq	Veri kaydının örnekleme frekansı (128 Hz)
marker	Her bir veri örneğine karşılık gelen BBA deneyinin arayüzünün o anki hali
data	Zaman x kanal biçimde olan ham EEG örneklerini içeren dizi

Sözü geçen arayüz için, “figure” komutu kullanılarak Matlab’ta bir görsel pencere oluşturuldu. Bu pencerede, üst sol bölgede sağ/sol uyarıcı tarif sinyalleri, üst sağ bölgede ham EEG verileri ve alt bölgede sağ/sol el hareketi düşüncesine bağlı belirli anda ölçülen ERP eğrileri gösterildi. Söz konusu BBA arayüzünün uyarma bölgesi, iki ok işaret resmi ve bir kırmızı odaklanma noktasından oluşturuldu. Sağ/sol hareket sinyali, ilgili oku çevreleyen bir kırmızı çerçeve ile gösterildi. Sağ/sol hareket sinyalleri deney başında rastgele olarak “prepare\_prg” metodunda hazırlanan deney programına göre verildi. Deneyin programı sırayla 1 saniyelik sağ/sol hareket uyarıcı ile 1 saniyelik ara şeklinde oluşturulmuştur. Sağ ve sol görsel uyarıcı gösterildikten sonra bireye ilgili hareket düşüncesini deney protokolüne göre uyguladı. Elde edilen ham EEG verilerinin son 10 saniyesi görsel arayüzün üst sağ bölgesinde gerçek zamanlı olarak grafik şeklinde gösterildi. Gerçek zamanlı güncelleştirilen ERP eğrileri grafikleri, sağ veya sol hareket uyarıcısı geldikten sonraki 1 saniyeyi kapsayacak şekilde hesaplanıp aşağıdaki bölgede gösterildi. Bunun için, C3 ve C4 elektrotlarının yerleşim pozisyonundaki EEG elektrotlarının sinyallerinin farkı hesaplanıp gösterildi. Sağ ve sol el hareketlerine bağlı olarak bu ölçüğün sağ ve sol el hareket düşüncelerine göre asimetric olması beklenir. Bu şekilde ERP grafikleri yardımıyla bireye bir geri bildirim sağlandı.



Şekil 6 Sağ ve sol el hareket düşünceleri kullanan BBA deneylerimizin arayüzü (User Interface for right and left hand motor imagery BCI experiments)

### 2.3. BBA'daki Zihinsel Halin Algılanması

BBA deneylerinde zihinsel halleri tespit etmek için güncel kaynaklarda üç genel yaklaşım kullanılmaktadır. Bunlar olaya-ilişkin-potansiyel (Event Related Potential, ERP), olaya-ilişkin-eşzamanlılık (Event Related Synchronization/Desynchronization, ERS/ERD) ve görsel çağrışımında durağan durum potansiyelleri (Steady State Visually Evoked Potential, SSEVP).

Olaya-ilişkin-potansiyeller, bir operatörün (BBA'ünü kullanan birey) belirli zihinsel haline karşılık olarak EEG sinyalinde gelişen stereotipik desenlerdir. ERP'ler belirli olaya bağlı olup, ERP'leri ölçmek için ilgili olayların anlarının tam bilinmesi ve EEG sinyalinin bu anlara göre hizalanıp incelenmesi gereklidir. Örneğin, çok iyi bilinen P300 EEG potansiyeli, birey tarafından beklenen bir görsel veya sesli sinyal geldiğinde yaklaşık olarak 300 milisaniye sonra parietal lobta büyük bir pozitif sapma şeklinde görülmektedir. Beklenen bu sinyalin geldiği ana hizalanmış EEG verilerinde 300-700 milisaniye arasında pozitif sapma görülecektir. Başka bir örnek, birey motor hareketleri uyguladığı veya düşündüğünde motor korteks üzerindeki EEG sinyalinde belirli stereotipik desenler görülmektedir. Bunlara yavaş motor potansiyelleri denir. EEG ERP'lerinin ana avantajı bireyin eğitimi olmadan, yani doğal olarak EEG sinyalinde görülebilmesi ve birey tarafından tipik olarak yüksek seviyede tekrarlanabilmesidir. Dolayısıyla, bu tür olay algılama yaklaşımı kullanacak BBA sistemlerinin uzun eğitim sürecine ihtiyacı yoktur. Eğitim yerine ilgili ERP şekillerini ölçen çok daha kısa BBA ölçümleri kullanılabilir. Aynı zamanda önemli bir nokta olarak, ERP eğrileri aynı bireyin farklı olaylarda stereotipik olmasından dolayı her kişiye özel olmalıdır, yani aynı BBA sistemi yeni bireye uygulandığında söz konusu ERP sinyallerinin yeniden ölçülmesi gereklidir. EEG ERP'lerinin ana dezavantajı ise, genelde çok düşük genliğe sahip olmalarıdır. Örneğin, tipik motor ve P300 potansiyellerinin genliği 1-5 mikro volt civarındadır. Aynı zamanda EEG sinyalinin doğal değişimi (yani deney arayüzünden gelen uyarma sinyallerine bağlı olmayan, beynin aktivitesine dayalı ve kayıt cihazının elektriksel özelliklerine bağlı olmayan EEG sinyalinin değişimi) 5-10 mikro voltur. Bu nedenle ERP sinyallerini gerçekçi bir biçimde algılamak zordur.

ERP araştırmalarında, ERP'ler genellikle ortalama olarak ölçülmektedir. Yani ortalama ERP, birçok aynı olayda görülen ve olayın başlangıç anına hizalanan EEG sinyalinin ortalama desendir. EEG kayıtları kullanılarak bu tip hesaplama için, zamansal uzun ve sürekli bir EEG kaydında bulunan BBA olay anlarından itibaren belirli süreye kadar (örneğin, olayın ilk anından 1 saniyeye kadar) EEG kayıt parçaları kesilip hazırlanmaktadır. Bu EEG kayıt parçaları birbirlerinin üzerine yerleştirilerek olaya ilişkin halen aynı EEG desenlerine ait örneklerin bir yığını oluşturulmaktadır. Bu yığından olaya ortalama ERP eğrisi, ilişkin EEG sinyal örneklerinin ortalaması olarak bulunmaktadır. ERP eğrileri, EEG kanallarının hepsi için olayın başlangıç anına göre ilgili kanaldaki ERP desenlerinin ortalaması olarak elde edilmektedir. Bu hesaplamada yeterli sayıda olay kullanılırsa, ortalama ERP eğrilerinin çok kararlı olduğu görülmektedir. Aynı zamanda tek olaylara ait olan aynı ERP eğrileri, EEG sinyalinin doğal değişiminden dolayı ortalama ERP eğrilerinden çok farklı olabilir ve olaydan olaya yüksek düzeyde değişiklik gösterebilir.

Olaya-ilişkin-eşzamanlılık, frekans uzayında gözlenen bir EEG tepkisidir. ERS/ERD daha çok motor eylemlerle alakalı olan 12-30 Hz (beta) ve 8-12 Hz (alfa) EEG ritimleri ile kullanılır. EEG sinyalinin beyin korteksindeki birçok nöron hücrelerinin ateşlemelerine bağlı sinirsel akış trafiği tarafından üretildiği bilinmektedir. Buna göre beynin bir bölgesinde nöronlar ateşlemeleri senkronize bir şekilde yaparsa, ürettiği EEG sinyalinin genliğinin daha yüksek olması beklenir. Aksi halde, eğer bir bölgede nöronlar ateşlemeleri rastgele yapıyorsa, ritmik EEG sinyallerinin genliğinin düşük olması beklenir. Bu ilkeden yola çıkarak birey tarafından bir hareket yapıldığı zaman, hareket ile ilgili motor korteksindeki nöronlar, ateşlemeleri birbirinden bağımsız olarak yapmaktadır ve ritmik EEG sinyalinin genliği düşmektedir. Bu duruma olaya-ilişkin-eş zamansızlık (ERD) denir. Birey rahatladığı zaman ise, motor korteksindeki nöronlar ateşlemeleri eşzamanlı bir dalga biçimde yapmaya başlar ve bundan dolayı ritmik EEG sinyali görülür. Bu duruma olaya-ilişkin-eşzamanlılık (ERS) denir. BBA amaçları için kullanılan motor kortekste alfa ve beta ritimleri için, birey hareket ettiği veya hareket etmeyi sadece düşündüğü zaman motor korteksindeki EEG sinyalinin gücü, bahsi geçen frekanslarda anlık olarak değişir. Birey rahat olduğu zaman alfa ve beta ritimleri gözlenmektedir. Birey bir hareketi düşündüğü zaman ise harekete bağlı olan kontralateral motor korteks bölgesinde alfa ve beta ritimlerinde düşme görülmektedir. Bireyin motor korteksinin sağ ve sol tarafındaki alfa ve beta ritimlerini kontrol etmeyi öğrenebilmesi mümkündür. Böylece bireyler, sağ/sol taraftaki alfa ve beta ritimlerini kontrol ederek bilgisayara bilgi gönderebilmektedir.

EEG ERS/ERD'lerinin ana avantajı, ilgili zihinsel olay olduğunda net ve uzun süreli görülmesidir. Örneğin, ERS/ERD BBA modelinde, birey ilk önce rahat olur, sonra bir elin hareketini sürekli yapmaya başlar. Bu durumda elin hareketleri tam yapıldığı zaman kontralateral alfa ve beta ritimlerinin düşmesi görülür. Bu tip sinyalleri BBA tarafından algılamak kolaydır. Ayrıca bireyler, alfa ve beta ritimlerinin genliklerinin dereceli kontrolünü öğrenerek, EEG ERS/ERD modelini bilgisayarda dereceli kontrol uygulamak için kullanılabilir. ERS/ERD'lerin ana dezavantajı, ERS/ERD kontrolünün birey tarafından öğrenilmesinin zor olması ve tüm bireyler tarafından gerçekleştirilememesidir. Örneğin,

rahatladıkları zaman bazı bireylerde alfa ritmi görülmekte, diğer bireylerde ise alfa ritmi hiç üretilmemekte ve bu durumun değiştirilemediği bilinmektedir.

Durağan hal görsel çağrışımlı potansiyeller (Steady State Visual Evoked Potentials, SSVEP), 3-90 Hz frekansla gösterilen görsel uyarıcılara karşılık olarak gelişen, aynı frekansta olan ve görsel kortekste bulunan EEG sinyalindeki salınımlardır. BBA için kullanılan bu modelde, BBA arayüzü bireye birkaç kontrol elemanı gösterir ve bu elemanları farklı frekanslarda ışıklarla aydınlatır. Birey, belirli bir kontrol sinyalini BBA'üne göndermek istediği zaman, arayüzün ilgili kontrol elemanına bakar ve görsel kortekste gelişen SSVEP sinyalinin frekansından bireyin dikkatini verdiği eleman belirlenebilir. SSVEP modelinin ana avantajı, çok belirgin olması ve tahminlerinin çok yüksek oranda doğruluk göstermesi, dolayısıyla sağlanan bilgi akışının çok yüksek olabilmesidir.

#### 2.4. Olaya-ilişkin Potansiyellerin Algılanması

BBA uygulamalarında, BBA ile etkileşim için seçilen ERP'lerin ham EEG verilerinden algılanması gereklidir. Genellikle ilgili ERP'lerin algılanması, söz konusu olayı kapsayan EEG sinyalinin bir parçası üzerinde gerçekleştirilir. EEG sinyalinin parçalarının seçildiği bölgeye algılama penceresi (detection window) denir. ERP'ler, EEG sinyalinin doğal değişimine göre yetersiz kaldığı için, gereken olay bazından ERP'lerin algılanması EEG sinyalinin birçok kanalından/elektrodundan aynı zamanda veya birkaç ayrı zamansal örneğinden alınan bilgilerin birlikte kullanılmasını gerektirir. Bu bilgilerin en iyi birleştirme yöntemi fark edilmeyebilmektedir. Bu nedenle kaynaklarda bu probleme yaklaşım şekli olarak en çok kullanılan metot, ERP algılama metodunun makine öğrenme yöntemi kullanılarak ortaya çıkarılmasıdır. En iyi sonuç veren makine öğrenme yöntemleri, Lineer Diskriminant Analiz (LDA) ve Destek Vektör Makineleri (DVM) olan lineer makine öğrenme yöntemleridir.

LDA ve DVM yöntemleri birçok boyutlu uzayda belirtilen verilerden iki durumu ayırt etmek için kullanılan lineer sınıflandırma yöntemleridir. Lineer sınıflandırma yöntemi, verilerde iki durumu ayırt etmek için çok boyutlu öznitelik uzayında bir düzgün düzlem kullanılır. Bu düzlem kullanılarak; belirtilen bir yarı-uzay birinci durum, diğeri ise ikinci durum olarak tanımlanır. Bu durum LDA ve DVM yönteminde ortak olsa da, ayırma düzlemi LDA ve DVM yönteminde farklı şekillerde seçilir. LDA yönteminde [60], iki sınıftan gelen veri normal dağılım kullanılarak modellenir (1). Yani, iki sınıfın her biri için birer merkez ve varyansının olduğu varsayılır;

$$x_{i,k} = \mu_i + \varepsilon_{i,k}. \quad \text{Eş.1}$$

Burada  $x_{i,k}$  i-inci sınıfa atanan k-inci örnek,  $\mu_i$  ilgili sınıfın merkez noktası ve  $\varepsilon_{i,k}$  normal gürültü olarak modellenen rastgele bir değişkendir. LDA yönteminde birinci ve ikinci sınıfa ait olan  $\varepsilon_{i,k}$  değişkenlerinin kovaryans matrislerinin  $\Sigma_{ij} = E[(x_{i,k} - \mu_i)(x_{j,k} - \mu_j)]$  aynı olduğu varsayılır ve bu durumda iki sınıfı en iyi ayırt eden düzlemin normal vektörü (2)'dedir.

$$w = \Sigma^{-1}(\mu_2 - \mu_1) \quad \text{Eş.2}$$

ile tanımlanır. Veri noktaları ayrımı (3) 'e göre yapılır.

$$\text{class}(x) = \begin{cases} 1, & \text{eğer } w^T x < c \text{ ise} \\ 2, & \text{eğer } w^T x > c \text{ ise} \end{cases} \quad \text{Eş.3}$$

Burada  $c$  sabiti, sınıflandırma hatalarını azaltarak seçilen eşik parametresidir. Aynı prensiple yola çıkan sınıflandırma yönteminde sınıfların kovaryanslarının eşit olduğu varsayılmazsa, elde edilecek sınıflandırma yönergesine karesel diskriminant analizi (Quadratic Discriminant Analysis, QDA) denir [61].

DVM yönteminde ayrılma düzlemi "en yüksek pay" (maksimum margine) prensibinden hesaplanır [62]. Söz konusu prensip, seçilen ayrılma yönüne göre iki sınıfın en kötü (en yakın) iki örneğine göre en büyük ayrımı sağlamaktadır. Söz konusu prensibin matematiksel ifadesi, (4),(5) problemlerinin çözümüdür.

$$(w, b) = \arg \min_{w,b} \left( \frac{1}{2} |w|^2 + C \sum \xi_i \right) \quad \text{Eş.4}$$

$$\text{s.t. } y_i(w^T x_i - b) \geq 1 - \xi_i, \xi_i \geq 0. \quad \text{Eş.5}$$

Burada  $w$  ayrılma düzleminin normal vektörü ve  $b$  bir ofset sabitidir. Veri noktalarının DVM ayrılma yönergesi (6) biçiminde tanımlanır.

$$\text{class}(x) = \begin{cases} 1, & \text{eğer } w^T x - b < 0 \text{ ise} \\ 2, & \text{eğer } w^T x - b > 0 \text{ ise} \end{cases} \quad \text{Eş.6}$$

LDA ve DVM yaklaşımlarının çözümü ve uygulanması basit olması ile beraber, bu yaklaşımları kullanabilmek için EEG verilerinin önceden uygun bir biçimde temsil edilmesi gerekir. Yani, farklı zihinsel haller ile ilişkili olacak EEG sinyallerinin bir öznitelik vektörü  $x$  olarak belirli bir şekilde belirtilmesi gerekir. Kaynaklarda, bu amaçla en çok kullanılanlar, EEG sinyalinin bir algılama penceresi içerisinde hesaplanan EEG bant güçleri ve Spektral Güç Dağılımı (Power Spectrum Distribution, PSD) öznitelikleridir. Eğer bir olayda görülen algılama penceresindeki EEG sinyali  $x_k(c; t)$  olarak belirtilirse, algılama penceresindeki EEG sinyalinin ayrık Fourier dönüşümü (7) biçiminde tanımlanabilir.

$$X_k(c; f) = \sum_{t=1}^T x_k(c; t) e^{-j2\pi ft/T} \quad \text{Eş.7}$$

Burada  $k$  indeksi belirli BBA olayını belirtir,  $t=1, \dots, T$  olayın algılama penceresindeki EEG zamansal ayrık örnekleri ve  $f=0, 1, \dots, T-1$  ayrık frekans indeksidir. Yani,  $x_k(c; t)$   $k$ . olayın algılama penceresindeki  $c$ . EEG elektrodunun  $t$ . zamansal örneğine karşılık gelir.  $X_k(c; f)$  ise, ayrık Fourier dönüşümünün  $k$ . olayının  $c$ . EEG elektrodunun  $f$ . karmaşık genliğine karşılık gelir.

Ayrık Fourier dönüşümü kullanılarak PSD (8) şeklinde hesaplanır.

$$S_k(c; f) = |X_k(c; f)|^2 \quad \text{Eş.8}$$

Yani,  $S_k(c; f)$  ilgili ayrık karmaşık Fourier genliğinin mutlak değerinin karesidir. EEG bant güçleri, sözü geçen PSD niteliğinden (9) şeklinde hesaplanır.

$$P_k(c; b) = \sum_{f=b_0}^{f=b_1} S_k(c; f) \quad \text{Eş.9}$$

Burada  $b = (b_0, b_1)$ , EEG bantlarını tanımlayan frekans çiftleridir. EEG bantları olarak kaynaklarda en tipik olarak standart EEG bant tanımları kullanılır. Bunlar **Tablo 2**'de gösterilmiştir.

Tablo 2. Standart EEG frekans bantlarının tanımları

Bant	$b_0$	$b_1$
Delta	1 Hz	4 Hz
Teta	4 Hz	8 Hz
Alfa (Alt Bant)*	8 Hz	10 Hz
Alfa (Üst Bant)*	10 Hz	12 Hz
Beta (Alt Bant)	12 Hz	18 Hz
Beta (Üst Bant)	18 Hz	30 Hz
Gama (Alt Bant)	30 Hz	40 Hz
Gama (Üst Bant)	40 Hz	50 Hz

\* - motor korteks üzerinde görülen alfa ritimlerine mu-ritmi denir

Yukarıdakilere göre, PSD ve EEG bant güçleri algılama pencerelerine bağlı EEG sinyalinin farklı frekanslardaki güçleri ifade eder. ERS/ERD ve SSVEP yöntemlerinde, EEG sinyalinin her bir frekans bandındaki güç değişimleri BBA için doğrudan kontrol sinyalleri üretmek için kullanılır. Örneğin, motor korteksin bir tarafında alfa ritminin kaybolduğu zaman, ilgili bölgenin EEG elektrodunun alfa bandı gücü de düşmektedir. BBA sistemi, bu değişikliği sayısal olarak algılayıp ona bağlı eylem uygulamaktadır. Benzer şekilde görsel kortekste belirli frekansta SSVEP sinyali geliştiğinde, görsel korteks üzerindeki EEG elektrodunda ilgili frekansta EEG gücü artmaktadır.

ERS/ERD ve SSVEP BBA'ünden farklı olarak, ayrı ERP olayları için olaya özgü ERP parçacıklarına ilişkin farklı frekanslarda geçici EEG sinyal değişimleri görülür. Bu nedenle EEG verilene karşılık gelen ERP olayları, EEG sinyalinin frekans bileşimindeki geçici değişiklikler benzer şekilde analiz edilerek tespit edilmelidir.

Bu şekilde  $x$  öznitelik vektörü genellikle belirli bir BBA olayı için tüm EEG elektrotlarından PSD veya EEG bant güçleri birleştirilerek tanımlanır (10),(11).

$$x = (S(c; f), tüm c, tüm f) \quad \text{Eş.10}$$

Veya

$$x = (P(c; b), tüm c, tüm b) \quad \text{Eş.11}$$

Örneğin, eğer analizde  $n_c$  sayıda EEG elektrodu ve  $n_f$  sayıda PSD frekansı veya EEG bandı kullanılmakta ise,  $x$  vektörü  $n_c n_f$  sayıda öznitelik oluşturur. LDA veya DVM sınıflandırma yöntemi, bu vektörü kullanarak  $n_c n_f$  boyutta sınıflandırma parametresi ( $w$ ) yaratır ve gözlemlenen EEG sinyallerinin ilgili sınıflarına  $w^T x$ 'e değerine göre atar. Bu çalışmada, PSD ve EEG bant gücü özniteliklerine ek olarak zaman uzayında EEG sinyali ve ayırık Fourier dönüşümünün karmaşık genlikleri, ERP algılanması için öznitelik olarak kullanılmıştır.

Kaynaklarda geniş çapta kullanılan PSD ve EEG bant gücü özniteliklerinin önemli bir dezavantajı, sinyalin farklı frekans bileşenlerinin fazları hakkındaki bilginin kaybolmasıdır. Bu faz bilgileri, sinyalin şekilleri belirtmek için önemlidir. Bununla birlikte, söz konusu faz bilgileri sinyalin orijinal zamansal dalga şeklinden veya ayırık Fourier dönüşümünün karmaşık genliklerinden de elde edilebilir. ERP öznitelikleri olarak olayın başlangıç anına hizalanmış EEG sinyalinin zamansal dalga şekli kullanıldığında, sınıflandırmaya giren öznitelik vektörü (12) şeklinde olacaktır.

$$x = (x(c; t), tüm c, t = 1, \dots, T) \quad \text{Eş.12}$$

Yani, sınıflandırmada kullanılacak öznitelik vektörü  $x$ , olay uyarıcısının anına göre  $T$  zamansal örneği olarak tanımlanır. ERP öznitelikleri olarak ayırık Fourier dönüşümünün karmaşık genlikleri kullanıldığında, sınıflandırmaya giren öznitelik vektörü ise (13) şeklinde olacaktır.

$$x = (X_{re}(c; f), X_{im}(c; f), tüm c, f = 0, \dots, T/2) \quad \text{Eş.13}$$

Yani  $X_{re}(c; f)$  ve  $X_{im}(c; f)$  EEG elektrodunun  $f$  frekansının ayırık Fourier dönüşümü genliğinin gerçel ve sanal bileşenidir. Ancak LDA veya DVM yönteminde kullanılacak öznitelik vektörü  $x$  tamamen gerçel olmalıdır. Ayrıca, bu durumda ilk  $T/2 + 1$  Fourier genliği kullanılır, çünkü gerçel sinyal için ayırık Fourier dönüşümü genlikleri birbirlerine (14) şeklinde bağlıdır;

$$X(c; f) = X^*(c; T - f) \quad \text{Eş.14}$$

Dolayısıyla, yukarıda belirten gerçel ve sanal bileşenlerinin sadece  $T/2 + 1$  tanesi birbirinden bağımsızdır.

### 3. BULGULAR VE TARTIŞMALAR

Yöntem kısmında geliştirilip açıklanan yöntem ve sistemleri denetlemek için, canlı deneyler tarafımızdan gerçekleştirildi. Gerçekleştirilen deneylerde Matlab arayüzümüzde iki oktan birisi gösterilerek bireylere gerekli hareket düşüncesi tarif edilmiştir. Bireyler, bilgisayar tarafından sağ/sol el hareket düşüncesi işaretçisi ile birlikte ilgili hareketin düşüncesini zihinlerinde gerçekleştirmişlerdir. Aynı zamanda EEG verileri daha önce sözü edilen Eloc cihazı ve emologger yazılımı yardımıyla bilgisayara kaydedilmiştir. Arayüzümüz elde edilen EEG verileri ve sağ/sol el hareket düşüncelerinin ilişkisini çevrimdışı olarak yansıtmıştır.

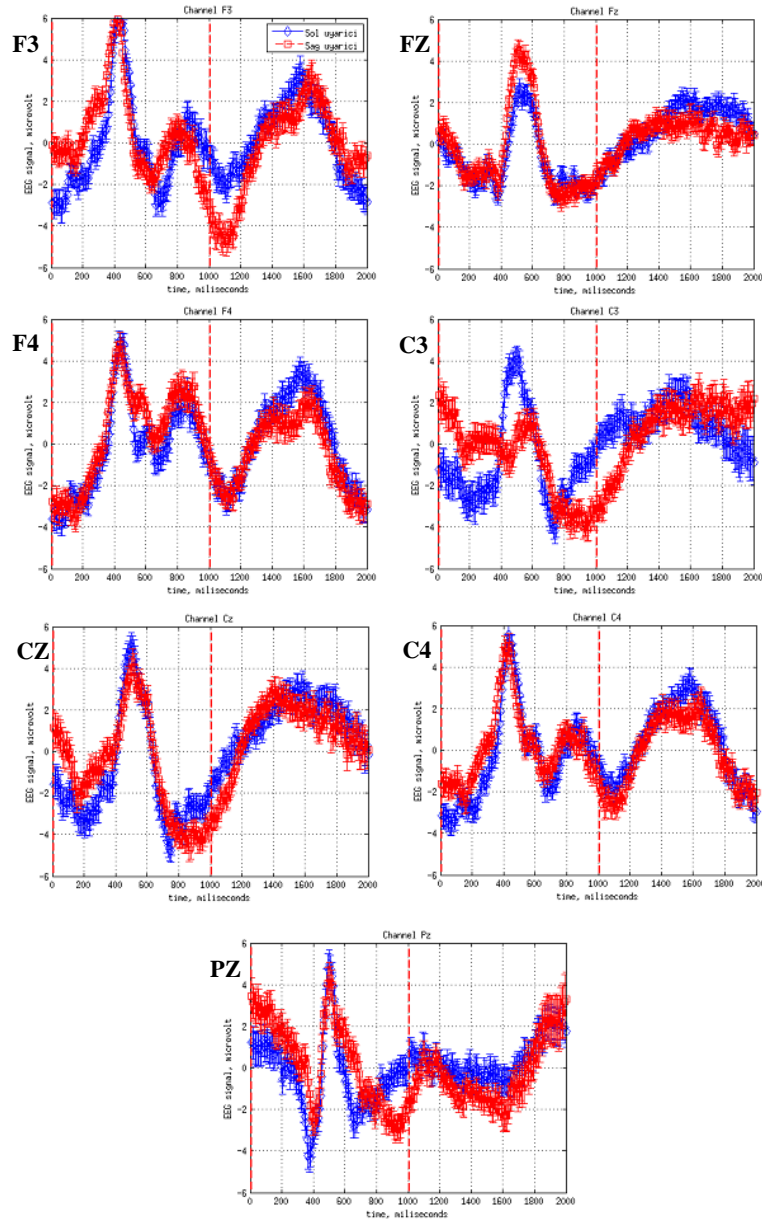
Deneylerimizde 3 farklı katılımcı farklı zamanlarda 4 oturuma katılarak, bir oturumda yaklaşık olarak 50 dakika veri kaydedilmiştir. Herhangi bir hareket düşüncesi uygulandığında, yazılımın hareket uyarıcı oku rastgele seçilip gösterildiğinde ilgili motor düşüncesinin kaydı için 1 saniye uygulandı ve sonra 1 saniye ara verildi. Bu şekilde deney boyunca yaklaşık olarak 1500 sağ/sol hareket düşünceleri için ERP örneği kaydedilebildi.

Elde edilen verilerden öncelikle sağ ve sol el hareket düşüncelerine bağlı tüm elektrotlardaki ERP eğrileri oluşturulup incelendi. ERP'ler, genlik olarak 4-5 mV, zaman olarak 250-500 ms civarında olduğu gözlemlendi. Bireylerin ortalama 200-300 ms tepki süresi olduğu için, ERP eğrilerinin başlangıcı genellikle uyarıcı anından 200-300 ms sonra olduğu gözlemlendi (**Şekil 7**). **Şekil 7**'de, kırmızı ERP sağ el hareketi ve mavi ERP sol el hareketi için ölçülmüştür. C3 elektrodu hariç, ERP eğrilerin sağ ve sol hareketlerinde benzer olduğu görülür. C3 elektrodundaki sağ ve sol el hareket olayları net olarak ayrılır. Eylem uyarma sinyali sıfır zamana hizalanmış, 1000 milisaniyedeki kesikli çizgi eylem uyarma sinyalinin bitişi göstermektedir. Yani, kırmızı kesikli çizgilerle gösterilen bölüm görsel objenin deneğe gösterildiği zaman aralığını göstermektedir. Ayrıca C3 elektrodu motor korteks elektrodu olduğundan elbette harekete bağlı farklılıklarda beklenmelidir.

EEG sinyallerinin ayrı ayrı incelendiğinde, ayrı ERP eğrilerinin olaydan olaya doğal değişiminin 5-10 mV civarında olduğu görüldü. Bu değişim EEG sinyalinin iç özelliklerine bağlıdır. Bu EEG sinyal varyasyonu, beynin doğal aktivitesiyle ilgi olan BBA kontrol sinyalinden bağımsızdır ve işlem cihazın özellikleri ile ilgili değildir. Her işlem

cihazında gözlemlenebilir. Dolayısıyla, ERP sinyallerinin elde edilmesiyle birlikte ERP sinyallerinin çok gürültülü olduğu gözlemlendi.

EEG verilerimizde sağ ve sol el hareket sınıfları otomatik olarak DVM yöntemi kullanılarak tespit edildi. Bunun için, farklı öznitelik biçimleri birbiriyle karşılaştırıldı. Karşılaştırma için veri seti rastgele %70'e %30 şeklinde eğitim test olarak ayrılmıştır. Karşılaştırma sırasında veriler, olay anına hizalanmış EEG sinyalinin zamansal serileri olarak, zaman-frekans uzayında Güç Spektrumu olarak ve karmaşık Fourier genlikleri olarak temsil edildi. Bunlardan, zaman-frekans uzayındaki Fourier genliklerinin öznitelik olarak kullanılmasının en yüksek başarıya ulaştırdığı gözlemlendi (Tablo 3).




Şekil 7 Aktif olan tüm elektrotlardan derlenen sol ve sağ ERP'ler.(ERPs from active electrodes. )

**Tablo 3.** Farklı öznitelik türlerine göre sağlanan sağ ve sol el hareket düşünceleri ayırma doğrulukları

Veri temsil yöntemi	Zaman serisi hizasız	Güç spektrumu	Zaman serisi hizalanan	Faz eşleşilmiş genlikler
Ayrırma doğruluğu	%55-60	%55-60	%65-75	%75-85

BBA sınıflandırıcısı uygulamasında önceki deneyimlere dayalı olarak üç parametrenin verilmesi gerekmektedir. Bunlar, kullanılan EEG sinyali inceleme penceresinin uyarıcıya göre ilk ve son noktası, yani inceleme penceresinin uyarıcı anına göre başlangıç ve bitiş noktası, inceleme penceresinin uzunluğu ve alçak geçiren filtreleme kesim frekansı. Bu parametreleri belirtmek için sistematik şekilde birçok parametre rejimi incelendi. Gözden geçirilen parametre rejimlerinde, inceleme penceresinin son noktası 150 mili saniyeden 1000 mili saniyeye kadar, inceleme penceresi uzunluğu 250 mili saniyeden 1000 mili saniyeye kadar 100'er ms adımlarla tüm muhtemel değerler, alçak geçiren filtreleme kesim frekansı olarak 5 Hz, 10 Hz, 16 Hz ve 24 Hz incelendi. En yüksek başarıyı sağlayan parametreler, kesim frekansı 5Hz, pencere uzunluğu 650 ms ve pencerenin son noktası ise uyarıcıdan sonra 850 ms olarak belirlendi.

Dikkat edilmelidir ki, alçak geçiren filtrenin kesim frekansı yükseltildikçe DVM olay sınıflandırıcısının öğrenme başarısı düşmektedir, çünkü daha yüksek kesim frekansı öznitelik uzayının boyutunu da yükseltir. Bu, iyi bir sınıflandırma modeli elde etmek için daha çok BBA olay örneklerine ihtiyaç yaratmaktadır. Örneğin Şekil 8'de, DVM yöntemi kullanılarak eğitimde kullanılan olay örneği sayısına göre sağ ve sol el hareket düşüncelerini ayırma kaliteleri BBA eğitiminin tüm diğer parametreleri sabit tutularak alçak geçiren filtrenin kesim frekansları 5Hz ve 10Hz olarak ayrı ayrı denenmiştir. DVM sınıflandırıcı eğitim kümesi olarak 25 ile 1300 arası olay sayısı denendi, test kümesi olarak 200 olay kullanılmıştır. Tüm deneylerde eğitim ve test örnekleri rastgele olarak seçilmiştir. 5Hz alçak geçiren filtre çıkışından elde edilen veriler için gereken eğitim veri miktarı 400-800 olay örneği olarak gözlemlendi. Aynı zamanda 10 Hz kesim frekansıyla filtrelenmiş veriler, 1300 olay örneği içeren eğitim kümesi BBA'nın DVM sınıflandırıcısını eğitmek için yetersiz olduğu gözlemlenebildi. Bununla birlikte, 5Hz kesim frekansı ile eğitilen DVM-BBA'nın asimptot performansı sağladığı görülmüş ve iki olay ayırmada %80 doğruluğa yaklaşmıştır.



Şekil 8. a) 5Hz alçak geçiren filtre kullanılarak oluşturulan öznitelik vektörleri için eğitim eğrileri (Training curve for using 5Hz lowpass filter generated feature vectors) b) 10Hz alçak geçiren filtre kullanılarak oluşturulan öznitelik vektörleri için eğitim eğrileri (Training curve for using 10Hz lowpass filter generated feature vectors)

#### 4. SONUÇ

Çalışmamızda basit bir EEG-ERP tabanlı BBA sisteminin tasarımı, hem donanım hem de yazılım geliştirilmesi ayrıntılı olarak açıklanmıştır. Ayrıca BBA araştırma alanına kapsamlı bir giriş ve özet kaynak sağlanmıştır. Tasarımın BBA uygulamasında tek sağ/sol el hareket düşünce olayı bazında çalışarak yaklaşık olarak %80



doğrulukla sağ/sol hareket düşüncelerinin ayrabildiğini gösterilmiştir. Sonuçlarımız, kaynaklarda var olan benzer EEG-BBA uygulamalarının performanslarına yaklaşmaktadır [30]. Eğer tek olay bazında EEG BBA uygulamamız %80-85 doğruluk oranıyla zihinsel eylemleri belirtebilmekte olduğundan, BBA kontrol sinyali olarak iki veya daha çok olay kullanılırsa %90-95 doğrulukla çalışıp zihinsel süreçlere bağlı harici cihazların kontrolünü sağlayabilmektedir. Çalışmamızda geliştirilen EEG BBA uygulamasında bazı iyileştirmelerin yapılabileceği gösterilmiştir. Elektrotların daha doğru ve hassas düzende yerleştirilmesi ve daha çok elektrot kullanılabilmesi için daha iyi EEG bonesi tasarımı geliştirilmesi faydalı olacaktır. EEG BBA'nın yeteneklerini artırmak için sağ/sol el hareketleri, ayak ve dil hareketleri gibi ikiden fazla kontrol sinyalinin kullanımı incelenebilir. Ayrıca, görüldüğü gibi BBA eğitiminde kullanılması gereken veri miktarlarının azaltılması bir başka çok önemli problemdir. Bunun için öznitelik ön-seçim veya boyut azaltma yöntemlerinin kullanılması incelenebilir. Kaynaklardaki bazı çalışmalarda da, geri bildirim kullanılarak BBA sistemlerinin daha hızlı eğitilebilmesi bahsedilmiştir.

## 5. BİLGİLENDİRME

Bu çalışma TUBITAK ARDEB 1001 projesi 113E611, Toros Üniversitesi BAP fonu projesi TUBAP135001 ve Bilim Akademisi BAGEP burs ödülü tarafından desteklenmiştir.

## KAYNAKLAR

- [1] E. E. Fetz, “Operant conditioning of cortical unit activity.”, *Science*, c. 163, sayı 3870, ss. 955–8, 1969.
- [2] S. Sutton, M. Braren, J. Zubin, ve E. R. John, “Evoked-Potential Correlates of Stimulus Uncertainty”, *Science* (80- ), c. 150, sayı 3700, s. 1187, 1965.
- [3] E. Donchin, K. M. Spencer, ve R. Wijesinghe, “The mental prosthesis: Assessing the speed of a P300-based brain-computer interface”, *IEEE Trans. Rehabil. Eng.*, c. 8, sayı 2, ss. 174–179, 2000.
- [4] L. A. Farwell ve E. Donchin, “Talking off the top of your head: toward a mental prosthesis utilizing event-related brain potentials”, *Electroencephalogr. Clin. Neurophysiol.*, c. 70, sayı 6, ss. 510–523, 1988.
- [5] M. Serruya ve J. Donoghue, “Design Principles of a Neuromotor Prosthetic Device”, *Neuroprosthetics Theory Pract.*, sayı November, ss. 1158–1196, 2004.
- [6] J. M. Carmena, M. A. Lebedev, R. E. Crist, J. E. O’Doherty, D. M. Santucci, D. F. Dimitrov, P. G. Patil, C. S. Henriquez, ve M. A. L. Nicolelis, “Learning to control a brain-machine interface for reaching and grasping by primates”, *PLoS Biol.*, c. 1, sayı 2, 2003.
- [7] J. Wessberg, C. R. Stambaugh, J. D. Kralik, P. D. Beck, M. Laubach, J. K. Chapin, J. Kim, S. J. Biggs, M. a Srinivasan, ve M. a Nicolelis, “Real-time prediction of hand trajectory by ensembles of cortical neurons in primates.”, *Nature*, c. 408, sayı 6810, ss. 361–365, 2000.
- [8] M. A. Lebedev, “Cortical Ensemble Adaptation to Represent Velocity of an Artificial Actuator Controlled by a Brain-Machine Interface”, *J. Neurosci.*, c. 25, sayı 19, ss. 4681–4693, 2005.
- [9] M. Velliste, S. Perel, M. C. Spalding, A. S. Whitford, ve A. B. Schwartz, “Cortical control of a robotic arm for self-feeding”, *Nature*, c. 453, sayı June, ss. 1098–1101, 2008.
- [10] J. L. Collinger, B. Wodlinger, J. E. Downey, W. Wang, E. C. Tyler-Kabara, D. J. Weber, A. J. C. McMorland, M. Velliste, M. L. Boninger, ve A. B. Schwartz, “High-performance neuroprosthetic control by an individual with tetraplegia”, *Lancet*, c. 381, sayı 9866, ss. 557–564, 2013.
- [11] M. Kryger, B. Wester, E. A. Pohlmeyer, M. Rich, B. John, J. Beaty, M. McLoughlin, M. Boninger, ve E. C. Tyler-Kabara, “Flight simulation using a Brain-Computer Interface: A pilot, pilot study”, *Exp. Neurol.*, c. 287, ss. 473–478, 2017.
- [12] O. Fukuda, T. Tsuji, M. Kaneko, ve A. Otsuka, “A human-assisting manipulator teleoperated by EMG signals and arm motions”, *IEEE Trans. Robot. Autom.*, c. 19, sayı 2, ss. 210–222, 2003.
- [13] G. C. Matrone, C. Cipriani, M. Carrozza, ve G. Magenes, “Real-time myoelectric control of a multi-fingered hand prosthesis using principal components analysis”, *J. Neuroeng. Rehabil.*, c. 9, sayı 1, s. 40, 2012.
- [14] F. V. G. Tenore, A. Ramos, A. Fahmy, S. Acharya, R. Etienne-Cummings, ve N. V. Thakor, “Decoding of individuated finger movements using surface electromyography”, *IEEE Trans. Biomed. Eng.*, c. 56, sayı 5, ss. 1427–1434, 2009.
- [15] “Advanced Arm Dynamics Smart Prosthesis”. [Çevrimiçi]. Available at: <http://armdynamics.com/>. [Erişim: 03-Tem-2017].
- [16] “Bebionic Smart Prosthesis”. [Çevrimiçi]. Available at: <http://bebionic.com/>. [Erişim: 03-Tem-2017].
- [17] “Touchbionics Smart Prosthesis”. [Çevrimiçi]. Available at: <http://touchbionics.com/>. [Erişim: 03-Tem-2017].
- [18] “Utaharm Smart Prosthesis”. [Çevrimiçi]. Available at: <http://utaharm.com/>. [Erişim: 03-Tem-2017].
- [19] N. Weiskopf, K. Mathiak, S. W. Bock, F. Scharnowski, R. Veit, W. Grodd, R. Goebel, ve N. Birbaumer, “Principles of a brain-computer interface (BCI) based on real-time functional magnetic resonance imaging (fMRI)”, *IEEE Trans. Biomed. Eng.*, c. 51, sayı 6, ss. 966–970, 2004.
- [20] “Pittsburg Brain Activity Interpretation Competition (PBAIC)”. [Çevrimiçi]. Available at: <http://www.lrdc.pitt.edu/ebc/2007/competition.html>. [Erişim: 03-Tem-2017].
- [21] Y. Miyawaki, H. Uchida, O. Yamashita, M. a Sato, Y. Morito, H. C. Tanabe, N. Sadato, ve Y. Kamitani, “Visual image reconstruction from human brain activity using a combination of multiscale local image decoders”, *Neuron*, c. 60, sayı 5, ss. 915–929, 2008.
- [22] S. Nishimoto, A. T. Vu, T. Naselaris, Y. Benjamini, B. Yu, ve J. L. Gallant, “Reconstructing visual experiences from brain activity evoked by natural movies”, *Curr. Biol.*, c. 21, sayı 19, ss. 1641–1646, 2011.
- [23] J. R. Wolpaw ve D. J. McFarland, “Control of a two-dimensional movement signal by a noninvasive brain-computer interface in humans”, *Proc. Natl. Acad. Sci.*, c. 101, sayı 51, ss. 17849–17854, 2004.
- [24] D. J. McFarland, W. A. Sarnacki, ve J. R. Wolpaw, “Electroencephalographic (EEG) control of three-dimensional movement”, *J. Neural Eng.*, c. 7, sayı 3, s. 36007, 2010.
- [25] D. J. McFarland ve J. R. Wolpaw, “Chapter 4 – Brain-Computer Interfaces for the Operation of Robotic and Prosthetic Devices”, içinde *Advances in Computers*, c. 79, 2010, ss. 169–187.
- [26] T. J. Bradberry, R. J. Gentili, ve J. L. Contreras-Vidal, “Reconstructing Three-Dimensional Hand Movements from Noninvasive Electroencephalographic Signals”, *J. Neurosci.*, c. 30, sayı 9, ss. 3432–3437, 2010.

- [27] B. Blankertz, G. Dornhege, M. Krauledat, K.-R. Müller, ve G. Curio, “The Berlin Brain-Computer Interface: Machine learning based detection of user specific brain states”, *Neuroimage*, c. 37, sayı 2, ss. 539–550, 2007.
- [28] B. Blankertz, G. Dornhege, M. Krauledat, K. R. Müller, ve G. Curio, “The non-invasive Berlin Brain-Computer Interface: Fast acquisition of effective performance in untrained subjects”, *Neuroimage*, c. 37, sayı 2, ss. 539–550, 2007.
- [29] E. Abdalsalam, M. Z. Yusoff, N. Kamel, A. S. Malik, ve D. Mahmoud, “Classification of four class motor imagery for brain computer interface”, içinde *Lecture Notes in Electrical Engineering*, 2017, c. 398, ss. 297–305.
- [30] F. Lotte, M. Congedo, A. Lécuyer, F. Lamarche, ve B. Arnaldi, “A review of classification algorithms for EEG-based brain-computer interfaces”, *J. Neural Eng.*, c. 4, sayı 2, ss. R1–R13, 2007.
- [31] W. Jia, X. Zhao, H. Liu, X. Gao, S. Gao, ve F. Yang, “Classification of single trial EEG during motor imagery based on ERD.”, *Conf. Proc. IEEE Eng. Med. Biol. Soc.*, c. 1, ss. 5–8, 2004.
- [32] N. Gupta, S. Gupta, V. Khare, C. K. Jain, ve S. Akhter, “An efficient model to decipher the electroencephalogram signals using machine learning approach”, içinde *IFMBE Proceedings*, 2008, c. 21 IFMBE, sayı 1, ss. 782–785.
- [33] A. O. G. Barbosa, D. R. A. Diaz, M. M. B. R. Vellasco, M. A. Meggiolaro, ve R. Tanscheit, “Mental tasks classification for a noninvasive BCI application”, içinde *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 2009, c. 5769 LNCS, sayı PART 2, ss. 495–504.
- [34] R. Palaniappan ve P. Raveendran, “Cognitive task prediction using parametric spectral analysis of eeg signals”, *Computer (Long Beach Calif.)*, c. 14, sayı 1, ss. 58–67, 2001.
- [35] J. L. Sirvent Blasco, E. Iáñez, A. Úbeda, ve J. M. Azorín, “Visual evoked potential-based brain-machine interface applications to assist disabled people”, *Expert Syst. Appl.*, c. 39, sayı 9, ss. 7908–7918, 2012.
- [36] E. Yin, T. Zeyl, R. Saab, T. Chau, D. Hu, ve Z. Zhou, “A Hybrid Brain-Computer Interface Based on the Fusion of P300 and SSVEP Scores”, *IEEE Trans. Neural Syst. Rehabil. Eng.*, c. 23, sayı 4, ss. 693–701, 2015.
- [37] X. Chen, Y. Wang, M. Nakanishi, X. Gao, T.-P. Jung, ve S. Gao, “High-speed spelling with a noninvasive brain-computer interface”, *Proc. Natl. Acad. Sci.*, c. 112, sayı 44, ss. E6058–E6067, 2015.
- [38] L. Wu, H. Liao, J. Hu, ve P. Lo, “Brain-controlled robot agent: an EEG-based eRobot agent”, *Ind. Robot An Int. J.*, c. 35, sayı 6, ss. 507–519, 2008.
- [39] Y. Chae, S. Jo, ve J. Jeong, “Brain-Actuated Humanoid Robot Navigation Control Using Asynchronous Brain-Computer Interface”, *Analysis*, sayı 1c, ss. 519–524, 2011.
- [40] Y. Chae, J. Jeong, ve S. Jo, “Toward brain-actuated humanoid robots: Asynchronous direct control using an EEG-Based BCI”, *IEEE Trans. Robot.*, c. 28, sayı 5, ss. 1131–1144, 2012.
- [41] R. Ron-Angevin, F. Velasco-Alvarez, S. Sancha-Ros, ve L. Da Silva-Sauer, “A two-class self-paced BCI to control a robot in four directions”, içinde *IEEE International Conference on Rehabilitation Robotics*, 2011.
- [42] F. Cincotti, D. Mattia, F. Aloise, S. Bufalari, G. Schalk, G. Oriolo, A. Cherubini, M. G. Marciani, ve F. Babiloni, “Non-invasive brain-computer interface system: Towards its application as assistive technology”, *Brain Res. Bull.*, c. 75, sayı 6, ss. 796–803, 2008.
- [43] L. Mayaud, S. Filipe, L. Pétégnef, O. Rochecouste, ve M. Congedo, “Robust brain-computer interface for virtual Keyboard (RoBIK): Project results”, *Irbm*, c. 34, sayı 2, ss. 131–138, 2013.
- [44] L. Bai, T. Yu, ve Y. Li, “A brain computer interface-based explorer”, *J. Neurosci. Methods*, c. 244, ss. 2–7, 2015.
- [45] M. Kim, B. H. Kim, ve S. Jo, “Quantitative Evaluation of a Low-Cost Noninvasive Hybrid Interface Based on EEG and Eye Movement”, *IEEE Trans. Neural Syst. Rehabil. Eng.*, c. 23, sayı 2, ss. 159–168, 2015.
- [46] D. P. McMullen, G. Hotson, K. D. Katyal, B. A. Wester, M. S. Fifer, T. G. McGee, A. Harris, M. S. Johannes, R. J. Vogelstein, A. D. Ravitz, W. S. Anderson, N. V. Thakor, ve N. E. Crone, “Demonstration of a semi-autonomous hybrid brain-machine interface using human intracranial EEG, eye tracking, and computer vision to control a robotic upper limb prosthetic”, *IEEE Trans. Neural Syst. Rehabil. Eng.*, c. 22, sayı 4, ss. 784–796, 2014.
- [47] F. Galán, M. Nuttin, E. Lew, P. W. Ferrez, G. Vanacker, J. Philips, ve J. del R. Millán, “A brain-actuated wheelchair: Asynchronous and non-invasive Brain-computer interfaces for continuous control of robots”, *Clin. Neurophysiol.*, c. 119, sayı 9, ss. 2159–2169, 2008.
- [48] A. Ferreira, T. F. Bastos-Filho, M. Sarcinelli-Filho, J. L. M. Sánchez, J. C. G. García, ve M. M. Quintas, “Improvements of a brain-computer interface applied to a robotic wheelchair”, *Commun. Comput. Inf. Sci.*, c. 52, ss. 64–73, 2010.
- [49] A. B. Benevides, T. F. Bastos, ve M. Sarcinelli Filho, “Proposal of brain-computer interface architecture to command a robotic wheelchair”, içinde *Proceedings - ISIE 2011: 2011 IEEE International Symposium on*

- Industrial Electronics*, 2011, ss. 2249–2254.
- [50] S. M. T. Müller, W. C. Celeste, T. F. Bastos-Filho, ve M. Sarcinelli-Filho, “Brain-computer interface based on visual evoked potentials to command autonomous robotic wheelchair”, *J. Med. Biol. Eng.*, c. 30, sayı 6, ss. 407–416, 2010.
- [51] T. F. Bastos, S. M. T. Müller, A. B. Benevides, ve M. Sarcinelli-Filho, “Robotic wheelchair commanded by SSVEP, motor imagery and word generation”, içinde *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS*, 2011, ss. 4753–4756.
- [52] R. Zhang, Y. Li, Y. Yan, H. Zhang, S. Wu, T. Yu, ve Z. Gu, “Control of a Wheelchair in an Indoor Environment Based on a Brain-Computer Interface and Automated Navigation”, *IEEE Trans. Neural Syst. Rehabil. Eng.*, c. 24, sayı 1, ss. 128–139, 2016.
- [53] Y. Sankai, “HAL: Hybrid assistive limb based on cybernics”, içinde *Springer Tracts in Advanced Robotics*, 2010, c. 66, sayı STAR, ss. 25–34.
- [54] S. R. Soekadar, M. Witkowski, C. Gómez, E. Opisso, J. Medina, M. Cortese, M. Cempini, M. C. Carrozza, L. G. Cohen, N. Birbaumer, ve N. Vitiello, “Hybrid EEG/EOG-based brain/neural hand exoskeleton restores fully independent daily living activities after quadriplegia”, *Sci. Robot.*, c. 1, sayı 1, s. eaag3296, 2016.
- [55] N.-S. Kwak, K.-R. Müller, ve S.-W. Lee, “A lower limb exoskeleton control system based on steady state visual evoked potentials”, *J. Neural Eng.*, c. 12, sayı 5, s. 56009, 2015.
- [56] K. K. Ang ve C. Guan, “Brain-computer interface for neurorehabilitation of upper limb after stroke”, *Proc. IEEE*, c. 103, sayı 6, ss. 944–953, 2015.
- [57] J. B. Zimmermann ve A. Jackson, “Closed-loop control of spinal cord stimulation to restore hand function after paralysis”, *Front. Neurosci.*, sayı 8 MAY, 2014.
- [58] K. K. Ang, C. Guan, K. S. Phua, C. Wang, L. Zhou, K. Y. Tang, G. J. Ephraim Joseph, C. W. K. Kuah, ve K. S. G. Chua, “Brain-computer interface-based robotic end effector system for wrist and hand rehabilitation: results of a three-armed randomized controlled trial for chronic stroke”, *Front. Neuroeng.*, c. 7, 2014.
- [59] E. Epoc, J. Yu, ve K. Sim, “EMOTIV EPOC: Brain computer interface and scientific contextual EEG”, 2015. [Çevrimiçi]. Available at: <http://emotiv.com/files/Emotiv-EPOC-Product-Sheet-2014.pdf>. [Erişim: 18-Tem-2016].
- [60] E. Alpaydin, *Introduction to Machine Learning*. 2014.
- [61] E. Alpaydin, *Introduction to Machine Learning*. 2014.
- [62] E. Alpaydin, *Introduction to machine learning*. 2014.

#### **EK A (Appendix A)**

emologger2 ve emoexperimentMotorC34v4 yazılımlarına <http://github.com/gmyuriy/emologger> linkten ulaşabilirsiniz.