T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

EEG SİNYALLERİNİN BEYİN MAKİNE ARAYÜZÜ AMAÇLI KULLANIMI

SABİT ÇAKIR

YÜKSEK LİSANS TEZİ
ELEKTRONİK VE HABERLEŞME MÜHENDİSLİĞİ ANABİLİM DALI
ELEKTRONİK PROGRAMI

DANIŞMAN
YRD. DOÇ. DR. UMUT ENGİN AYTEN

İSTANBUL, 2016

T.C.

YILDIZ TEKNİK ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

EEG SİNYALLERİNİN BEYİN MAKİNE ARAYÜZÜ AMAÇLI KULLANIMI

Sabit ÇAKIR tarafından hazırlanan tez çalışması 12.08.2016 tarihinde aşağıdaki jüri tarafından Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Elektronik ve Haberleşme Mühendisliği Anabilim Dalı'nda **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Tez Danışmanı

Yrd. Doç. Dr. Umut Engin AYTEN

Yıldız Teknik Üniversitesi

Jüri Üyeleri

Yrd. Doç. Dr. Umut Engin AYTEN

Yıldız Teknik Üniversitesi _____

Yrd. Doç. Dr. Tuba KIYAN

Yıldız Teknik Üniversitesi _____

Yrd. Doç. Dr. Tolga Ensari

İstanbul Üniversitesi _____

Bu çalışma, Yıldız Teknik Üniversitesi Bilimsel Araştırma Projeleri Koordinatörlüğü' nün 2014-04-03-KAP01 ve 2014-04-03-YL01 numaralı projeleri ile desteklenmiştir.

ÖNSÖZ

Mevcut teknolojik ilerlemeler dikkate alındığında insanlığın birçok zoru başardığı görünmektedir. Bilgisayar, elektronik ve biyomedikal gibi disiplinlerarası alanların geldiği düzey, insan sağlığı ve insan sağlığı üzerinde çözümlenemeyen hareket kaybı gibi sorunlar için alternatif çözüm yolu arayışlarına kapı açmıştır. İnsanı insan yapan, tüm bilişsel aktivitenin merkezi diyebileceğimiz organımız beyin; tüm bilişsel süreç boyunca belirli elektriksel örüntüler oluşturmaktadır. Bu örüntülerden elektronik, bilgisayar ve makine öğrenmesi teknikleriyle sınırlı sayıda da olsa anlamlı komutlar elde edilebilmekte, gelecekte ise bu etkinliklerin, belirli sorunlar için daha etkili çözümler oluşturulmasının önünü açacağı öngörülmektedir. Tez çalışmasında beyin makine arayüzü (BMA) sistemlerinin oluşturulma süreçleri ele alınmış P300 işareti kullanılarak geliştirilecek BMA sisteminin ilk aşaması olan çevrimdışı analiz kısmı gerçekleştirilmiştir. Bu amaçla C# .Net dilinde bir adet P300 heceleyici uygulaması, Matlab ile analiz yazılımı hazırlanmış; daha sonra elde edilen özellik vektörleri Weka uygulaması kullanılarak sınıflandırılmıştır.

Çalışma süresince desteğini esirgemeyen tüm değerli hocalarıma teşekkürü borç bilirim.

Ağustos, 2016

Sabit ÇAKIR

İÇİNDEKİLER

Sayfa

SİMGE LİSTESİ vii

KISALTMA LİSTESİ viii

ŞEKİL LİSTESİ ix

ÇİZELGE LİSTESİ x

ÖZET xi

ABSTRACT xiii

BÖLÜM 1

GİRİŞ 1

1.1 Literatür Özeti 1
1.2 Tezin Amacı 3
1.3 Hipotez 4

BÖLÜM 2

EEG SİNYALLERİNİN OLUŞUMU 5

2.1 EEG Sinyallerinin Biyolojik Kökeni 5
2.2 EEG Sinyallerinin Davranışı 6
2.3 Uyarılmış Potansiyeller 8

BÖLÜM 3

BMA İŞLEM SÜREÇLERİ 10

3.1 Verilerin Elde Edilmesi 11
3.2 Ön İşlemler 13
3.3 Sınıflandırma 14
3.3.1 Naive Bayes 14
3.3.2 Çok Katmalı Algılayıcı (ÇKA) 15
3.3.3 Destek Vektör Makineleri (DVM) 20

BÖLÜM 4

BMA SİSTEM YÖNTEMLERİ 23

4.1 Motor İmgeleme 23
4.2 SSVEP 23
4.3 P300 26

BÖLÜM 5

BMA HECELEME SİSTEMİ TASARIMI VE P300 VERİLERİNİN ELDE EDİLMESİ 29

5.1 EEG Kayıt ve Çevre Birimleri 31
5.2 Uyaran Sunumu 32
5.3 Uyaran ve EEG Veri Senkronizasyonu 36
5.4 EEG Kayıt Yazılımı 37
5.5 EEG Yayın Sunucusu 38
5.6 Veri işleme Birimi 38
5.6.1 Segmentasyon 39
5.6.2 Detrend 40
5.6.3 Kayar Ortalama Filtre 40
5.6.4 Ortalama 40
5.6.5 Öznitelik Seçimi 40
5.6.6 Veri Azaltma 47
5.6.7 Öznitelik Kümesi Birleştirme 47
5.6.8 Normalizasyon 47
5.6.9 Sınflandırma 47

BÖLÜM 6

BMA SİSTEMİNİN TEST VERİLERİNİN SINIFLANDIRILMASI VE DEĞERLENDİRİLMESİ 49

BÖLÜM 7

SONUÇ VE ÖNERİLER 54

KAYNAKLAR 56

ÖZGEÇMİŞ 61

SİMGE LİSTESİ

$Ç_i$	i. YSA çıkışı
β	YSA eşik değeri
λ	YSA öğrenme katsayısı
δ_m	m. no' lu sinir hücresine ait hata
A	sinir hücresine ait girdi ağırlığı
ξ_i	DVM' de hiper düzlemin ters tarafında kalan örnekler için yapay değişken

KISALTMA LİSTESİ

ALS	Amyotrofik Lateral Skleroz (Amyotrophic Lateral Sclerosis)
Au	Altın
Ag	Gümüş
AgCl	Gümüş Klorür
BMA	Beyin Makina Arayüzü
ÇKA	Çok Katmanlı Algılayıcı
DVM	Destek Vektör Makineleri
DP	Doğru Pozitif
DN	Doğru Negatif
ECG	Elektrokardiyografi
ECOG	Elektrokortikografi
EEG	Elektroensefalografi
EMG	Elektromiyografi
fMRI	Fonksiyonel Manyetik Rezonans Görüntüleme
HP	Hatalı Pozitif
HN	Hatalı Negatif
MI	Motor İmgeleme (Motor Imagery)
MEG	Manyetoensefalografi
Ö.O	Öğrenme Oranı
PET	Pozitron Emisyon Tomografi
SCP	Yavaş Kortikal Potansiyel (Slow Cortical Potential)
SSVEP	Kararlı Hal Görsel Uyarılmış Potansiyel (Steady State Visual Evoked Potential)
UP	Uyarılmış Potansiyeller

ŞEKİL LİSTESİ

Sayfa

Şekil 2. 1 Aksiyon potansiyelinin oluşumu 6
Şekil 2. 2 Beyin lobları 7
Şekil 2. 3 Orta oksipital lob' dan alınmış EEG verisinde, 200 ms altında N1, P1, N2 VEP (görsel uyarılmış potansiyeller) bileşenleri 9
Şekil 3. 1 Temel BMA bileşenleri 10
Şekil 3. 2 Uluslararası 10-20 sisteme göre A) Soldan elektrot pozisyonlarının görünümü B) Yukardan elektrot pozisyonlarının görünümü 13
Şekil 3. 3 Temel ÇKA modeli 16
Şekil 3. 4 İki sınıflı veri kümesi için hiper düzlemler ve sınırlar üzerindeki destek vektörleri 21
Şekil 4. 1 Dört sınıflı, sınıflandırma problemi için SSVEP ekran tasarımı 24
Şekil 4. 2 Frekans domeninde 6Hz - 8.2 Hz arası SSVEP uyaran frekanslarına bağlı tepeler 25
Şekil 4. 3 Uyarandan sonra 300ms - 500ms arasında oluşan p300 bileşeni 26
Şekil 4. 4 Orijinal P300 heceleme ekranı 27
Şekil 4. 5 Uygulamada istenen harfin belirlenmesi 28
Şekil 5. 1 Çevrimdışı kayıt topolojisi 30
Şekil 5. 2 Planlanan çevrimiçi BMA tasarımı 30
Şekil 5. 3 ActiCap aktif elektrotlar 31
Şekil 5. 4 Vamp 16+2 kanal amplifier 32
Şekil 5. 5 Easy Cap Uluslarası 10 -20 sistemine uygun kep 32
Şekil 5. 6 Uygulama giriş ekranı 33
Şekil 5. 7 Uygulama yapılandırma ekranı 34
Şekil 5. 8 P300 heceleyici uygulama ekranı 36
Şekil 5. 9 S-Link marka paralel port kartı 37
Şekil 5. 10 Brain Recorder uygulama ekran görüntüsü 38
Şekil 5. 11 Brain Analyzer 2 uygulama ekran görüntüsü 39
Şekil 5. 12 Denek 1' e ait ortalama üzerinden dalga formu değişimi 42
Şekil 5. 13 Denek 2' ye ait ortalama üzerinden dalga formu değişimi 43
Şekil 5. 14 Denek 3' e ait ortalama üzerinden dalga formu değişimi 44
Şekil 5. 15 Denek 4' e ait ortalama üzerinden dalga formu değişimi 45
Şekil 5. 16 Denek 5' e ait ortalama üzerinden dalga formu değişimi 46

ÇİZELGE LİSTESİ

Sayfa

Çizelge 5. 1 EEG uyaran işaretlerinde bitlerin kullanım şekli 37
Çizelge 6. 1 Denek 1' e ait öznitelik kümesi seçimi ve algoritma başarıları 50
Çizelge 6. 2 Denek 2' e ait öznitelik kümesi seçimi ve algoritma başarıları 51
Çizelge 6. 3 Denek 3' e ait öznitelik kümesi seçimi ve algoritma başarıları 51
Çizelge 6. 4 Denek 4' e ait öznitelik kümesi seçimi ve algoritma başarıları 52
Çizelge 6. 5 Denek 5' e ait öznitelik kümesi seçimi ve algoritma başarıları 52

ÖZET

EEG SİNYALLERİNİN BEYİN MAKİNE ARAYÜZÜ AMACIYLA KULLANILMASI

Sabit ÇAKIR

Elektronik ve Haberleşme Mühendisliği Anabilim Dalı

Yüksek Lisans Tezi

Tez Danışmanı: Yrd. Doç. Dr. Umut Engin AYTEN

Beyin Makine Arayüzü (BMA), beyin sinyallerinin herhangi bir sistemde girdi olarak kullanılması amacıyla; sinyallerin elde edilmesi, işlenmesi ve anlamlı hale getirilmesini içeren teknolojiyi ifade etmektedir.

BMA teknolojisi; omurilik zedelenmesi, nöral kanallarda oluşan zarar ve ALS (Amyotrofik Lateral Skleroz) gibi rahatsızlık durumlarında kritik önem kazanmaktadır. Bu gibi rahatsızlıklarda organlarla beyin sinyallerinin iletişimi kesilse de; beyin, sinyalleri aynı şekilde üretmeye devam eder. Bu sinyallerin işlenerek yapay organlara ya da bilgisayara iletilmesi ve kullanılması için belirli yöntemler geliştirilmiştir. Bu yöntemler içinde P300 tabanlı sistemler ve SSVEP tabanlı BMA uygulamaları beynin uyaranlara karşı doğal tepkisini temel aldıkları için; eğitim süresi, ihtiyaç duyulan elektrot sayısı gibi nedenlerle en uygulanabilir yöntemler olarak değerlendirilmiştir. İnvaziv BMA yöntemleriyle birlikte fMRI (Fonksiyonel Manyetik Rezonans Görüntüleme), PET (Pozitron Emisyon Tomografi) ve MEG (Manyetoensefalografi) gibi yöntemler hem maliyet, hem de uygulanabilirlik açısından belirli zorlukları içermektedir.

Son 30 yılda BMA teknolojisinde invaziv ve invaziv olmayan olmak üzere; birçok başarılı çalışma yapılmış ve gelişen teknolojik imkânlarla birlikte daha başarılı sonuçların elde edileceği öngörülmektedir.

Tez çerçevesinde bu amaçla kullanılan yaklaşımlar anlatılmış, bir adet bağımsız P300 heceleyici uygulaması geliştirilmiş, veriler Matlab ortamında analiz edilmiş ve Weka uygulamasında sınıflandırılarak BMA geliştirme sürecinin ilk aşaması olan çevrimdışı analiz kısmı gerçekleştirilmiştir.

Anahtar Kelimeler: Elektroensefalogram, Beyin Makine Arayüzü P300, SSVEP, Naive Bayes, ÇKA, DVM

ABSTRACT

USING OF EEG DATA FOR THE PURPOSE OF BRAIN COMPUTER INTERFACES

Sabit ÇAKIR

Department of Electronics and Communications Engineering

MSc. Thesis

Adviser: Assoc. Prof. Dr. Umut Engin AYTEN

Brain Machine Interfaces (BMI), identifies the developed technology that aimed to use brain signals on any system as input that includes acquiring, processing and evaluating of signals. The technology of BMI comes into question in case of illness like spinal cord damages, damage of neural channels and ALS (Amyotrophic Lateral Sclerosis). In case of this kind of illness brain and limbs disconnects but the brain activity remains as same as previous.

Certain methods are developed for processing and sending these signals to prostetic libs or computers. P300 based systems and SSVEP based applications are assessed as applicable methods since they have shorter training time and less required electrode channels because these methods depends on human brain's natural reaction.

Invasive techiques with the methods of fMRI (Functional Magnetic Resonance Imaging), PET (Positron Emission Tomography) and MEG (Magnetoencephalography) consist some kind of difficulties in terms of cost and usability.

In the last 30 years, many applications have been developed as invasive and non-invasive in BMI technologies and it is projected to obtain more succesful results with the developing technologies.

In the context of this thesis, some basic approaches are explained and standalone P300 speller application is developed. Then, obtained data are analyzed in MATLAB

environment. These data are classified via WEKA and offline analysis as the first part of the BCI development is applied.

Keywords: Electroencephalogram, Brain Machine Interface, Naive Bayes, MLP, SVM

BÖLÜM 1

GİRİŞ

1.1 Literatür Özeti

EEG tabanlı Beyin Makine Arayüzü (BMA) çalışmalarının tarihi 1970' lerde Kaliforniya Üniversitesinde Vidal' in [1] çalışmalarıyla başlıyor görünse de altyapı olarak elektroensefalografi (EEG) ve biyoelektriksel aktivitenin ölçüm sürecine ait tarih daha da eskidir. Galvani (1737 - 1798), kurbağa bacağının metalle temas durumundaki hareketiyle, kurbağa bacağının sinir sistemindeki elektriksel aktivite arasında ilişki kurmuştur [2]. Helmotz (1821 - 1894), yaptığı çalışmada kurbağa sinir iletisinin hızının 25m/s ve 43m/s arasında olduğunu keşfetmiştir [3]. Bernstein (1839 - 1917), 1902 yılında biyolojik hücre ve dokuya ait "Elektriksel Potansiyellerin Membran Teorisi"' ni geliştirmiştir. Berstein aynı zamanda biyolojik sinir iletisine aksiyon potansiyeli ismini veren ve aksiyon potansiyelinin ilk sayısal açıklamasını yapan kişidir [4]. Caton, tavşan ve maymun beyinleri üzerinde yaptığı çalışmalarla beynin elektriksel doğasını açıklamış (1875) ve Berger' in EEG sinyalleriyle alakalı çalışmalarına zemin hazırlamıştır [5]. Berger (1873 - 1941) ilk defa insan beynine ait elektriksel aktivitenin ölçümünü yapmış ve EEG ismini vermiştir [6]. Adrian (1889 - 977) yaptığı çalışmalarla Berger' in keşiflerini onaylamıştır (1934) [7]. Hodgkin (1914 - 1998) ve Huxley (1917 - 2012) sinir iletiminin hücre zarı ve iyonlarla ilişkisini açıklamışlardır [8]. Walter, Nörofizyoloji üzerine 24 kanallı EEG cihazını elektrot konumlarıyla tanımlamış ve uygulamıştır [9]. Jasper bugün kullandığımız uluslararası 10 - 20 sistemindeki elektrot dizilimini geliştirmiştir (1958) [10].

Fetz çalışmalarını makak maymunlarına yoğunlaştırarak (1969), makak maymunlarının beyinlerinde, presentral korteks bölgesinde tek bir nöronun davranışını incelemiştir [11]. Georgopoulos vd. maymun beyninde motor korteks' te el hareketiyle alakalı bağımsız nöronların davranışını incelemiştir (1986) [12]. Yaptıkları çalışmada 274 bağımsız nöron' un el konumunu uzayda nasıl sağladığına ait matematiksel modeli oluşturmuşlardır (1988) [13]. 1987 yılında Kennedy ilk neurotrophic elektrodu geliştirmiştir. Kennedy vd. maymun beynine yerleştirdikleri bu elektrotla ilk intrakortikal BMA' yı geliştirmişlerdir. Daha sonra Kennedy ve Bakay aynı uygulamayı ilk defa insan üzerinde başarılı bir şekilde gerçekleştirmişlerdir [14].

Bunlarla birlikte Chapin vd. tarafından fareler üzerinde yapılan invaziv BMA çalışmaları başarılı BMA çalışmalarına örnek verilebilir [15].

Non invaziv EEG tabanlı BMA çalışmalarına döndüğümüzde ise P300, SSVEP ve Motor İmgeleme (Motor Imagery) tabanlı BMA çalışmaları daha fazla uygulanma alanı bulmuşlardır.

1988 yılında P300 sinyallerinden faydalanarak Farewell ve Donchin P300 heceleme uygulamasını geliştirmiştir [16]. Bu uygulamada dört farklı sınıf ve iki farklı uyaran arası zaman aralığı (125ms ve 500ms) kullanarak dakikada ortalama 2.3 harf elde edebilmişlerdir. Bu sistemde sıklıkla gelen uyaran karşısında, beklenen uyaranla karşılaşıldığında yaklaşık 300 ms sonra, çeper (parietal) lobu potansiyellerinde belirlenebilir değişimden faydalanmışlardır. Çalışmada; farklı uyaran zaman aralıklarında, farklı sınıflandırıcıların performanslarını değerlendirmişlerdir. P300 heceleme sisteminde 6 x 6' lık matris üzerinde sırasıyla yanan ve sönen satır sütun ikililerinin içinde, P300 sinyalini taşıyan ikilinin kesişiminden denek tarafından belirlenen harf seçilebilmektedir.

Son yıllarda Obeidat vd. tarafından P300 heceleyici sisteminin performansını artırmak için; uyaranların yakınlığı gibi etkenlerin olumsuz etkilerini ortadan kaldırmak amacıyla ”Edges Paradigm” geliştirilmiştir [17].

Regan, 1966' da monokromatik ışıkta görsel uyaranlarla alakalı çalışmalara başlamıştır. Çalışmalarda bu uyaranların EEG' de küçük genlikte kararlı görsel uyarılmış potansiyeller oluşturduğu belirlenmiştir [18]. Bu EEG dalgaları daha sonra insan görme

sistemine ait kararlı hal görsel uyarılmış potansiyeller (SSVEP) terminolojisiyle ifade edilmiştir. Kişi belirli bir frekansta tekrarlayan görsel uyarana baktığında oluşan bu tepki, frekans domeninde uyaran ve onun harmoniklerinde tepe noktası olarak elde edilebilmektedir. SSVEP tabanlı BMA uygulamalarında bu amaçla öncelikle farklı frekanslarda titreşen uyaranlar oluşturulur. Tercih edilen uyarana ait EEG örüntüleri BMA amaçlı kullanılabilmektedir [19].

SSVEP ve P300 yöntemlerinin birlikte kullanıldığı hibrit çalışmalar da mevcuttur [20].

Bugün, P300 ve SSVEP yöntemleri hızlı uygulanabilirlik açısından en avantajlı invaziv olmayan yöntemlerdir. Bunların haricinde Motor Imgeleme ve Mu - Beta ritimleri [21], yavaş kortikal potansiyeller (SCP) ' den [22] faydalanılan çalışmalar mevcuttur.

Tez çalışmasında Motor İmgeleme, SSVEP ve P300 yöntemleri anlatılmış, daha sonraki çalışmalarda da kullanabilmek üzere bir adet konfigüre edilebilir P300 heceleyici uygulaması yazılmış ve elde edilen verilerle BMA geliştirme sürecinin ilk aşaması olan çevrimdışı analiz kısmı gerçekleştirilmiştir.

1.2 Tezin Amacı

Beyin makine arayüzü teknolojisinde farklı teknik ve yaklaşımlar mevcuttur. Bu teknikler; risk, başarım ve zamansal/uzamsal çözünürlük gibi faktörler dikkate alındığında EEG işaretlerinin, BMA amacıyla kullanılabilecek en anlamlı işaretler olduğu değerlendirilmektedir. EEG tabanlı BMA çalışmalarında, yaklaşımları EEG sinyallerine erişim bakımından; invaziv ve invaziv olmayan şeklinde ikiye ayırabilmemiz mümkündür. İnvaziv BMA çalışmalarında elektrotlar doğrudan kortekse yerleştirilerek gürültüsüz sinyaller elde edilebilmektedir. Bununla birlikte cerrahi müdahalenin riskleri ve uygulama koşullarının erişilebilirliği dikkate alındığında, uygulanabilirlik açısından invaziv olmayan yöntemler kadar tercih edilebilir görünmemektedir. İnvaziv olmayan yöntemde ise elektrotlar saç derisi üzerine yerleştirildiğinden sinyal gürültü oranı artmaktadır. Bu durumda farklı filtre ve teknikler kullanılarak anlamlı sinyaller elde edilmeye çalışılmaktadır. Tez çalışmasının konusu invaziv olmayan yöntem ile elde edilen sinyallerin gürültü azaltımı, makine öğrenmesi yöntemleriyle işaretlerin sınıflandırılması ve sistem için girdi olarak değerlendirilmesi olacaktır. Bu amaçla tez

çerçevesinde çevrimdışı analiz amacıyla kullanılacak, daha sonrasında ise çevrimiçi analizde de kullanılabilecek bağımsız bir P300 heceleyici uygulamasının geliştirilmesi planlanmıştır.

2. bölümde EEG' sinyallerinin oluşumu ve karakteristiği, 3. bölümde ise BMA işlem süreçleri anlatılmış, 4. bölümde BMA sistemlerine ait sık kullanılan yöntemler, 5. bölümde ise Brain Products marka V-Amp EEG Cihazı, donanımsal kurulum ve P300 metodolojisi üzerine BMA geliştirme sürecindeki tecrübemiz, 6. bölümde geliştirilen uygulamaya ait test sonuçları anlatılmış son olarak ta 7. bölümde test sonuçlarına ait değerlendirme yapılmıştır.

1.3 Hipotez

BMA amaçlı çalışmalarda uygun özellik seçimi ve sağlıklı bir yapılandırma kullanılarak çevrimiçi bir P300 heceleyicisi uygulamasının altyapısını sağlamak mümkündür.

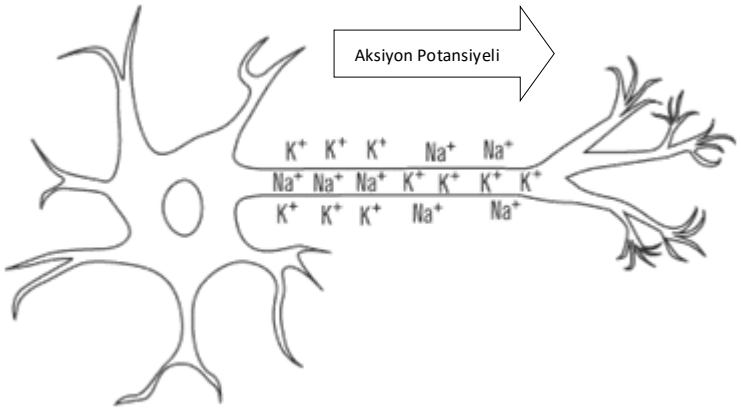
BÖLÜM 2

EEG SİNYALLERİNİN OLUŞUMU

EEG; saç derisi üzerinden iki farklı noktadan elektrotlar aracılığıyla elde edilen beyin kaynaklı voltaj farkının belirli zaman periyotlarında ölçülmesi ve grafiksel gösterimini ifade etmektedir. EEG haricinde bu sinyaller; daha az gürültüyle elektrokortikogram (ECOG) vasıtasıyla invaziv yöntemlerle de elde edilebilmektedir. Beyin tüm bilişsel aktiviteler boyunca farklı frekans bantlarında bu sinyalleri üretmektedir. EEG sinyalleri sadece beyin değil, tüm beden hakkında fikir verdiği için daha çok beyin rahatsızlıkları olmak üzere; uzunca zamandır klinik teşhis ve tedavide ciddi bir referans kaynağı kabul edilmektedir. Bu sinyallarin oluşumu belirli biyokimyasal süreçlere dayanmaktadır.

2.1 EEG işaretlerinin Biyolojik Kökeni

EEG sinyalleri tüm sinir sistemindeki elektriksel iletilerin serebral korteks boyunca oluşturdukları potansiyel farklarıdır. Bu elektriksel aktiviteler sinir sisteminin en küçük birimi olan nöronlar düzeyinde oluşmaktadır. Normal koşullarda membran (hücre zarı) boyunca, hücre içinde ve dışında potansiyel farkı mevcuttur. Hücre içi negatif (-70 mV), dışı pozitif yüklüdür.



Şekil 2. 1 Aksiyon potansiyelinin oluşumu [23]

Membranın uyarılması sonucu oluşan iyon transferi akson boyunca ilerleyen ve tek yönlü elektriksel bir aktivite oluşturur. Bu aktivite belirli biyokimyasal süreçler neticesinde oluşur. Eğer elektriksel uyarım belirli bir eşiğe ulaşmışsa membranda Sodyum (Na^+) kapıları açılır ve hücre Na^+ yüklenmeye başlar buna depolarizasyon denir. Bu arada bu pozitif yüklenme belirli bir eşiğe ulaştıktan sonra Potasyum (K) kapıları açılır ve hücre dışına doğru potasyum akımı başlar ve hücre tekrardan negatif yüklenir. Bu durum ise repolarizasyon olarak ifade edilir.

Daha sonra hücre tekrar eski haline döndüğünde Na^+ ve K kapıları kapanır. Potansiyel değişimi akson boyunca bu şekilde ilerler. Şekil 2. 1' de aksiyon potansiyeli olarak adlandırılan bu elektriksel potansiyel değişimi gösterilmiştir.

Bir hücrenin aksonu ve diğer sinir hücresinin dendritleri arasında sinapslar vardır. Oluşan bu elektriksel ileti daha sonra nörotransmitter adı verilen kimyasallar vasıtasıyla sinapslardan diğer sinir hücresinin dendritlerine iletilir. Dendritler gelen elektriksel iletiyi hücre gövdesine taşıyan çıkıntılardır. Dentritlerden hücre gövdesine iletilen ileti belirli bir eşiği aşarsa diğer hücrelere aynı şekilde iletilmeye devam eder.

2.2 EEG Sinyallerinin Davranışı

EEG sinyallerin davranışı kişi, yaş ve cinsiyet gibi özelliklere bağlı olarak belirli farklılıklar gösterse de belirli bilişsel süreçlerde belirgin olan beş temel EEG frekans bandı mevcuttur. Bunlar sırasıyla şunlardır. Alfa, teta, beta, delta ve gama.

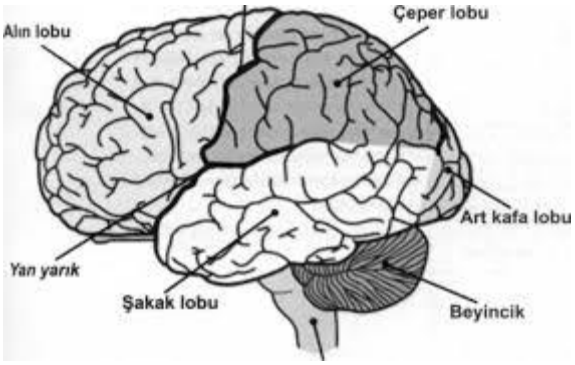
Alfa ve Beta dalgaları, ilk olarak Hans Berger tarafından tanımlanmıştır [24]. Alfa dalgası 8 Hz ve 13 Hz arasındadır ve yine ayrıca Berger dalgası adıyla bilinmektedir [25]. Bu dalga özellikle kişi dinlenme halinde gözleri kaplı olarak yatarken oluşmaktadır [26].

Beta dalgasının frekans aralığı 13 Hz ve 30 Hz bandıdır. Beta dalgası aktif düşünce, fokus ya da aktif şekilde çalışırken oluşmaktadır [27].

Teta frekansı 1944' te Dovey ve Walter tarafından tanımlanmıştır [28]. Teta dalgası 4 Hz ve 7.5 Hz arasında uyku gibi zihnin bilinçsiz durumlarında ortaya çıkmaktadır. Delta dalgası 0.5 Hz ve 4 Hz aralığında derin uyku durumunda ortaya çıkmaktadır. Gama dalgası 30 Hz üzerini ifade etmektedir.

Beyin çalışma frekansları ve belirli sağlık sorunları arasındaki ilişkiler klinik araştırmalara konu olmaya devam etmektedir. Meditasyon ve EEG ilişkisi [29] , Epilepsi ve EEG ilişkisi [30] üzerine yapılan çalışmalar ilgili çalışmalara örnek verilebilir.

İnsan sinir sisteminde 10 milyar civarı sinir hücresi mevcuttur. Bir beyin hücresinde diğer sinir hücreleriyle yaklaşık 10000 civarı bağlantı vardır [31]. Beyin yapısal olarak; iki yarım küre ve farklı fonksiyonları icra eden dört lobdan oluşmaktadır. Bu loblar görsel şekil 2.2 de gösterilmiştir. Sol yarım küre mantıksal ilişki, yorum ve matematiksel ilişki çerçevesinde etkinlik gösterirken, sağ yarım küre daha çok görsel bilgi, sezgisel yaklaşım ve duygular çerçevesinde düşünme gibi alanlarda etkinlik gösterir [32].



Şekil 2. 2 Beyin lobları [33]

Bu loblar aşağıdaki gibidir.

- **Alın Lobu (Frontal Lobe)**
- **Şakak Lobu (Temporal Lobe)**
- **Çeper Lobu (Parietal Lobe)**
- **Arka Kafa Lobu (Occipitial Lobe)**

Alın lobu; mantık yürütme, analitik düşünce ve planlama ile ilgilenir. Şakak lobu; işitme, hafıza, organizasyon konuşulan dili anlama ile ilgilenir. Yan kafa lobu; konuşulan dili ve kelimeleri yorumlama, dış dünyadan gelen görsel, işitsel, hafızadan, motor-sensori sistemden gelen işaretlerin yorumlanması ve görsel-uzamsal algı ile ilgilenir. Arka kafa lobu; görme duyusuyla alakalı işlemlerle ilgilenir (görüntülere ait renk, ışık, hareket gibi verilerin yorumlanması) [34].

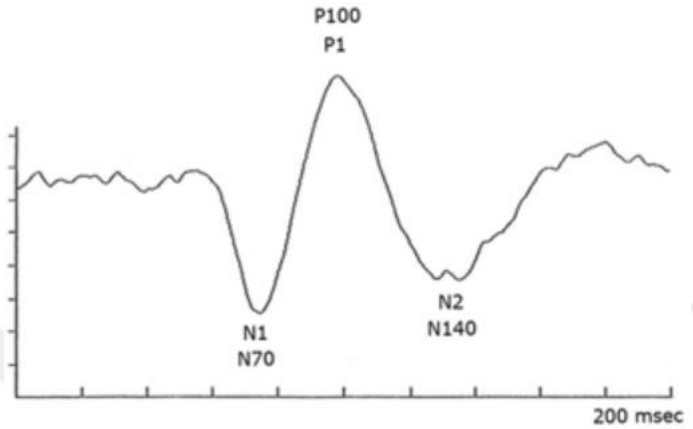
İnsan beyninin dış kısmı ise beynin büyük kısmını örten ve ayrıca gri madde gibi isimlerle anılan serebral korteks, 1.5 mm ve 5 mm arasındaki kalınlıkta bir yapıdan oluşur [35].

2.3 Uyarılmış Potansiyeller

Modern dönemde uyarılmış potansiyel (UP) çalışmalarının tarihi 1964' te başlamıştır [36]. UP, herhangi dâhili ya da harici bir uyaran karşısında kişinin sinir sisteminde oluşan elektriksel tepkiyi ifade etmektedir. Olaya ilişkin potansiyeller ve uyarılmış potansiyeller, çalışmalarda aslında aynı şeyi ifade etmektedir [37]. UP çalışmalarında belirli bir zaman aralığı / periyodu belirlenerek kişiye görsel, işitsel ya da daha farklı bir uyaran uygulanır. Örneğin; kişiye sıklıkla gösterilen bir uyaran içinde, özel bir uyaranı gördüğünde bir butona basması ya da içinden sayması istenir. Çalışma yapılırken oluşacak elektriksel aktivitenin mümkün ölçüde gürültüsüz kayıt elde edilebilmesi için, kişiden gözünü kırpmaması ya da hareket etmemesi gibi isteklerde bulunulabilir. Tıbbi amaçlı UP çalışmalarında EEG sinyallerinde gecikme, genlik gibi parametreler patolojiyi saptamak için değerlendirilir [38].

Uyarılmış potansiyel çalışmalarına görsel (VEP), işitsel (AEP) ve duyusal (SSEP) uyarılmış potansiyel çalışmalarını verebiliriz. UP çalışmalarında özellikle aranan belirli bileşenler

vardır. Uyarandan sonraki zaman aralıklarına bağlı olarak bunlara P1 (P100), P2 (P200), P3 (P300), N1 ve N2 bileşenlerini örnek verebiliriz. Örnek işaretler şekil 2. 3' te gösterilmiştir. BMA çalışmalarında görsel uyarılmış potansiyellerden sıkça faydalanılmaktadır. P300 tabanlı BMA çalışmaları ilerleyen bölümlerde daha detaylı anlatılmıştır.

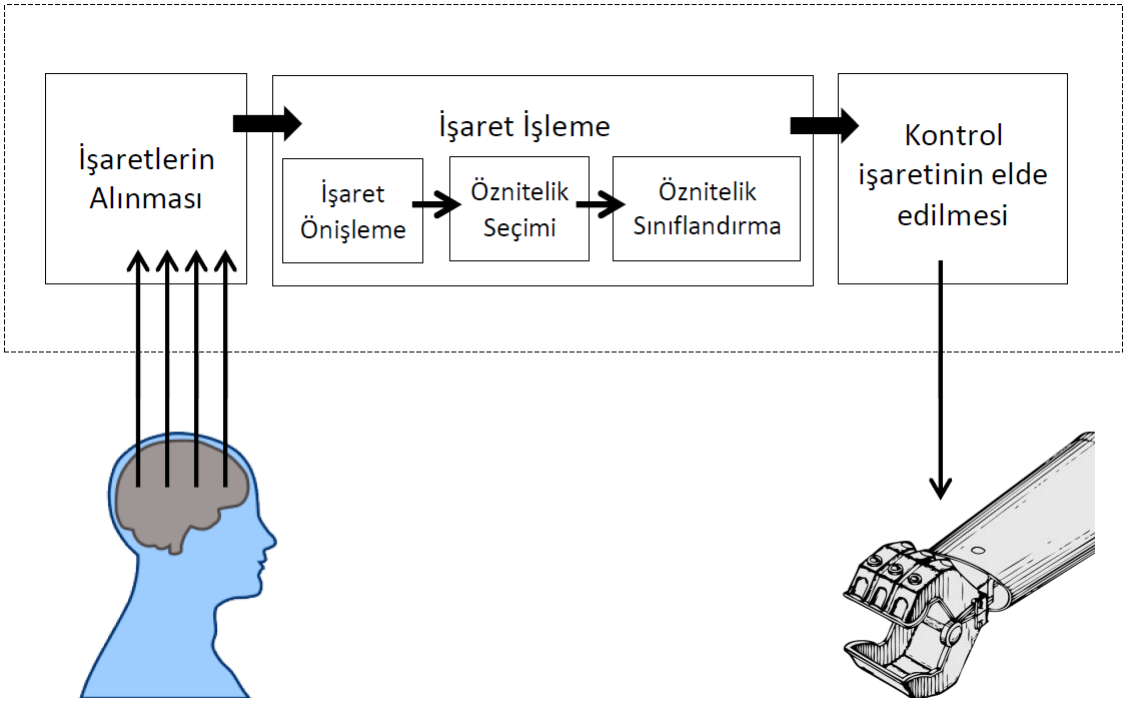


Şekil 2. 3 Orta Oksipital lob' dan alınmış EEG verisinde, 200 ms altında N1, P1, N2 VEP (görsel uyarılmış potansiyeller) bileşenleri [39]

BÖLÜM 3

BMA İŞLEM SÜREÇLERİ

EEG tabanlı BMA sistemlerinde süreç; kabaca verilerin alınması, sinyallerin; ortalama, dönüşüm, filtreleme gibi ön işleme aşaması daha sonra ise kullanılabilir özelliklerin belirlenmesi ve mevcut verilerin sınıflandırılıp, test edilmesi şeklindedir. Bu işlemlerden sonra veriler değerlendirilir ve çevrimiçi test için simulasyon ortamı kurulur. Sistemin ürettiği çıktılar; bilgisayar, protez organ ya da farklı bir cihaz için girdi olarak kullanılabilir. BMA sistemlerine ait bileşenler şekil 3. 1' de gösterilmiştir.



Şekil 3. 1 Temel BMA bileşenleri

3.1 Verilerin Elde Edilmesi

Verilerin elde edilmesi için; öncelikle, asgari olarak belirli donanım bileşenlerine ihtiyaç vardır.

EEG ölçüm sisteminde sinyal ölçüm sürecinin ilk aşamasında elektrotlar yer almaktadır. Elektrotlar EEG haricinde; elektrokardiyografi (ECG), elektromiyografi (EMG) gibi diğer elektriksel kökenli fizyolojik işaretlerin ölçümünde de kullanılmaktadır.

Elektrotların kullanım biçimi ve ihtiyaca göre farklı boyutlarda altın (Au), gümüş (Ag), gümüş klorür (AgCl) veya farklı bir metal olmak üzere; farklı türleri mevcuttur. Elektrotlar uygulanırken, kullanım kolaylığı amacıyla yerleştirmek üzere kep ve empedansı düşürmek üzere elektrot ile saç derisi arasına jel / pasta ya da uygulanacak yüzeye sodyum klorür (NaCl) çözeltisi uygulanabilir. Sağlıklı ölçüm için empedans 5 kOhm' un altında olmalıdır [40].

Elektrotlar kullanılırken dikkat edilmesi gereken belirli parametreler mevcuttur.

- Eğer jel/pasta gibi iletkenliği artıracak bir sıvı kullanılıyorsa yakın iki elektrodun fazla sıvı kullanılarak etkileşime geçmemesine dikkat edilmelidir.
- Göz kapağı artifaktı ya da diğer kas hareketlerine bağlı bozulmalara karşı denek bilgilendirilmelidir. Özellikle göz kapağına yakın yerlerde, göz kapatılıp açıldığında istenmeyen artifaktlar oluşacaktır.
- Elektrot sağlam olup olmadıklarına karşı, ölçüm öncesi empedans testinden geçirilmeli [40].
- Etraf mümkün mertebe manyetik gürültü kaynaklarından arındırılmalı, mümkünse Faraday Kafesi oluşturulmalı [41].
- Şehir şebekesinden kaynaklanan gürültüye karşı noç filtresi uygulanmalı [40].
- Elektrotlar yerleştirilirken nasion ve inion’ un noktası Cz elektrodu olacak şekilde ayarlanmalıdır [42].

EEG sistemlerinde çoğunlukla uluslararası 10-20 sistemi yaklaşım yarım yüzyıldır standart kabul edilmiştir [43]. Uluslarası 10-20 sistemine ait konumlandırma şekil 3. 2’

de gösterilmiştir. Bu sistemde 10 ve 20 elektrotların birbiri arasındaki yüzde cinsinden mesafeyi ifade etmektedir [44].

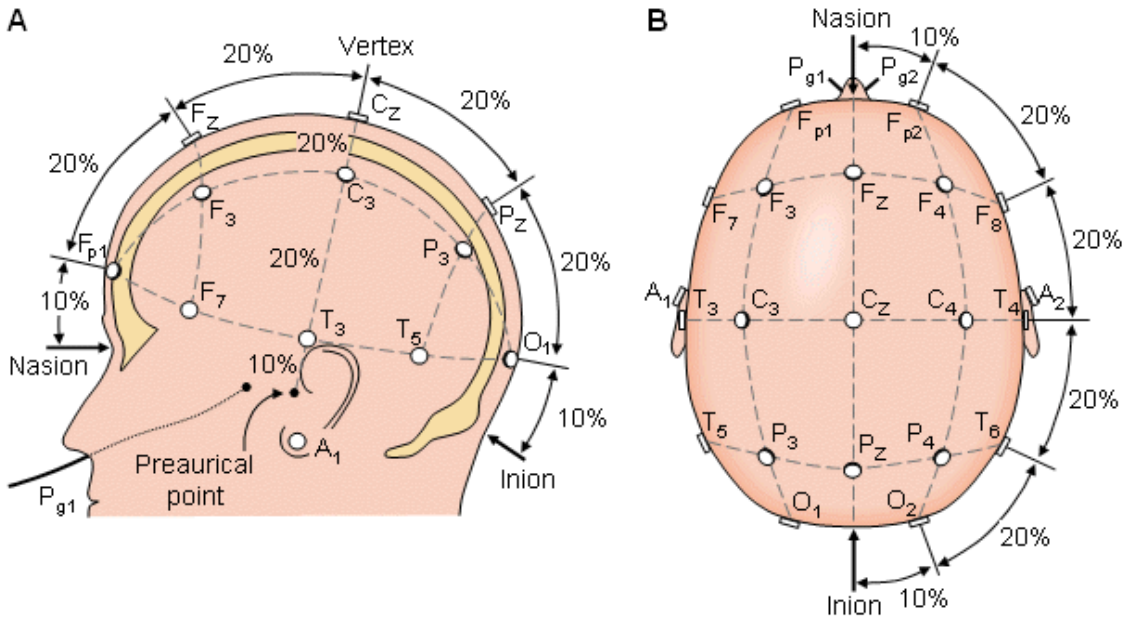
Ayrıca uzamsal konumlar önden arkaya karşılık gelen loblara ait harflerle belirtilmektedir. Sağdan sola ise konum ilgili lob' a karşılık gelen ifadenin yanına; sağ taraf elektrotları çift rakamlar, sol taraf elektrotları için ise tek rakamlar, merkez elektrotları küçük z harfi ile ifade edilir.

- Fp: Frontal Pole
- F: Frontal
- FC: Frontal / Central
- C: Central
- T: Temporal
- P: Parietal
- PO: Parietal / Occipital
- O: Occipital

Bununla birlikte önerilen daha farklı EEG konumlandırma sistemleri de mevcuttur [45].

Sinyal ölçüm sürecinin ikinci aşamasında elektrotlardan sonra amplifier vardır. Elektrotlar üzerinden alınan analog sinyaller tercih edilen edilen örnekleme frekansına bağlı olarak amplifier aracılığıyla digital olarak görüntülenir, kaydedilir ya da çevrimiçi test amacıyla kullanılır. Amplifier aracılığıyla elde edilen veriler üçüncü aşamada bir bilgisayara iletilir.

Bu aşamada elektrotların doğru yerleştirildiği ve sinyallerin doğru alındığı test edilmelidir. Elektrotların doğru bağlandığını ya da empedans düzeyini kontrol etmek için donanımsal ya da yazılımsal kontrol mekanizmaları mevcuttur.



Şekil 3. 2 Uluslararası 10-20 sisteme göre A) Soldan elektrot pozisyonlarının görünümü B) Yukardan elektrot pozisyonlarının görünümü [46]

3.2 Ön İşlemler

Yazılım bileşenine bağlı olarak gerekli filtreler, özellik çıkarımı gibi işlemler yapılır. Uyarılmış potansiyel tabanlı sistemlerde zamanlama ve gürültü azaltımı gibi sebeplerle uyaran ikinci bir bilgisayar tarafından üretilip, test süresince iki bilgisayarın eşzamanlı hale getirilmesi sağlanabilir.

Sistemde kullanılacak yönteme bağlı olarak belirli filtre ve dönüşümler uygulanabilir.

Şehir şebekesi gürültüsünü engellemek amacıyla; Amerikada için 60Hz, Amerika dışında ise 50Hz noç filtresi, çalışılacak yöntemin hassas olduğu frekans aralığına bağlı olarak ise ilgili frekans aralığında band geçiren filtre uygulanabilir.

Ayrıca sinyallere gürültüyü azaltmak için kayar ortalama filtre (moving average filter) gibi uygulamalar da yapılmaktadır [47].

$Y(n)$, n noktasındaki çıktı $X(n)$, n noktasındaki girdi olmak üzere, n adet örnek için yürüyen ortalama filtre aşağıdaki gibi uygulanabilir (3.1).

$$Y_n = \frac{X_1 + \cdots + X_{n-1} + X_n}{n} \tag{3.1}$$

n, örneklerin bitiş konumu olarak kabul edildiği gibi, orta naktası da kabul edilebilir.

Eğer frekans domeninde bir özellik kullanılacaksa, EEG verisi frekans domenine taşınması için Fourier dönüşümü uygulanmalıdır. Ayrıca sınıflandırma için PSD (güç spektral yoğunluğu) özniteliklerinden faydalanılır.

SSVEP tabanlı BMA çalışmalarında, uyaran frekansı ve harmoniklerine ait tepeler frekans domeninde arandığından öncelikle bu dönüşüm yapılır.

Belirli bir kanaldan alınan L uzunluğundaki bir EEG verisi için ilgili EEG segmentlerine, ayrık zamanlı Fourier dönüşümü (DFT) aşağıdaki şekilde uygulanabilir (3.2).

$$X(k) = \sum_{n=0}^{L-1} \mathrm{x(n)e^{-j2\pi nk/L}} \qquad k = 0,1,\ldots,L-1 \tag{3.2}$$

Daha sonra birer EEG veri örneği olmak üzere $X(k)'$ için PSD aşağıdaki şekilde uygulanabilir (3.3).

$$P(k) = |X(k)|^2 \qquad k = 0,1,\ldots,N-1 \tag{3.3}$$

Kullanılacak öznitelikler belirlendikten sonra, sınıflandırma algoritmaları değerlendirilir.

3.3 Sınıflandırma

Mevcut verilerde tercih edilen paradigma doğrultusunda işlemler gerçekleştirildikten sonra son aşamada sınıflandırma algoritmaları uygulanır. Örneğin P300 tabanlı BMA tasarımında zaman domeninde P300 işareti aranır ve seçilen EEG kanallarına ait veriler üzerinde P300 işareti içeren ve içermeyen kayıt parçalarından oluşan iki sınıf olmak üzere sınıflandırma işlemi gerçekleştirilir. Buradaki çıktı BMA sisteminde elde edilen karar olarak değerlendirilir. Sınıflandırıcının zaman domenindeki başarı düzeyi BMA sisteminin performans düzeyini belirlemektedir.

3.3.1 Naive Bayes

Naive Bayes sınıflandırıcı, bir örnek kümesi içinde örneğin bir sınıfa ait olmasının koşullu olasılıklarını değerlendiren istatistiksel bir sınıflandırma yöntemidir. X, sınıfı bilinmeyen bir örnek olmak üzere ve $X = \{x_1, x_2 \ldots x_n\}$ nitelik değerlerinden oluşmak üzere, örnek sınıfta m sınıf değeri olduğunu varsayalım. $C_1 \ldots C_n$ sınıf değerleri olmak

üzere; sınıfı belirlenecek bir örnek için, öncelikle (3.4)' teki gibi olasılık değerleri hesaplanır.

$$P(C_i|x) = \frac{P(X|C_i)P(C_i)}{P(x)} \tag{3.4}$$

Burada işlemi basitleştirmek için x değerleri birbirinden bağımsız kabul edilerek (3.5)' teki bağıntı kurulabilir.

$$P(X|C_i) = \prod_{k=1}^{n} P(Xk|C_i) \tag{3.5}$$

Sınıfı bilinmeyen bir X örneğini sınıflandırmak için (3. 4) de $P(C_i \mid X)$ içinde yer alan payda değerleri eşit olduğu için, pay değeri büyük olan seçilerek bilinmeyen örneğin bu sınıfa ait olduğu ifade edilebilir.

$$arg\ max_{c_i} = \{P(X|C_i)P(C_i)\} \tag{3.6}$$

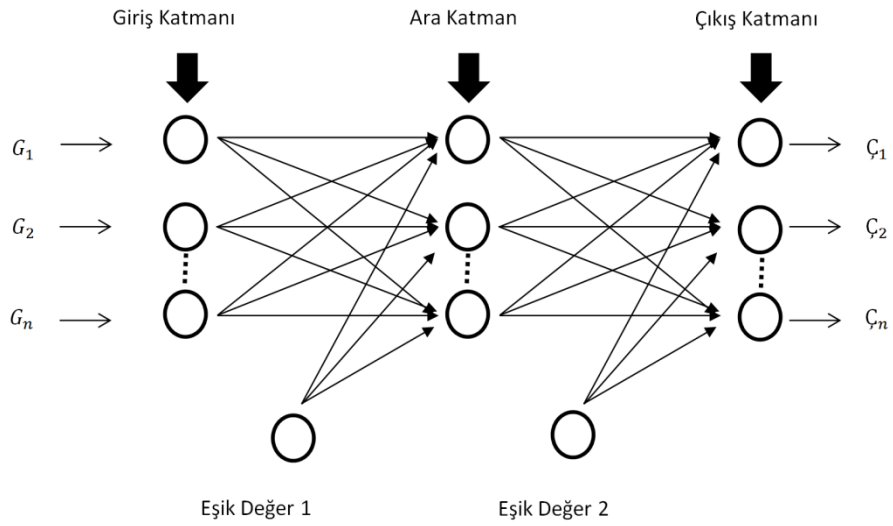
Bu ifade (3.6), en büyük sonrasal sınıflandırma yöntemi olarak ta bilinir.

$$C\ =\ arg\ max \prod_{k=1}^{n} P(Xk|C_i) \tag{3.7}$$

Bu durumda (3.5)' ten dolayı yukarıdaki bağıntı (3.7) kullanılabilir [48].

3.3.2 Çok Katmanlı Algılayıcı (ÇKA)

Yapay sinir ağları, insan beyninin öğrenme ve çıkarımda bulunma özelliklerinin model alındığı, aynı amacı belirli konular çerçevesinde gerçekleştirmek üzere tasarlanan yazılımsal modellerdir. ÇKA' da bu amacı gerçekleştirmek üzere nöronlar birden fazla katmanda organize olmuştur. Oluşturulan topolojiye bağlı olarak nöronlar birbirine bağlıdır. ÇKA' nın matematiksel anlamda, öğrenmesi her bir nöronla temsil edilen ağırlığın güncellenmesidir. ÇKA eğiticili bir öğrenme yöntemidir. Her bir iterasyonda örneğe ait öznitelik değerleri birer girdi olarak giriş katmanından iletilir. Çıkış katmanında beklenen sınıf bilgisi oluşana kadar, kullanılan ÇKA algoritmasına bağlı olarak ağırlık değerleri güncellenir. ÇKA' da giriş katmanı, ara katmanlar ve çıkış katmanı olmak üzere en az üç katman mevcuttur.



Şekil 3. 3 Temel ÇKA modeli

Ara katman sayısı ve bağlantılar ağın topolojisini belirler. Genel bir ÇKA ağ yapısı Şekil 3.6' da verilmiştir.

Giriş katmanında bilgi işleme olmaz. Buradaki veriler işlenmek üzere daha sonraki katmanın tüm işlem elemanlarına gönderilir.

Yapay sinir ağına bağlı her bir sinir hücresi 5 adet bileşenden oluşur. Bu bileşenler sırasıyla; girdiler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıktı bilgisidir.

Girdiler: Sinir hücresine dış dünyadan gelen bilgilerdir.

Ağırlıklar: Ağırlık sinir hücresine dışarıdan gelen bilginin önem düzeyini belirleyen değerdir ve öğrenme esnasında bu değerler doğru sınıf bilgisini üretene kadar güncellenir.

Toplama fonksiyonu: Burada sinir hücresine gelen net girdi hesaplanır. En çok kullanılanı, girdilerin ağırlıklarıyla çarpılarak tek bir sinir hücresi için toplamının hesaplanmasıdır.

$$\mathrm{NET} = \sum_{i}^{n} G_i \, A_i \qquad (3.8)$$

Aktivasyon fonksiyonu: Bu aşamada ilgili hücreye gelen net girdi işlenerek ne şekilde bir çıktı üretileceği belirlenir. ÇKA' da en çok kullanılan aktivasyon fonksiyonu, sigmoid fonksiyonudur.

$$F(NET) = \frac{1}{1 + e^{-NET}} \tag{3.9}$$

Çıktı: Aktivasyon fonksiyonu tarafından belirlenen çıktı değeridir. Burada iletilen sonuç dış dünyaya ya da bir topoloji üzerinde farklı hücrelere iletilir.

Bir ÇKA ağı aşağıdaki parametrelere göre karakterize edilir.

- Ağ topolojisi
- Kullanılan toplama fonksiyonu
- Kullanılan aktivasyon fonksiyonu
- Öğrenme stratejisi
- Öğrenme kuralı

ÇKA ağının öğrenme kuralı Delta öğrenme kuralının genelleştirilmiş halidir. Bu kural en küçük kareler yöntemine dayalıdır.

Delta kuralı iki safhadan oluşur.

1. İleri doğru hesaplama: Bu aşamada ağ çıktısı hesaplanır
2. Geriye doğru hesaplama: Bu aşamada ağırlıklar güncellenir

İleri doğru hesaplama yapılırken girdi katmanında katmanında işlem yapılmayacağı için herbir işlem elemanınının çıktısı aşağıdaki gibi belirlenir.

$$Ç_k^i = G_k \tag{3.10}$$

Ara katmandaki her bir sinir hücresi için; ağırlıklar (A1, A2, …) olmak üzere net girdi;

$$NET_j^a = \sum_{k=1}^{n} A_{kj}\, Ç_k^i \tag{3.11}$$

şeklinde hesaplanır.

Sigmoid fonksiyonu kullanıldığında çıktı;

$$Ç_j^a = \frac{1}{1 + e^{-NET_j^a - \beta_j^a}} \quad (3.12)$$

şeklinde ifade edilebilir.

Burada β eşik değeridir ve bu değer 1' dir. Eşik değer eğitim esnasında değişmez.

Geriye doğru hesaplama esnasında ise, beklenen çıktılar $(B1,\ B2, \dots)$ olmak üzere; çıktılar bu değerlerle karşılaştırılır. Çıktı ve beklenen değer hata kabul edilir. Bu hata değerini azaltmak için; bu hata, herbir iterasyonda ÇKA' nın ağırlık değerlerine dağıtılarak ağ yapısı güncellenir. Çıktı katmanın n. Sinir hücresi için hata E_n olmak üzere;

$$E_n = B_n - Ç_n \quad (3.13)$$

şeklinde ifade edilebilir.

Bir sinir hücresine ait toplam hata şu formülle bulunur;

$$\mathrm{TH} = \frac{1}{2}\sum_m E_m^2 \quad (3.14)$$

Toplam hatanın minimize edilmesi için bu hata kendisine sebep olan sinir hücrelerine dağıtılır.

Ara katman ve çıktı katmanı arasındaki ağırlıkları değiştirmek için; ara katmandaki j. sinir hücresini çıktı katmanındaki m. Sinir hücresine bağlayan bağlantının ağırlık değişim miktarı ΔA^a t. İterasyondaki bir ağrlığın değişim düzeyi aşağıdaki gibi hesaplanır;

$$\Delta A_{jm}^a(t) = \lambda \delta_m Ç_j^a + \alpha \Delta A_{jm}^a(t-1) \quad (3.15)$$

Burada λ öğrenme katsayısını ifade eder. Bununla birlikte ağırlık değişimi esnasında değişimim yerel bir optimum noktaya takılmaması için, değişimin belirli bir oranda sonraki iterasyonda eklenebilmesi sağlanır. Bu değişime momentum denir. Momemtum katsayısı α ile ifade edilir.

Formüldeki δ_m ise m. no' lu çıktı sinir hücresinin hatasını ifade eder ve şu şekilde hesaplanır;

$$\delta_m = \text{ƒ}'(NET).E_m \quad (3.16)$$

$\text{ƒ}'(NET)$ burada aktivasyon fonksiyonunun türevidir. Sigmoid fonksiyonu kullanılması durumunda;

$$\delta_m = \text{Ç}_m(1 - \text{Ç}_m).E_m \quad (3.17)$$

şeklinde hesaplanır.

Değişim düzeyi hesaplandıktan sonra ağırlıklar t. iterasyonda şu şekilde hesaplanır;

$$A_{jm}^a = A_{jm}^a(t-1) + \Delta A_{jm}^a(t) \quad (3.18)$$

Eşik değerin ise t. İterasyondaki ağırlık değeri;

$$\beta_m^{\text{ç}}(t) = \beta_m^{\text{ç}}(t-1) + \Delta\beta_m^{\text{ç}}(t) \quad (3.19)$$

şeklinde hesaplanır.

Giriş katmanı ve ara katmanlar arasındaki değişim, ΔA^i ile gösterilmek üzere değişim miktarı;

$$\Delta A_{kj}^i(t) = \lambda\delta_j^a \text{Ç}_k^i + \alpha\Delta A_{kj}^i(t-1) \quad (3.20)$$

olacaktır.

Burada hata δ^a olmak üzere; şu şekilde hesaplanır;

$$\delta_j^a = \text{ƒ}'(NET)\sum_m \delta_j \ A_j^m \quad (3.21)$$

Eğer aktivasyon fonksiyonu olarak sigmoid kullanılırsa hata değeri şu şekilde olur;

$$\delta_j^a = \text{Ç}_j^a\left(1 - \text{Ç}_j^a\right).\sum_m \delta_m A_{jm}^a \quad (3.22)$$

Değişim miktarı bu formüle göre hesaplandıktan sonra, ağırlıklar aşağıdaki şekilde hesaplanır;

$$A_{kj}^i(t) = A_{kj}^i(t-1) + \Delta A_{kj}^i(t) \quad (3.23)$$

Ara katman eşik değerleri β^a ile gösterilirse seğişim miktarı aşağıdaki gibi hesaplanır;

$$\Delta\beta_j^a(t) = \lambda\delta_j^a + \alpha\Delta\beta_j^a(t-1) \quad (3.24)$$

t. iterasyonda ağırlık değerleri aşağıdaki gibi hesaplanır;

$$\beta_j^a(t) = \beta_j^a(t-1) + \Delta\beta_j^a(t) \quad (3.25)$$

Sırasıyla ileri ve geriye doğru tüm iterasyonlar, beklenen değerler oluşana kadar tamamlanır [49].

3.3.3 Destek Vektör Makineleri (DVM)

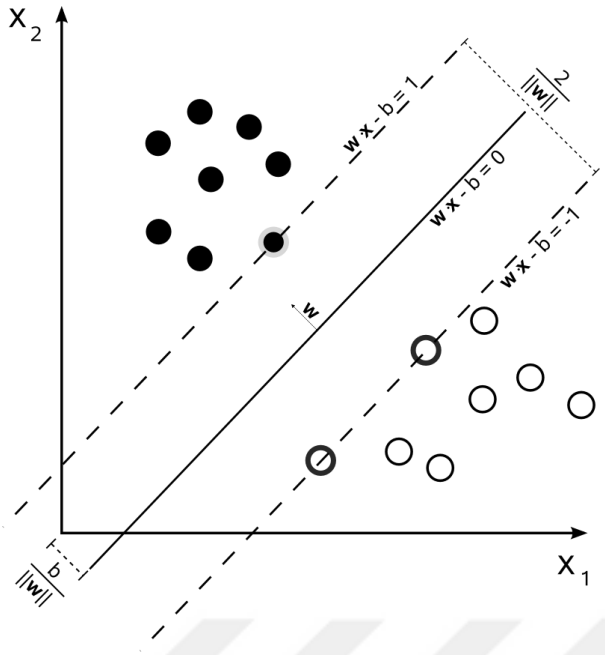
Destek Vektör Makinaları sıklıkla kullanılan eğiticisiz öğrenme yöntemlerindendir. Bu algoritmada amaç, sınıflara ait destek vektörlerinin arasını maksimize ederek, iki sınıfı en optimal düzeyde ayıracak hiper düzlemi elde etmektir. DVM' de iki ya da çok sınıflı problemler çözülebilir. DVM' ler doğrusal ve doğrusal olmayan olmak üzere ikiye ayrılmaktadır.

Doğrusal ayrılabilen n adetten oluşan bir veri kümesi için $\{x_i, y_i\}\ i = 1, \dots, n$ kabul edildiğinde optimum hiper düzlem eşitsizlikleri aşağıdaki gibidir;

$$w \cdot x_i + b \geq +1 \qquad \forall\, y = +1 \text{ için,} \quad (3.26)$$

$$w \cdot x_i + b \leq +1 \qquad \forall\, y = -1 \text{ için,}$$

$x \in R^N$ olmak üzere N boyutlu bir uzayı, $y \in \{-1, +1\}$ sınıf bilgisini, w ağırlık vektörünü ve b eğilim değerini ifade eder. Optimum hiper düzlemin belirlenmesi için, öncelikle düzleme paralel ve sınırlarını oluşturacak iki hiper düzlem belirlenmelidir. Bu noktalar destek vektörleri şeklinde isimlendirilir ve düzlemler $w \cdot x_i + b = \pm 1$ şeklinde ifade edilirler.



Şekil 3. 4 iki sınıflı veri kümesi için hiper düzlemler ve sınırlar üzerindeki destek vektörleri [50]

Optimum hiper düzlemin maksimize edilebilmesi için $||w||$ ifadesinin minimize edilmesi gerekmektedir. Bunun için aşağıdaki sınırlı optimizasyon problemi çözümlenmelidir.

$$min\left[\frac{1}{2}||w||^2\right] \tag{3.27}$$

Buradaki sınırlamalar ise;

$$y_i(w \cdot x_i + b) - 1 \geq 0 \text{ ve } y_i \in \{-1, +1\} \tag{3.28}$$

şeklinde ifade edilmektedir. Bu problem Lagrange denklemleri kullanılarak çözülebilir. İşlem sonrasında;

$$L(w, b, \alpha) = \frac{1}{2}\left||w|\right|^2 \sum_{i=1}^{k} \alpha_i y_i (w \cdot x_i + b) + \sum_{i=1}^{k} \alpha_i \tag{3.29}$$

eşitliğine ulaşılır. Doğrusal bir iki sınıflı problem için karar fonksiyonu aşağıdaki gibidir;

$$f(x) = sign\left[\sum_{i=1}^{k} \lambda_i y_i (x \cdot x_i) + b\right] \tag{3.30}$$

Doğrusal olmayan sınıflandırma problemlerinde ise; optimum hiper düzlemin ters tarafında kalan örnekler için bir yapay değişken (ξ_i) ile çözülür. Sınırın maksimize edilip, hataların minimize edilmesi arasındaki denge, pozitif değer alan bir c düzenleme parametresi ($0 < C < \infty$) ile kontrol edilir. Düzenleme parametresi ve yapay değişken ile doğrusal olarak ayrılamayan veri kümeleri için optimizasyon problemi aşağıdaki şekilde (3.28) ifade edilebilir.

$$min\left[\frac{||2w||^2}{2} + c \cdot \sum_{i=1}^{r} \xi_i\right] \tag{3.31}$$

İlgili sınırlamalar ise; aşağıdaki gibi (3.29) ifade edilebilir;

$$Y_i(w \cdot \varphi(X_i) + b) \text{ -1 } \geq 1 \text{ - } \xi_i \tag{3.32}$$

$$\xi_i \geq 0 \text{ ve i} = 1, \ldots, \text{N}$$

Doğrusal olarak ayrılamayan sınıflar $K(X_i, X_j) = \varphi(X) \cdot \varphi(X_j)$ şeklindeki kernel fonksiyonuyla dönüştürülerek daha yüksek bir boyutta doğrusal bir şekilde ayrılması sağlanır [51].

BÖLÜM 4

BMA SİSTEM YÖNTEMLERİ

EEG tabanlı BMA sistemlerinin geliştirilmesinde beynin belirli davranış karakteristiklerinden faydalanılmaktadır. Zaman ve frekans domeninde izlenilen bu karakteristiklerden belirli öznitelik vektörleri elde edilmektedir. Bu öznitelik vektörlerinden kullanıldığı en temel BMA yöntemleri aşağıda anlatılmıştır.

4.1 Motor İmgeleme

Motor İmgeleme (Motor Imagery) tabanlı BMA çalışmalarında, insan beyninde birincil sensorimotor korteks bölgesindeki elektriksel salınımlardan faydalanılır. Sensorimotor korteks bölümünde 8 Hz - 12 Hz arasındaki salınımlar Mu ritmi ifadesiyle adlandırılır. Sensorimotor bölgesindeki aktivite boyunca ilgili frekans bandlarının gücünde düşüş ve yükselişler olmaktadır. Bu düşüşler ERS (Event Related Syncronization) ve yükselişler ise ERD (Event Related Desyncronization) olarak ifade edilir [52]. Aynı aktivite herhangi bir harekette bulunulmadığında sadece zihinsel hazırlık süresince de görülmektedir [53]. Diğer yöntemlere göre daha fazla eğitim süreci gerektirmesi dezavantajıdır.

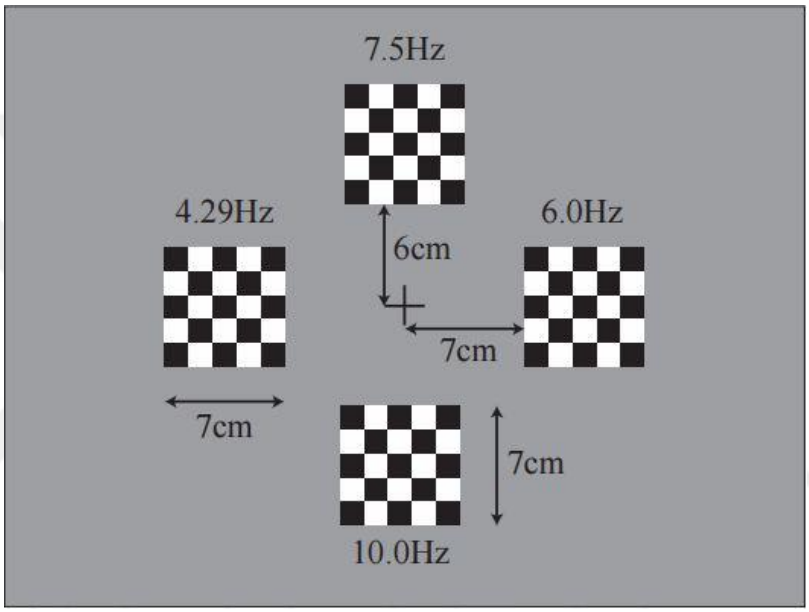
4.2 SSVEP

SSVEP ve P300 tabanlı BMA çalışmaları, görsel uyarılmış potansiyeller çerçevesinde değerlendirilen iki farklı yöntemdir.

SSVEP, belirli bir frekansta tekrarlanan bir ışık kaynağına bakıldığında, yoğunlukla görsel kortekste ortaya çıkan rezonans fenomenidir [54]. Kişi 1 Hz ve 100 Hz arasında tekrarlayan bir görsel uyarana baktığında oluşan bu tepki, frekans domeninde uyaran ve onun harmoniklerinde tepe noktası olarak elde edilebilir [55].

SSVEP BMA amaçlı kullanılmak istediğinde, deneğe değişmeyen bir frekansta tekrarlayan uyaranlar gösterilir.

Ekran üzerinde, örneğin farklı yönleri işaret eden ve farklı frekansta değişen uyaranlar oluşturulur. Denek niyeti doğrultusunda herhangi bir uyaranı seçer. Bu aşamada EEG sinyallerine Fourier dönüşümü uygulanarak deneğin niyetinin ne yönde olduğu ve hangi uyarana baktığı belirlenebilir. SSVEP, insan beyninin doğal davranışı olması ve uzun eğitimler gerektirmemesi SSVEP yönteminin en büyük avantajıdır. Örnek bir SSVEP uyaran ekranı tasarımı Şekil 4. 1' de görülmektedir.



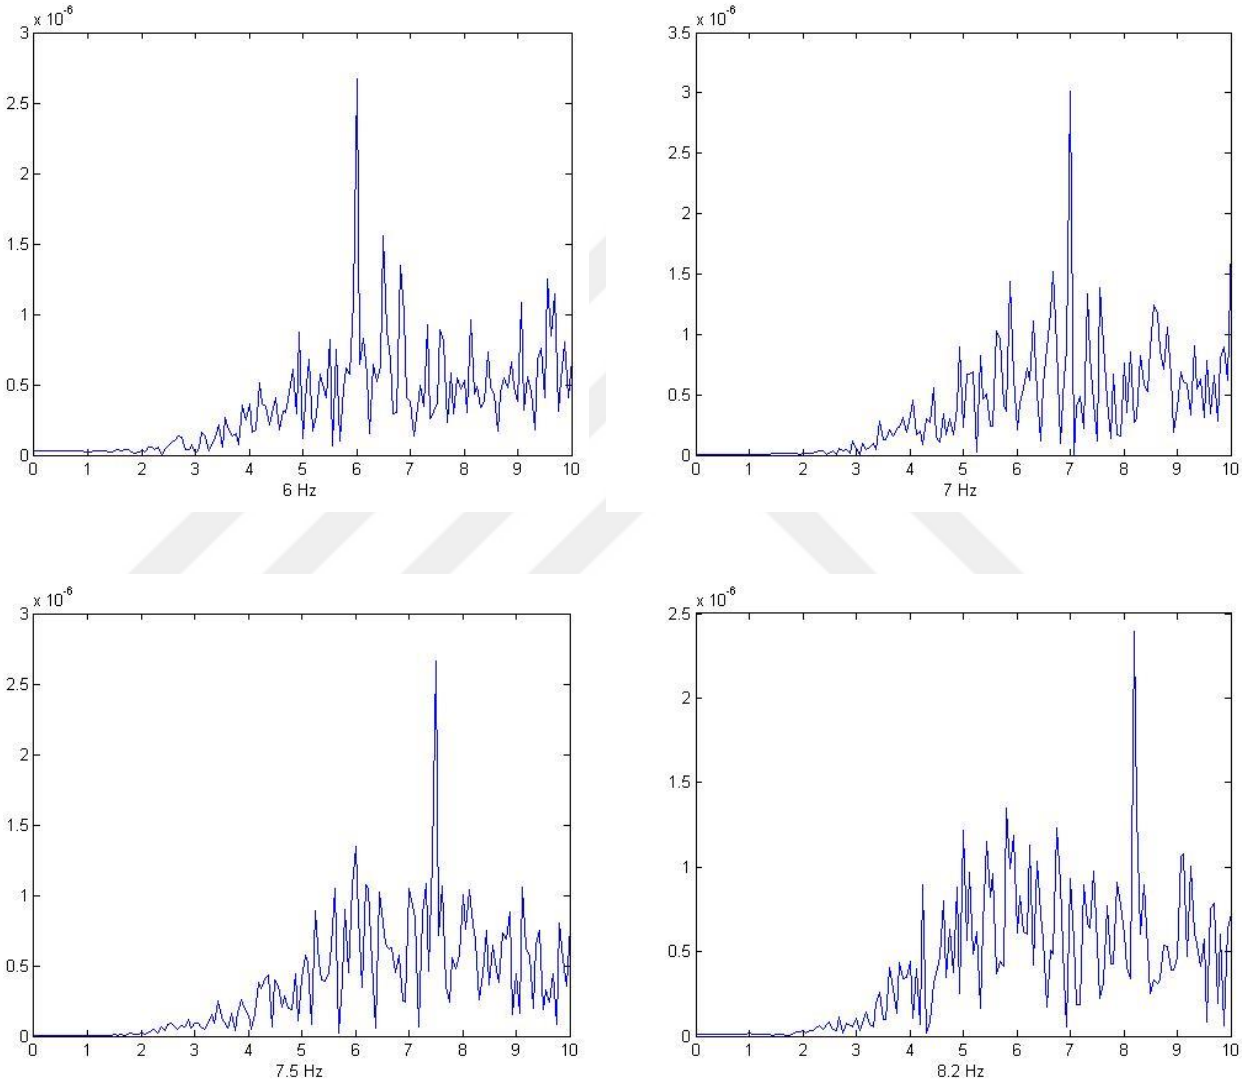
Şekil 4. 1 Dört sınıflı sınıflandırma problemi için SSVEP ekran tasarımı [56]

Ayrıca uyarılmış potansiyellerde zamanlama kritik öneme sahiptir [57]. Klasik işletim sistemi uygulamalarında iş parçacıkları belirli bir kuyruk sürecine girmekte, öncelik işletim sistemi tarafından belirlenmektedir. Uygulamanın işletim sistemi bünyesinde haberleştiği ara katman servisleri ve monitör yenileme hızı gibi sebepler çalışmanın başarısını sınırlamaktadır. Ayrıca maksimum noktaları, yenileme ilgili uyaranın frekansı ve harmoniklerinde de görüldüğü için uyaranlar için belirlenen frekanslar harmoniklerde kesişmeyecek şekilde ayarlanmalıdır.

Örnek olarak sol yönü işaret eden uyaran 5 Hz, sağ yönü işaret eden uyaran 10 Hz olduğunda sol yönü işaret eden uyarın ikinci harmonikte sağ yönü işaret eden uyaran

ile kesişecektir. Monitör yenileme hız düştükçe uyaran frekanslarını ayırmak güçleşecektir.

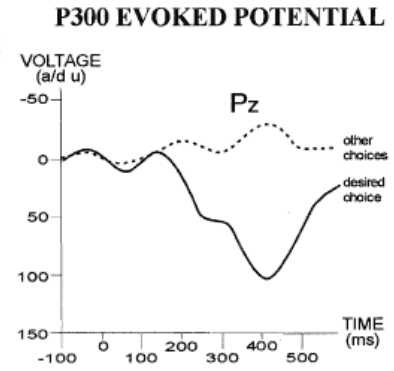
Oz konumundaki elektrottan, farklı frekanslardaki uyaranlara ait veriler kaydedilmiştir. Aşağıda Fourier dönüşümü uygulandıktan sonra frekans domeninde, genlik üzerindeki tepe noktalar görünmektedir. Farklı frekanslara ait örnek tepeler Şekil 4. 2' de görülmektedir (AVI SSVEP Dataset) [58].



Şekil 4. 2 Frekans domeninde 6Hz - 8.2 Hz arası SSVEP uyaran frekansına bağlı Tepeler [58]

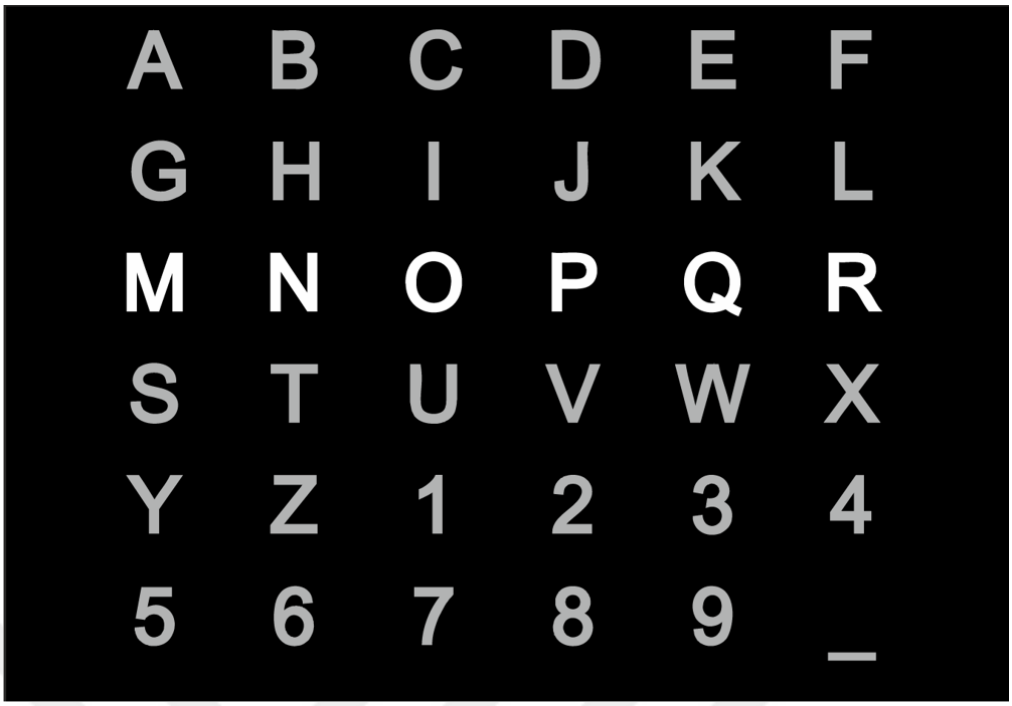
4.3 P300

P300 tabanlı BMA yöntemi ya da P300 heceleme sistemi Farewell ve Donchin tarafından 1988 yılında geliştirilmiştir. Farewell ve Donchin bu çalışmada uyaranlar arası zaman aralıkları ve farklı sınıflandırıcıları değerlendirmiştir. Çalışmada Peak Picking, SWDA, Area ve Covariance algoritmalarının arasında SWDA ve Peak picking algoritmalarının en verimli algoritmalar olduğunu onaylamıştır. SWDA ve Covariance algoritmalarının zaman konusunda hassaslığı, zayıf noktalar olarak değerlendirilmiştir. Uyaranlar arası zaman aralığı arttıkça beklenen uyaran ve beklenmeyen uyarana ait ayrılabilirlik artmıştır [16]. Bu yöntemde, yine uyarılmış potansiyellerden faydalanılmaktadır. P300 tabanlı sistemleri uygulanabilir kılan oddball paradigmasıdır. Bu sistemde rastgele ve sıklıkla uygulanan uyaranlar arasında beklenen ve az sayıda görüntülenen uyarana karşı çeper (parietal), arka kafa (occipital) lob ve çevresine ait EEG sinyallerinde yaklaşık 300 ms sonra oluşan belirgin bir genlik değişimidir. Genlik yönü ters çevrilmiş olmak üzere; örnek bir P300 işareti Şekil 4. 3' te gösterilmiştir.



Şekil 4. 3 Uyarandan sonra 300ms - 500ms arasında oluşan P300 bileşeni [59]

Bu değişiklik P300 işareti ya da Oddball paradigması kavramlarıyla ifade edilmektedir. Donchin bu değişikliklerden faydalanarak P300 heceleme uygulamasını geliştirmiştir. Bu uygulamada harf ve rakamları içeren 6 x 6 matris görünümü kullanılır. Bu karakterler dikey ve yatay olmak üzere rastgele ve belirli sayılarda ve belirli milisaniye düzeyinde yanıp sönerler. Örnek P300 heceleyici ekran görüntüsü Şekil 4. 4' te gösterilmiştir.



Şekil 4. 4 Orijinal P300 heceleme ekranı

Öncelikle kişiye ait EEG karakteristiği, sinyal genliği, zamansal konumu ilgili elektrot konumu gibi bilgiler belirlenip sınıflandırma için gerekli parametreler kaydedilir ve çevrimiçi simulasyon sürecinde girilen parametreler heceleme sisteminde kullanılır. Basitçe anlatmak gerekirse; EEG davranışının belirlenmesi için veri, uyaran referans alınmak üzere segmentlere ayrılır. Yatay ve dikey -6x6 matris için- on iki uyaran bir seti oluşturur. Bu set içinde ilgili ardışıl segmentlerin hangilerinde ilgili P300 işareti bulunursa, bu iki uyaranın işaret ettiği kesişim noktası belirlenen karakteri verir. Örneğin Şekil 4. 5' te, işaretli 8 numaralı uyaran 8. numaralı kolonu ve 6. numaralı uyaran 6 numaralı satırı ifade etmektedir. Denek B harfini yazdırmak istediğinde; bir set içinde, 8. ve 6. numaralı uyaranlardan yaklaşık 300 ms sonra P300 deseninin görünmesi bize B harfini verecektir.

	7	8	9	10	11	12
6	A	B	C	D	E	F
5	G	H	I	J	K	L
4	M	N	O	P	Q	R
3	S	T	U	V	W	X
2	Y	Z	1	2	3	4
1	5	6	7	8	9	_

Şekil 4. 5 Uygulamada istenen harfin belirlenmesi

Ayrıca sistemin kalibre edilmesi için; segmentlere ayrılmış veriye farklı filtre, özellik ve sınıflandırma algoritmaları uygulanmaktadır.

BÖLÜM 5

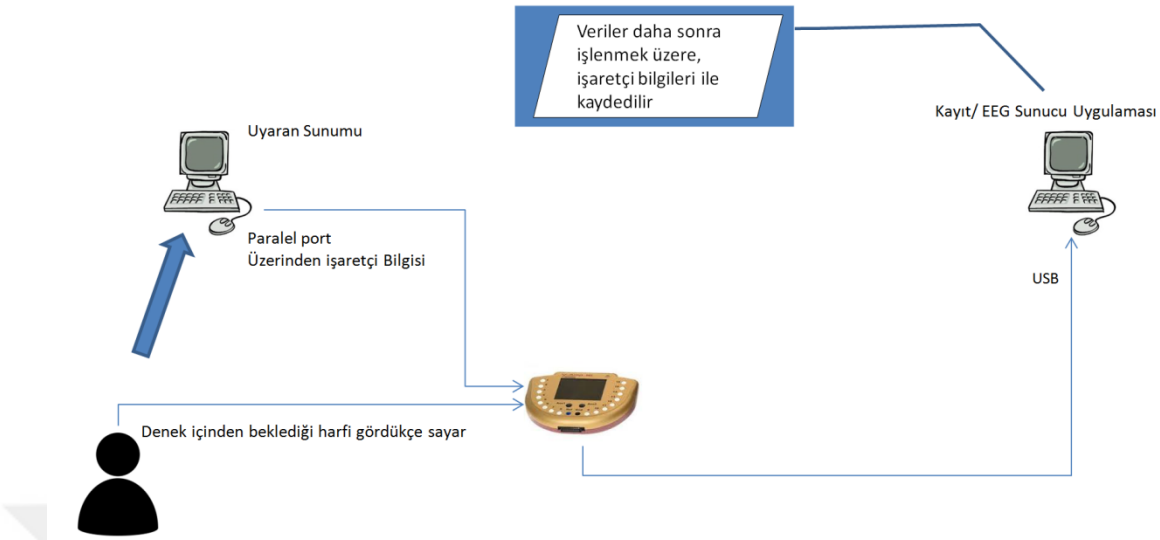
BMA HECELEME SİSTEMİ TASARIMI VE P300 VERİLERİNİN ELDE EDİLMESİ

Bu çalışmada BMA geliştirme sürecinin ilk aşaması olan çevrimdışı analiz kısmı gerçekleştirilmiştir. Bu amaçla öncelikli olarak daha sonraki çalışmalar da düşünülerek bir adet P300 heceleyici uygulaması geliştirildi. Bir adet uyaran bilgisayarı, bir adet kayıt bilgisayarı, bir de EEG kayıt cihazının kullanıldığı bir topoloji tasarlandı. Bu şekilde on adet denekten EEG verileri toplandı. Daha sonra verileri analiz etmek ve sınıflandırmaya hazır veri vektörleri oluşturmak amacıyla Matlab uygulamaları yazıldı. Daha sonra elde edilen vektörler, WEKA uygulaması kullanılarak farklı algoritmalar ile sınıflandırıldı.

Mevcut çalışmanın nihayetinde çevrimiçi bir sistemin geliştirilmesi planlandı. Fakat tez çalışması, çevrimiçi uygulamanın ilk aşaması olan çevrimdışı analiz kısmını kapsamaktadır. Çevrimdışı analiz aşamasında mevcut sonuçlar çevrimiçi geliştirme için değerlendirilebilecek belirli bir başarı düzeyini sağlamıştır.

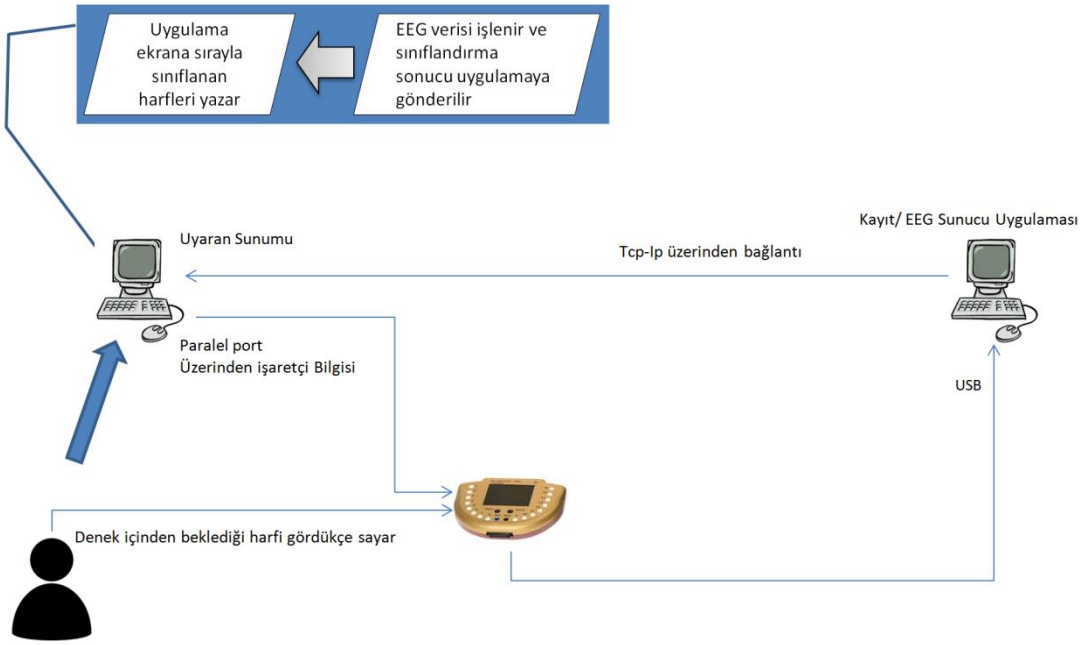
Çevrimdışı analiz ve çevrimiçi uygulama aşamalarında iki farklı topolojiye ihtiyaç duyulmaktadır. Detaylı bilgiler ilerleyen bölümlerde aktarılmıştır.

Çevrimdışı analiz aşamasında kullanılan topoloji Şekil 5. 1' deki gibidir.



Şekil 5. 1 Çevrimdışı kayıt topolojisi

Daha sonraki çalışmalar için planlanan çevrimiçi topoloji ise Şekil 5. 2 ' deki gibidir.



Şekil 5. 2 Planlanan çevrimiçi BMA tasarımı

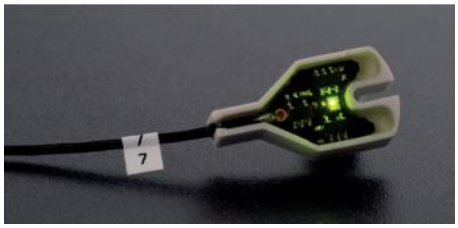
Planlanan tasarımdaki bileşenler sırasıyla aşağıdaki gibidir:

1. EEG kayıt cihazı ve çevre birimleri
2. Uyaran sunumu
3. Uyaran ve EEG veri senkronizasyonu
4. EEG kayıt yazılımı
5. EEG yayın sunucusu
6. Veri işleme birimi

İlerleyen bölümlerde tasarlanan birimler daha detaylı anlatılmıştır.

5.1 EEG Kayıt Cihazı ve Çevre Birimleri

EEG kaydı amacıyla 16 adet adet Ag/AgCl aktif elektrot (Şekil 5. 3), bir adet Brain Products marka V-Amp 16 kanallı EEG kayıt cihazı (Şekil 5. 4), 2 farklı boy uluslararası 10- 20 standardı dizilimine izin veren Easy Cap kep (Şekil 5. 5), empedansı düşürmek için Easy Cap jel, 1 adet masaüstü uyaran bilgisayarı ve bir adet te dizüstü EEG kayıt bilgisayarı kullanıldı.



Şekil 5. 3 ActiCap aktif elektrotlar [60]



Şekil 5. 4 V-Amp 16+2 kanal amplifier [61]

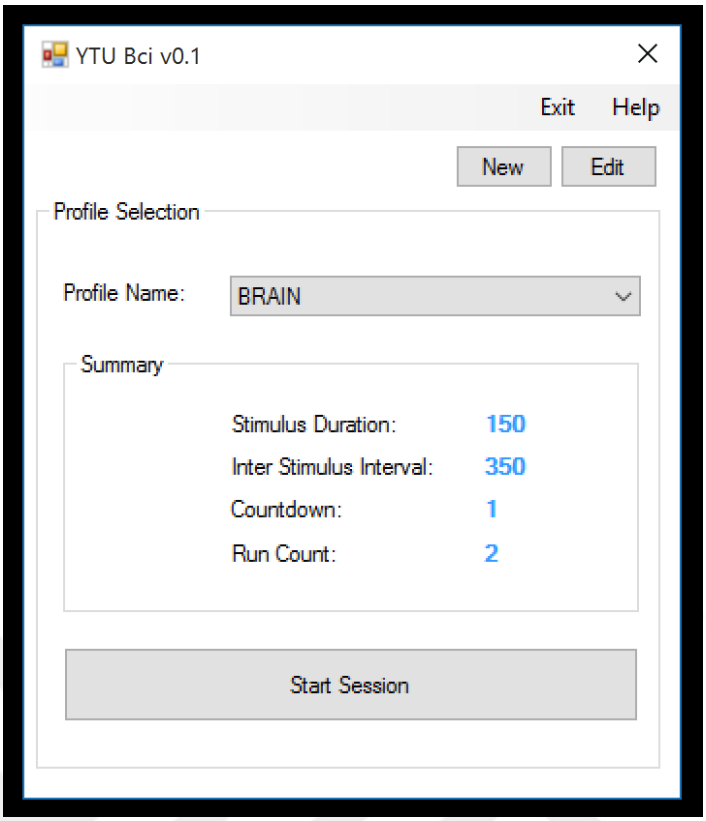


Şekil 5. 5 Easy Cap Uluslararası 10 -20 sistemine uygun kep [62]

Uyaran bilgisayarı, uyarana ait işaret bilgilerini paralel porttan EEG cihazına iletirken, kayıt bilgisayarı ise bu bilgileri EEG cihazından USB port vasıtayla almaktadır.

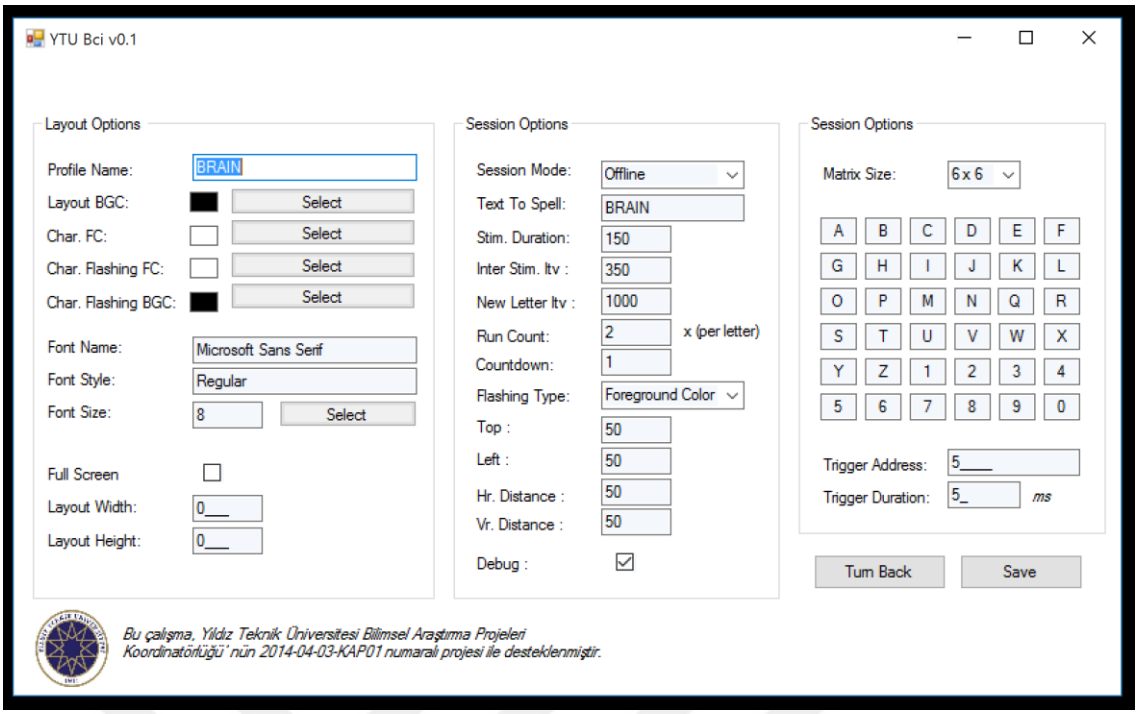
5.2 Uyaran Sunumu

SSVEP ve P300 tabanlı BMA çalışmalarının temel bileşeni uyaran sunumudur. P300 tabanlı BMA çalışmalarında uygulama denekten doğru şekilde bilgi çıkarımında bulunmak amacıyla rastgele ve belirli periyotlarla uyaran sunumu yapılır ve deneğin tercih ettiği uyaran ve diğer uyaranlar arasındaki desen farkı incelenir. Bu amaçla öncelikli olarak daha sonraki çalışmalarda da kullanılabilecek ve farklı ihtiyaçlar doğrultusunda özelleştirilebilecek özellikteki "YTU BCI" isimli P300 heceleyici uygulaması yazıldı. Bu uygulamada hızlı geliştime imkânı sebebiyle .Net platformu ve C# dili tercih edildi. Yazılan uygulama Windows işletim sistemlerinde .Net framework 4.0 ile başarılı bir şekilde çalışmaktadır.



Şekil 5. 6 Uygulama giriş ekranı

Uygulama farklı simulasyonlar için farklı uyaran, matriks, zaman aralığı gibi temel parametrelerin değiştirilerek her bir simulayon modelinin farklı bir profilde kaydedilmesine ve daha sonra kolaylıkla kullanılabilmesine imkân sağlamaktadır. Uygulama bu profillerin kaydedilmesi amacıyla bir de profil özelleştirme ekranına sahiptir.



Şekil 5. 7 Uygulama yapılandırma ekranı

Uygulama çevrimiçi ve çevrimdışı çalışmaya uygun tasarlanmıştır. Ayrıca uyaran durumlarının takibi için debug mode özelliğine sahiptir. Uygulamada oturum için özelleştirilebilen parametreler ve açıklamaları aşağıdaki gibidir;

Ekran düzeni seçenekleri:

- *Profile Name: Seçilen deney profiline verilen isim*
- *Layout BGC: Seçilen deney profilinde P300 uygulaması arkaplan rengi*
- *Char. FC: Karakterlerin uyaran aktfi hale gelmeden önceki renkleri*
- *Char. Flashing F.C: Karakterlerin uyaran aktif hale geldiğindeki renkleri*
- *Char. Flashing B.G.C : Karakterlerin uyaran aktif hale geldiğindeki arka plan renkleri.*
- *Font Name: Karaktere ait font ismi*
- *Font Size: Karakterlere ait font boyutu*
- *Font Style: Font temel nitellikleri (kalın, yatık, düz)*
- *Full Screen: Uygulama tam ekran ya da belirli bir ölçüde açılsın*

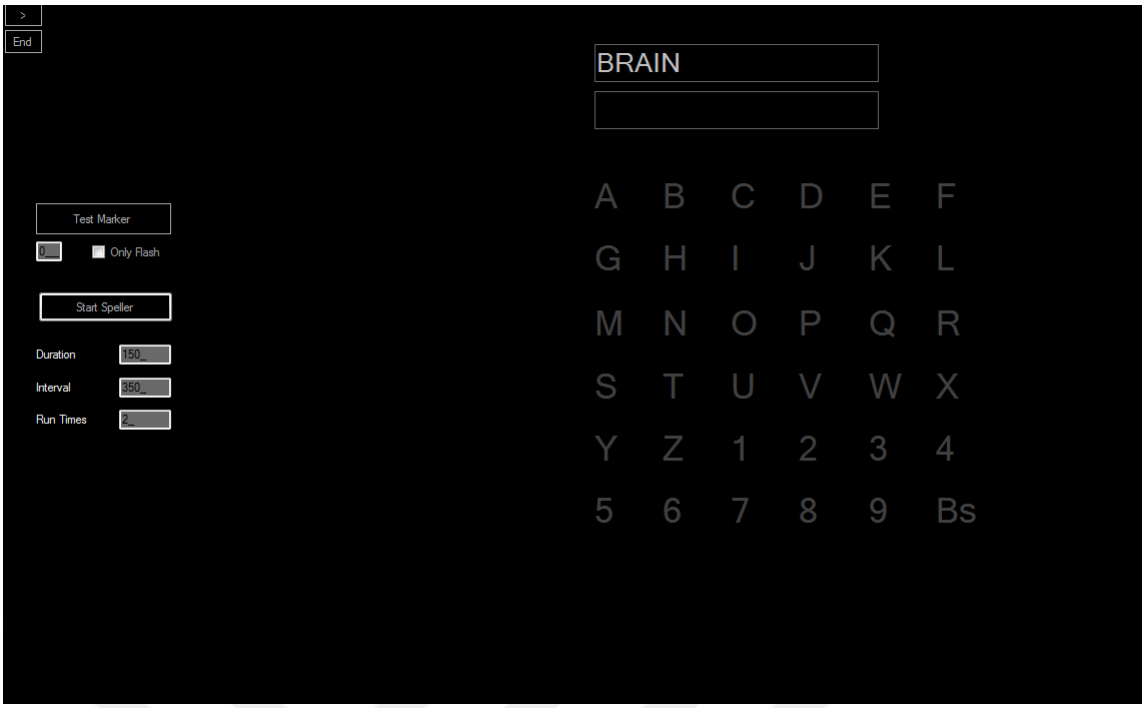
- *Layout Width: Uygulama ekran genişliği*
- *Layout Height: Uygulama ekran yüksekliği*

Oturum Seçenekleri:

- *Session mode: Oturum çevrimiçi/çevrimdışı*
- *Text to spell: Fokuslanılacak ifade*
- *Stim. Duration: Uyaran ekranda kalma süresi*
- *Inter Stim. Itv: İki uyaran arasındaki zaman boşuğu*
- *New letter Itv: Yeni bir harfe fokuslanmadan önceki zaman aralığı*
- *Run count: Bir harf için döngü sayısı*
- *Flashing type: Uyaran karakter ya da arka plan renk değişikliği*
- *Top: Karakter matriksinin üstten konumu (piksel)*
- *Left: Karakter matriksinin soldan konumu (piksel)*
- *Hr. Distance: Karakterler arası yatay mesafe (piksel)*
- *Vr. Distance: Karakterler arası dikey mesafe (piksel)*
- *Debug: Karakterlerin uyaran aktivite bilgileri görüntülenir*
- *Matrix size: Heceleyici matris boyutu*

  (Matris karakterleri değiştirilebilir)
- *Marker address: İşaretçi gönderilecek birimin donanımsal adresi (onluk)*
- *Marker duration: İşaretçi gönderilen birimde aktivite süresi*

Uygulamada test amacıyla P300 içeren ve P300 içermeyen sinyalleri tespit için bir adet profil belirlendi. Bu profilde, deneğin 10 setten oluşmak üzere tüm döngüler tamamlanana kadar 'A' harfi bulunan satır ve sütun olmak üzere uyaranların toplam adedinini içinden sayması istendi. Detay bilgileri ilerleyen bölümlerde anlatılmıştır.



Şekil 5. 8 P300 Heceleyici uygulama ekranı

5.3 Uyaran ve EEG Veri Senkronizasyonu

EEG sinyalleri ve uyaran arasındaki senkronizasyon, zaman periyodundaki verinin işlendiği BMA çalışmalarının anahtar adımlarından biridir. Bu aşamada belirli engellerle karşılaşılmaktadır. Yazılımsal senkronizasyon uygulamalarında, Windows işletim sistemlerinin gerçek zamanlı işletim sistemi olmaması, iş parçacıklarının kuyruğa girmesi, donanımlar arası gecikmeler gibi sebeplerle istenilen doğruluğu sağlayamamaktadır. Bu sebeple donanımsal doğrudan bağlantı senkronizasyon kalitesini artırmaktadır. Bu amaçla uygulama ve EEG cihazı arasında paralel port üzerinden bir arayüz tasarlanmıştır. Kullanılan uyaran sunum bilgisayarı üzerinde PCI express portu üzerine bir adet S-Link marka paralel port kartı bağlantısı yapıldı.



Şekil 5. 9 S-Link marka paralel port kartı [63]

Yazılan uyaran uygulamasının paralel port üzerinden EEG cihazı ile iletişim kurması için harici bir dll dosyası kullanıldı. Ayrıca çevrimdışı analiz için dosya üzerinde EEG bilgilerini kullanmak üzere bir protokol oluşturuldu.

Paralel port üzerinden 8 bit veri taşınmaktadır ve bunlar kayıt yazılımı (Brain Vision Recorder) için uyaran (Stimulus) ve cevap (Response) olmak üzere iki farklı şekilde kaydedilebilmektedir. Öncelikle bu amaçla her bir bit değeri, daha sonra analiz yazılımında kullanılmak üzere uyaran olmak üzere ayarlandı. Sonuç olarak her bir segment işareti onluk tabanda aktarılmakta ve her bir işareti ikilik tabana çevirdiğimizde segmente ait gerekli bilgilere ulaşabiliyoruz.

Belirlenen protokol Çizelge 5. 1 deki gibidir.

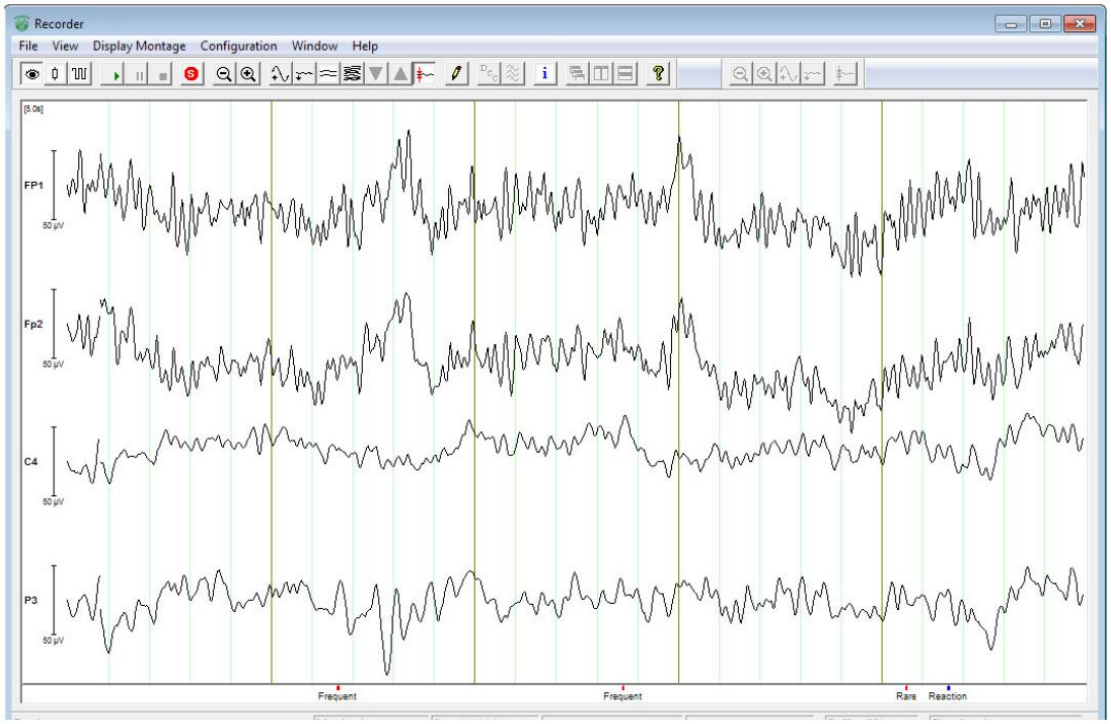
Çizelge 5. 1 EEG uyaran işaretlerinde bitlerin kullanım şekli

8	7	6	5	4	3	2	1
Kullanılmadı	Kullanılmadı	P300 işareti olmalı / olmamalı	Set başlangıç durumu	Uyaran indeksi			

Burada soldan ilk dört bit heceleyici matris' teki uyarana ait kimliği, beşinci bit yeni bir uyaran set' inin başlangıcını ve altıncı bit ise mevcut segmentin P300 işareti içerip içermemesi gerektiğini ifade etmektedir.

5.4 EEG Kayıt Yazılımı

EEG kayıt süresince V-Amp EEG cihazına ait kayıt yazılımı Brain Vision Recorder uygulamasını kullanıldı (Şekil 5.10). Uygulama yüksek-alçak geçiren filtre, noç filtresi, segmentasyon gibi seçeneklere izin vermektedir.



Şekil 5. 10 Brain Recorder uygulama ekran görüntüsü

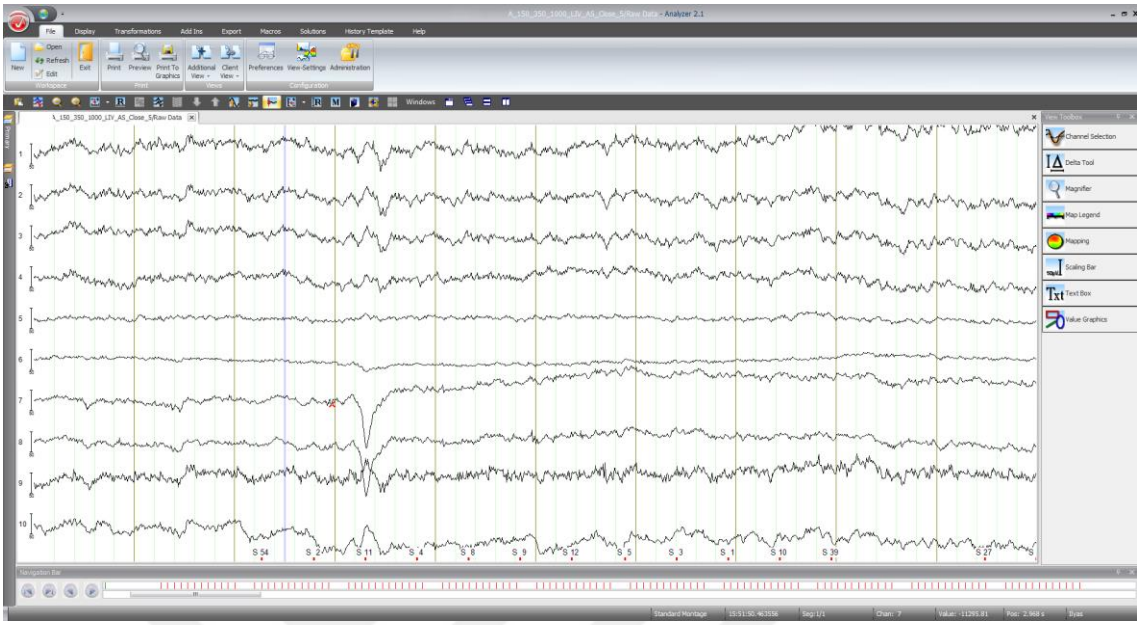
5.5 EEG Yayın Sunucusu

Çevrimiçi BMA uygulamaları ayrıca verinin alınması esnasında farklı platformlarda analiz edilebilmesine gerektirmektedir. Kullanılan uygulama olan Brain Vision Recorder ağ üzerinde verinin yayıyını yaparak RDA (Remote Data Access) sunucu fonksiyonuyla bu ihtiyaca cevap vermektedir. İlgili veriler soket bağlantısıyla 51234 veya 51244 numaralı portlardan erişilebilmektedir. Birinci port 16 bit, ikincisi ise 32 bit veri yayını için kullanılmaktadır. BMA geliştirme sürecinin bu aşamasında sadece çevrimdışı analiz kısmı ile ilgilenildiği için bu fonksiyona ihtiyaç duyulmadı. İlerleyen çalışmalarda aynı işlemlerin çevrimiçi veri üzerinde yapılması planlandığı için bu fonksiyona ileride ihtiyaç duyulacaktır.

5.6 Veri İşleme Birimi

Çalışmada BMA geliştime sürecinin ilk aşaması olan çevrimiçi analiz kısmı gerçekleştirildi. Bu aşamada kaydedilen verilerin, detaylı analiz işlemlerinin gerçekleştirilmesi için Matlab uygulaması kullanılmıştır. Mevcut veriler Brain Vision

Recorder uygulaması ile kaydedildikten sonra Brain Vision Analyzer 2 isimli araçla görüntülenmiştir (Şekil 5.11).



Şekil 5. 11 Brain Analyzer 2 uygulama ekran görüntüsü

Ayrıca bu araç mevcut verilerin Matlab ortamında analiz edilebilmesi için işaret bilgileri ile birlikte .mat formatında kaydedilebilmesine olanak sağlamaktadır.

Bu fonksiyon kullanılarak; mevcut veriler daha sonra analiz edilmek amacıyla .mat formatında kaydedilerek Matlab ortamına taşındı. Matlab' ta sırasıyla belirli işlemler uygulandı.

5.6.1 Segmentasyon

Uyaran uygulamasında görseller belirli periyotlarla yanıp sönmekte ve kayıt yazılımı belirli bir örnekleme frekansı ile kayıt yapmaktadır. Uyaranlar için 150 ms uyaran süresi, 350 ms iki uyaran arası olmak üzere, bir uyaran için toplam zaman aralığı 500 ms olarak belirlendi. Kayıt yazılımında ise örnekleme frekansı 250 Hz olarak belirlendi. Bu şekilde her bir uyaran için örnek sayısı 500 ms ile 125 örneğe tekabül etmektedir. Her bir uyaran için veriler, işaret bilgileri çözümlenerek 125 örnek x 6 kanal olmak üzere segmentlere ayrıldı.

5.6.2 Detrend

EEG verilerinin farklı süreçlerde, uyaranlara bağlı olmayan eğilimlerini nötralize etmek için; temel eğilim eğrisi, mevcut veriden çıkartılarak detrend işlemi uygulanmış oldu. Detrend işlemi bir Matlab fonksiyonu olarak kolaylıkla uygulanabilmektedir.

5.6.3 Kayar Ortalama Filtre (Moving Average Filter)

Bu aşamada şehir şebekesi etkisi gibi basit gürültülerin yok edilmesi amacıyla için beş adımlık kayar ortalama filtre işlemi uygulandı ve her bir segment için daha yumuşak bir eğri oluşturuldu.

5.6.4 Ortalama

Mevcut verilerin P300 olması gereken ve P300 olması gerekmeyen bilgilerine göre ortalamaları alınarak grafikleri oluşturuldu.

P300 olması beklenen ve beklenmeyen segment ortalamalarına bakıldığında farklı kişilerde 250. ms ve 500. ms arasında açık genlik değişim farklarını gözlemledik. Bu şekilde beklenen uyaranların oluşturduğu açık EEG karakteristiği belirlendi. P300 işaretinin baskın olarak görüldüğü 4 adet kanalın verileri, sınıflandırma kapsamında kullanıldı.

5.6.5 Öznitelik Seçimi

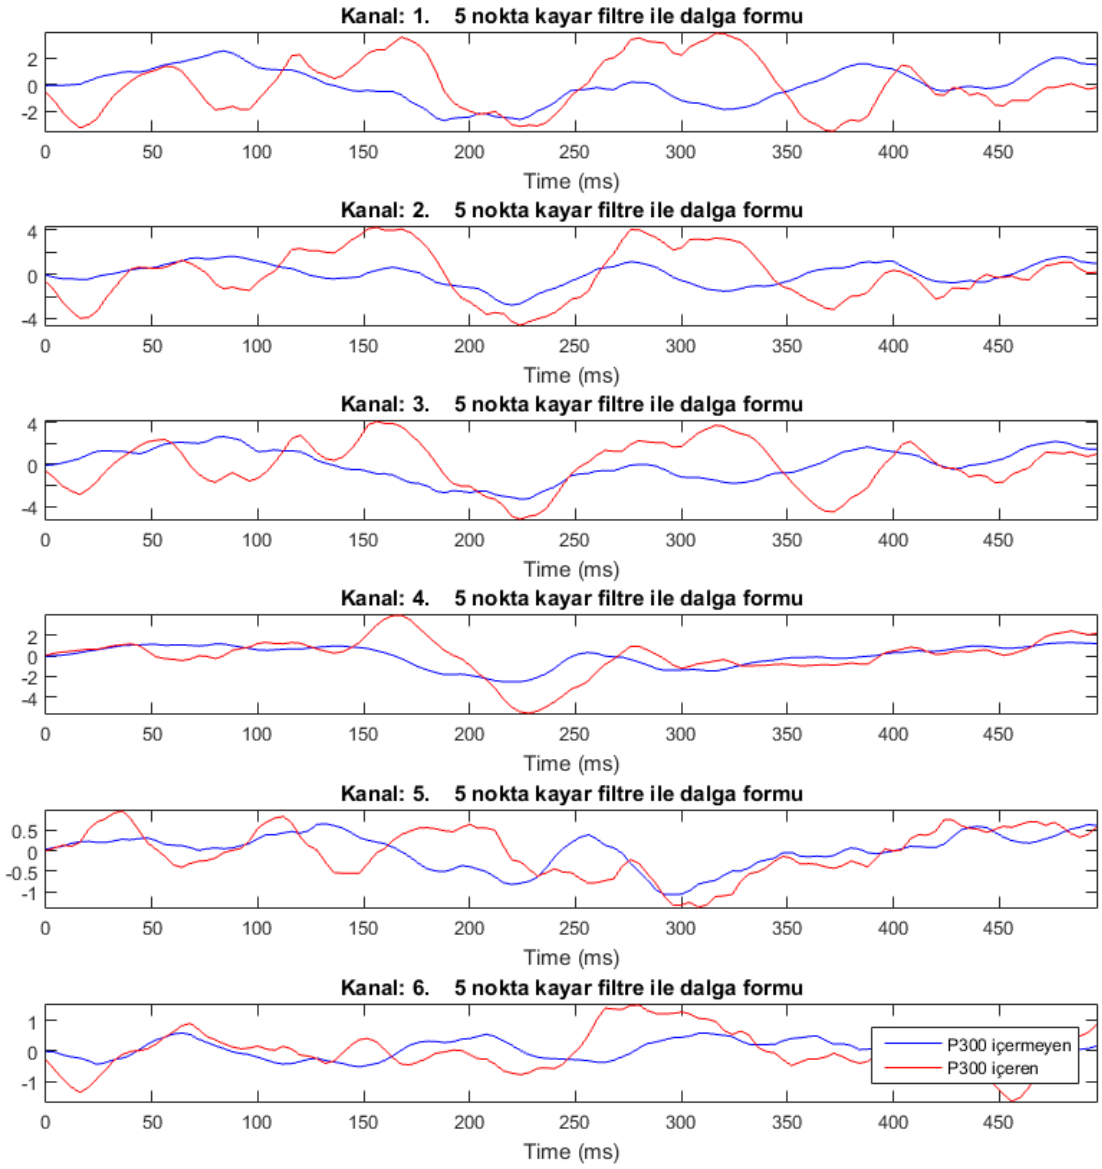
Her bir oturumda deneklerin matris üzerindeki 'A' harfi bulunan satır ve sütunlara odaklanmasını ve deneğin sadece 10 set için 'A' harfini içeren uyaranları içinden sayması istenmiştir.

Uygulamada her bir uyaran seti; yatayda 6, dikeyde 6 olmak üzere 12 uyaran şeklinde ayarlanmıştır. Oturum esnasında bu uyaranlar rastgele sırayla aktif hale gelmektedir.

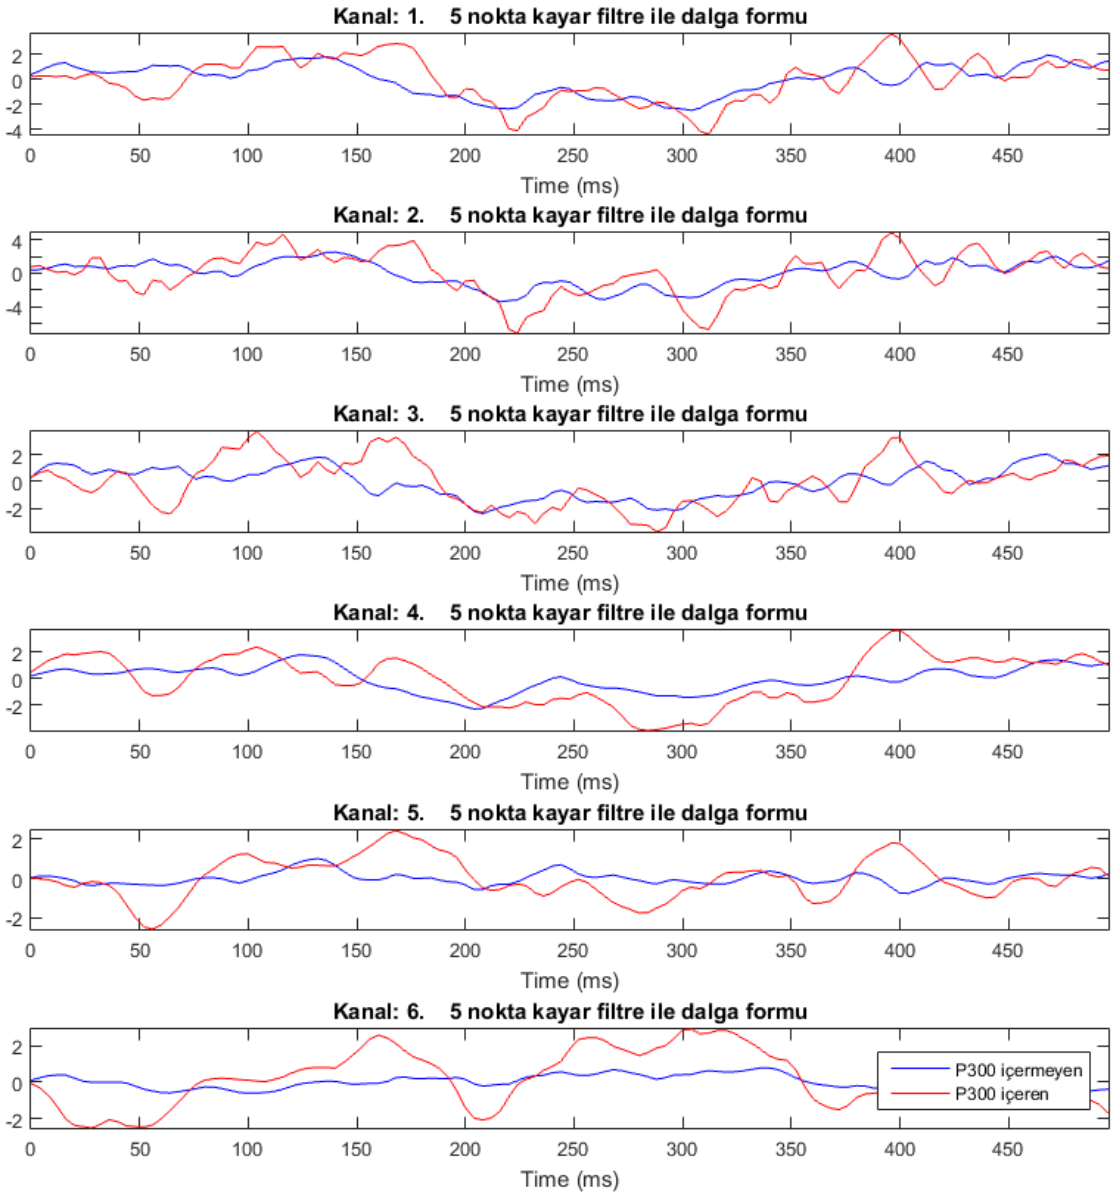
'A' harfi için 10 sette 12 uyaran olmak üzere 120 uyaran mevcut. Bunlar içinde her 12 uyaran içinde 2 adet uyaran olmak üzere, 10 sette 20 adet P300 işareti içeren ve 100 adet P300 işareti içermeyen segment olması beklenmektedir.

Her bir segment, 125 örnek ve 6 kanal olmak üzere; 750 adet örnekten oluşmaktadır.

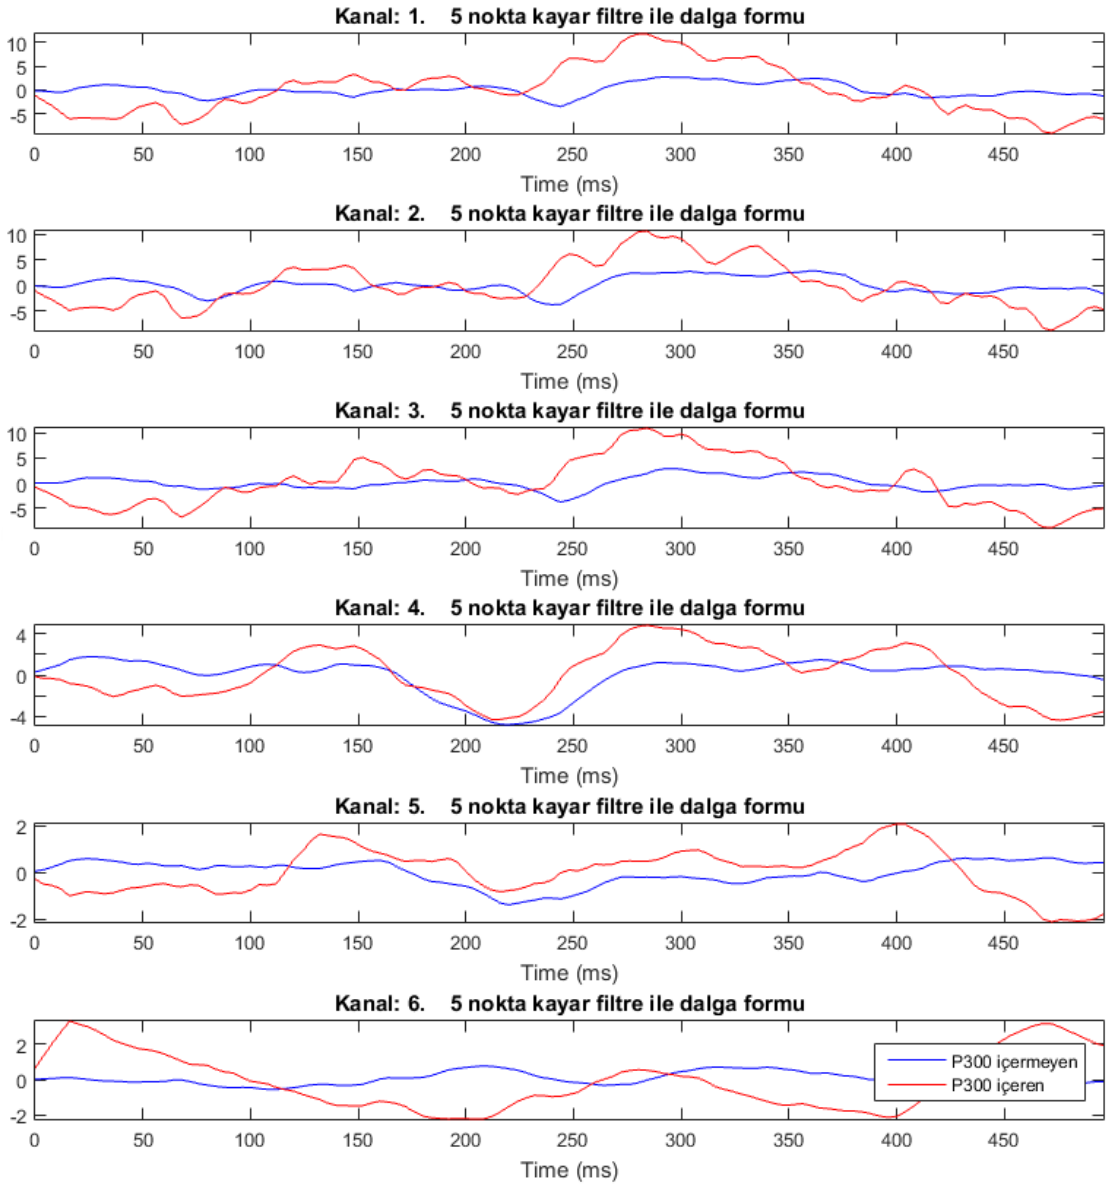
Görselleştirmelerimizde özellikle dört kanalın ortalamasında P300 işaretinin kişiye bağlı olmak üzere baskın olduğu görüldü. 5 adet farklı denek için, uyarana karşı değişen dalga formları aşağıdaki gibidir. Kanal sıralaması konumları ise 1' den 6’ ya kadar; Oz, O1, O2, Pz, Cz ve Fz şeklindedir. P300 işaretinin yoğunlaştığı konum ve genlik her bir denek için farklılık arz etmektedir.



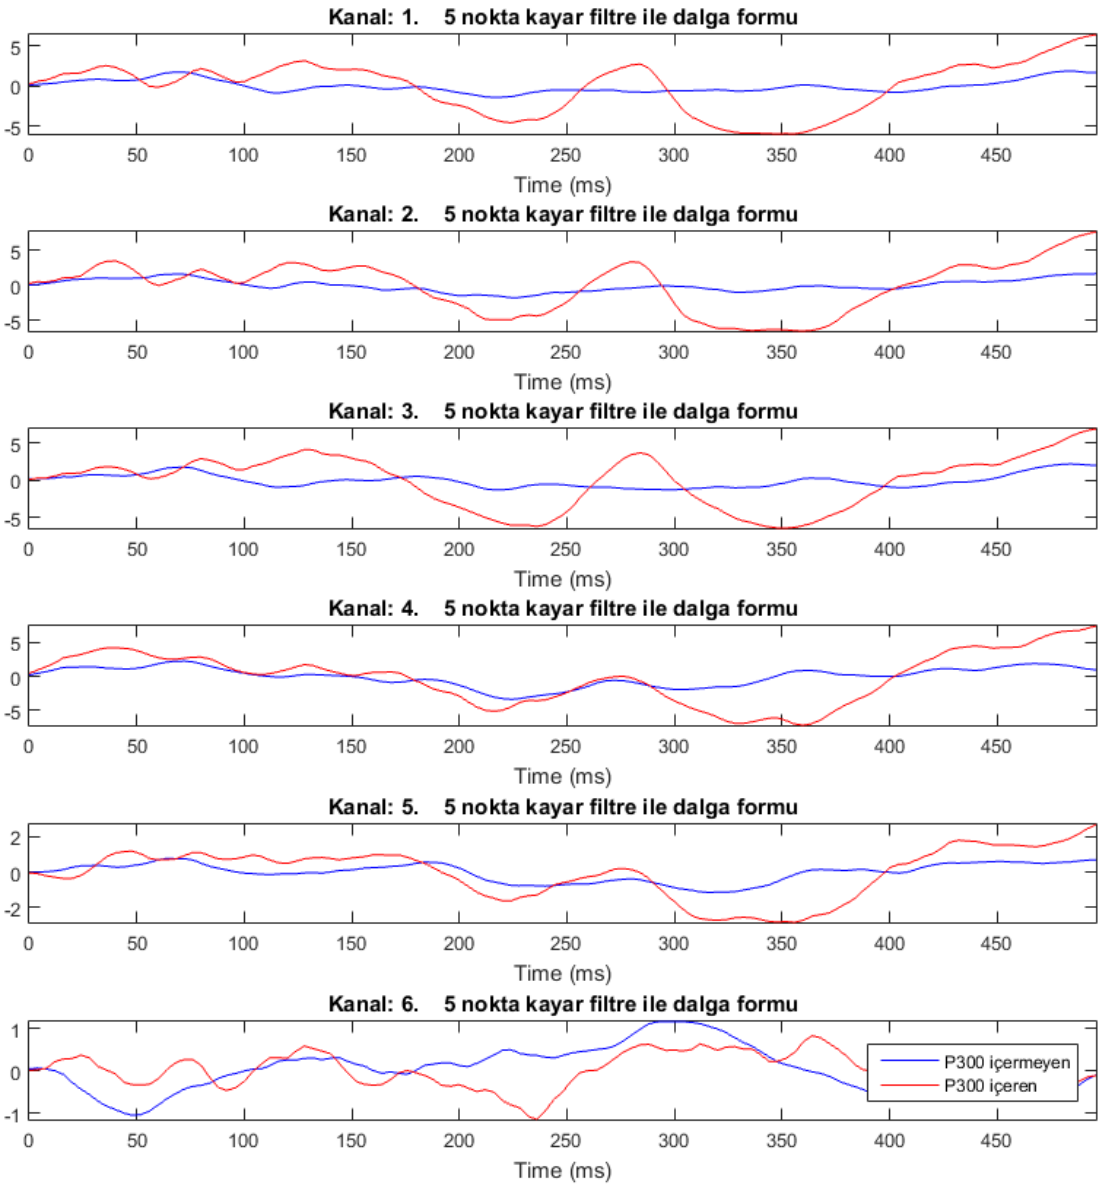
Şekil 5. 12 Denek 1' e ait ortalama üzerinden dalga formu değişimi



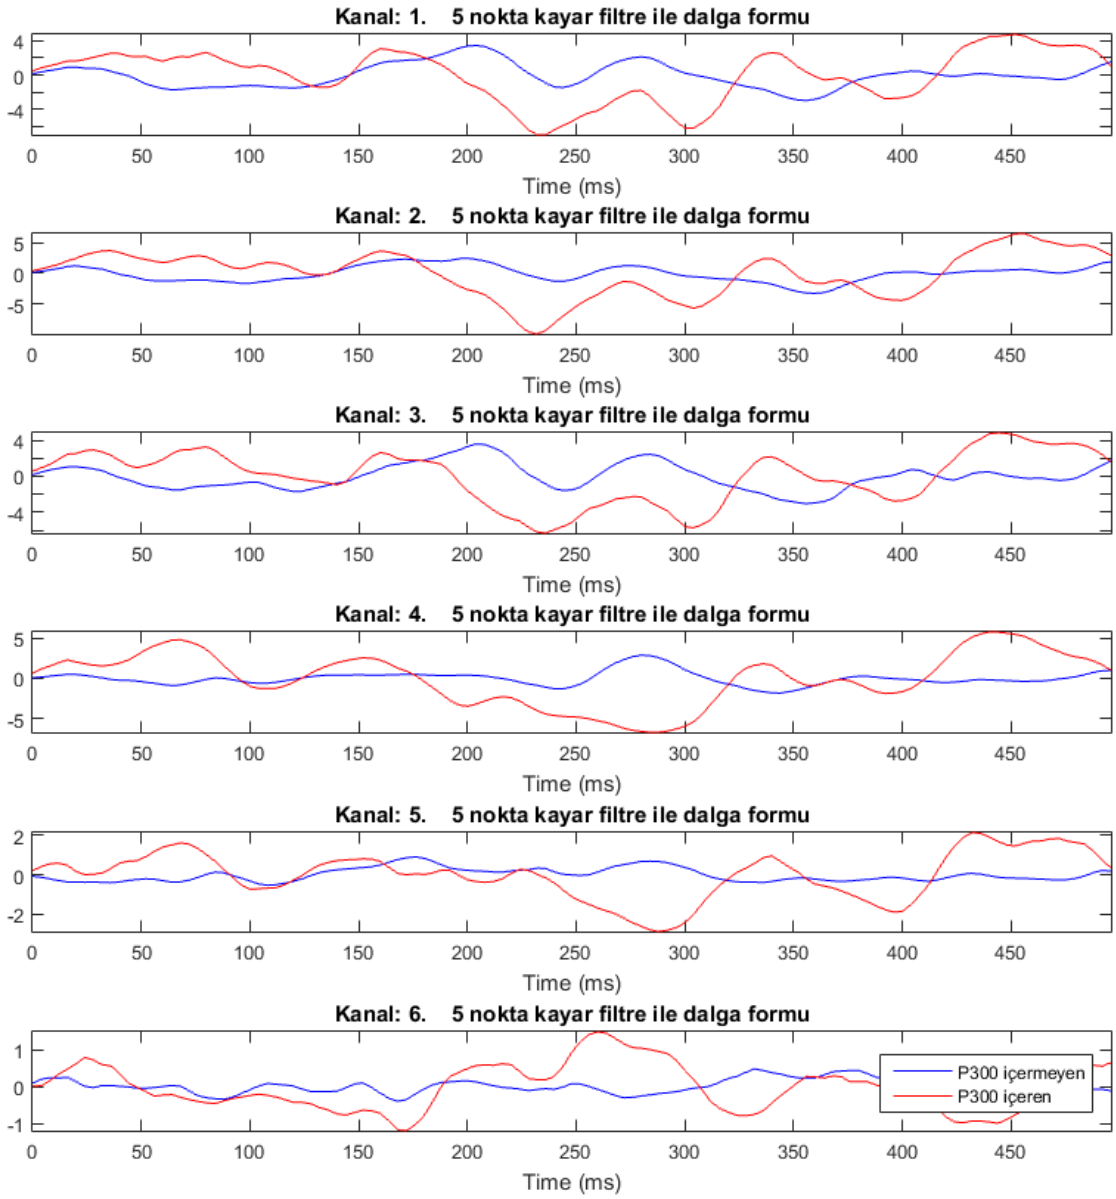
Şekil 5. 13 Denek 2' ye ait ortalama üzerinden dalga formu değişimi



Şekil 5. 14 Denek 3' e ait ortalama üzerinden dalga formu değişimi



Şekil 5. 15 Denek 4' e ait ortalama üzerinden dalga formu değişimi



Şekil 5. 16 Denek 5' e ait ortalama üzerinden dalga formu değişimi

Burada her bir uyaran' a ait segmentler dikkate alındığında, 20 adet P300 işareti içermesi gereken ve 100 adet P300 işareti içermesi gerekmeyen olmak üzere; toplam 120 adet örnek kümesi oluşturuldu. Bu örenk kümeleri de P300 içermesi gerekenler için 1 ve P300 içermesi gerekmeyenler için 0 olmak üzere etiketlendi.

Daha sonra, verilerin sınıflandırılması amacıyla verilere aşağıdaki işlemler uygulandı.

5.6.6 Veri Azaltma

Öznitelik kümesinde, öncelikli olarak P300 işaretinin baskın olarak göründüğü dört kanal belirlenip, dört ile örnek azaltma (decimate / downsampling) işlemi uygulanarak örnek sayısı her bir kanal için 1/4 oranında azaltıldı.

5.6.7 Öznitelik Kümesi Birleştime

Daha sonra bu örnekler yanyana eklenerek (concatanation) 128 örneklik bir özellik vektörü oluşturuldu. Daha sonra sınıf etketi de dâhil edildiğinde, toplam 129 örneklik bir özellik öznitelik edildi.

5.6.8 Normalizasyon

Sınıflandırma algoritmalarının daha sağlıklı çalışması için verilere ait değerler belirli bir aralığa indirgenmelidir. Burada herbir segmetteki veriler, herbir kanal için; ayrı 0 ve 1 arasında kendi içinde normalize edilerek, kendi içinde göreli değişimleri belirlendi.

5.6.9 Sınıflandırma

Tez çalışması kapsamında on farklı denekten EEG verileri alındı. Bu veriler içinden beş farklı deneğe ait olan verinin sağlıklı şekilde elde edildiği değerlendirildi. Daha sonra sınıflandırma amacıyla bu veriler kullanıldı. Her bir denek için mevcut veriler daha sonra çevrimiçi kullanım uygunlukları değerlendirilmek üzere; önce excel ortamına aktarılarak kaydedildi ve daha sonra Weka uygulaması kullanılarak farklı algoritmaların başarı oranları değerlendirildi.

Weka uygulaması veri işleme yetenekleri ve kullanım kolaylığı sebebiyle, sınıflandırma çalışmalarına hız katan oldukça etkili bir araçtır. Bu sebeple veri sınıflandırma işlemi için WEKA uygulamasının kullanılması tercih edildi.

Weka uygulamasına sırasıyla Naive Bayes, ÇKA ve DVM algoritmaları bu özellik vektörleri üzerinde uygulandı. Algoritmalara ait sonuçlar bir sonraki bölümde detaylı olarak anlatılmıştır.

BÖLÜM 6

BMA SİSTEMİNİN TEST VERİLERİNİN SINIFLANDIRILMASI VE DEĞERLENDİRİLMESİ

Daha önce EEG verisinden önişleme süreçleri sonucunda elde ettiğimiz öznitelik vektörlerine sırasıyla Naive Bayes (NM), Çok Katmanlı Algılayıcı (ÇKA) ve Destek Vektör Makineleri (DVM) algoritmaları uygulandı.

Her bir denek için kullanılan sınıflandırma algoritmaları ve sınıflandırma başarıları çizelge 6. 1 ve çizelge 6. 5 arasında gösterilmiştir.

Testlerde DVM için doğrusal kernel kullanıldı. ÇKA' da ise öğrenme oranı 0.01 ve 0.02 olmak üzere iki farklı şekilde kullanıldı.

ÇKA' da kullanılan diğer parametreler aşağıdaki gibidir.

Momentum: 0.2

Gizli katman sayısı: 5

Eğitim iterasyon sayısı: 500

Mevcut verilerin test edilen sistemin üzerinde ne kadar genelleştirilebildiğinin belirlenebilmesi için veriler n adet farklı kümeye ayrılır ve bir küme test için dışarıda kalmak üzere, $n-1$ adet küme eğitim amacıyla kullanılır. Bu uygulama n çapraz geçerleme şeklinde ifade edilmektedir. Daha sonra tüm bu testlerin ortalaması alınarak, test başarı düzeyi belirlenir.

Burada her test için 10 adet çapraz geçerleme yapılmıştır. Test sonuçları çizelge 6. 1 ve çizelge 6. 5 arasında verilmiştir. Her çizelgede doğru yüzdeleri ile birlikte doğru pozitif (DP), hatalı pozitif (HP), doğru negatif (DN) ve hatalı negatif (HN) değerleri de ayrıca

verilmiştir. Doğruluk yüzdeleri; doğru pozitif ve doğru negatif toplamlarının, toplam öznitelik vektör sayısına oranını vermektedir. ÇKA algoritmasında ayrıca, öğrenme oranı (Ö.O) parametresi 0.01 ve 0.02 olmak üzere; iki farklı değer için sonuçlar verilmiştir.

Çizelge 6. 1 Denek 1' e ait öznitelik kümesi seçimi ve algoritma başarıları

Naive Bayes	DVM	ÇKA Ö.O 0.01	ÇKA Ö.O 0.02
% 77.5	% 85	% 85.8333	% 82.5
DN HN **89** **11** **16** **4** HP DP	DN HN **94** **6** **12** **8** HP DP	DN HN **99** **1** **16** **4** HP DP	DN HN **93** **7** **14** **6** HP DP

İlk deneğe ait sınıflandırma sonuçları incelendiğinde maksimum doğru pozitif sayısının DVM algoritmasında olduğu görülmektedir. Naive Bayes algoritmasında doğru pozitif sayıları öğrenme oranı 0.01 olan ÇKA ile aynı iken, hatalı negatif sayıları Naive Bayes algoritmasında daha fazla olması, bu algoritma için olumsuz bir durum olmuştur. Öğrenme orana 0.01 olan ÇKA ve öğrenme oranı 0.02 olan ÇKA karşılaştırıldığında; 1. de hatalı negatif 1 iken 4 adet pozitif belirlenebilmiştir. Öğrenme oranı 0.02 yapıldığında ise gerçek pozitif sayısı 6’ ya çıkarken hatalı negatif sayısı da 1’ den 7’ ye çıkmıştır. Birinci denek için gerçek pozitif sayısı dikkate alındığında en başarılı olan DVM şeklinde değerlendirilirken, 0.01 Ö.O ile ÇKA algoritması doğru pozitif ve doğru negatiflerin toplamında maksimum başarıyı vermiştir.

Çizelge 6. 2 Denek 2' ye ait öznitelik kümesi seçimi ve algoritma başarıları

Naive Bayes	DVM	ÇKA Ö.O 0.01	ÇKA Ö.O 0.02
% 77.5	% 74.1667	% 83.3333	% 75.8333
DN HN **87** **13** **14** **6** H DP	DN HN **88** **12** **19** **1** HP DP	DN HN **100** **0** **20** **0** HP DP	DN HN **90** **10** **19** **1** HP DP

Denek 2’ ye ait sonuçlar değerlendirildiğinde 0.01 Ö.O ile ÇKA algoritması maksimum başarıyı verdiği görülmesine rağmen, bu şekilde hiçbir doğru pozitif yakalayamadığı görülmektedir. Bu durumda bu parametreler 2. Denek için bu algoritmanın çevrimiçi bir uygulamada kullanılabilmesi mümkün değildir. Naive Bayes algoritması toplam başarı dikkate alındığında DVM ve 0.02 Ö.O ile ÇKA’ ya yakın iken doğru pozitif oranı olarak en başarılı sonucu vermiştir.

Çizelge 6. 3 Denek 3' e ait özellik kümesi seçimi ve algoritma başarıları

Naive Bayes	DVM	ÇKA Ö.O 0.01	ÇKA Ö.O 0.02
% 83.3333	% 80	% 85	% 79.1667
DN HN **89** **11** **9** **11** HP DP	DN HN **89** **11** **13** **7** HP DP	DN HN **96** **4** **14** **6** HP DP	DN HN **89** **11** **14** **6** HP DP

Denek 3. için başarı değerleri değerlendirildiğinde, DVM ve 0.02 Ö.O ile ÇKA algoritması çok yakın sonuçları vermiştir. Naive Bayes, 0.01 Ö.O ile ÇKA’ dan daha düşük başarıya

sahip görünmesine rağmen doğru pozitif sayısı Naive Bayes algoritmasında daha yüksek olmuştur.

Çizelge 6. 4 Denek 4' e ait öznitelik kümesi seçimi ve algoritma başarıları

Naive Bayes	DVM	ÇKA Ö.O 0.01	ÇKA Ö.O 0.02
% 74.1667	% 80	% 84.1667	% 83.3333
DN HN **77** **23** **8** **12** HP DP	DN HN **90** **10** **14** **6** HP DP	DN HN **99** **1** **18** **2** HP DP	DN HN **94** **6** **14** **6** HP DP

Denek 4.' e ait başarı sonuçları incelendiğinde iki farklı öğrenme oranı ile ÇKA algoritması DVM algoritmasından daha başarılı sonuçlar vermiş görünmektedir. Fakat Naive Bayes algoritması da DVM' da ÇKA' dan daha düşük sonuçlar vermiş görünmesine rağmen doğru pozitif oranı ikisinde de ÇKA algoritmasında daha fazla olmuştur. DVM algoritması ayrıca, 4. Örnek doğru pozitiflerin %80' ini doğru belirlemiş görünmektedir.

Çizelge 6. 5 Denek 5' e ait öznitelik kümesi seçimi ve algoritma başarıları

Naive Bayes	DVM	ÇKA Ö.O 0.01	ÇKA Ö.O 0.02
% 79.1667	% 80	% 85.8333	% 85
DN HN **84** **16** **9** **11** HP DP	DN HN **88** **12** **12** **8** HP DP	DN HN **95** **5** **12** **8** HP DP	DN HN **92** **8** **10** **10** HP DP

Denek 5’ e ait başarı sonuçları incelendiğinde en düşük başarı Naive Bayes’ te görülmesine rağmen en yüksek doğru pozitif oranı da Naive Bayes algoritmasında görülmektedir. DVM ve 0.01 öğrenme oranı ile ÇKA aynı doğru pozitif oranlarına sahip iken DVM’ de hatalı pozitif daha fazladır. 0.02 öğrenme oranı ile ÇKA pozitiflerin yarısını yakalayabilmiş ve hatalı negatif oranı 0.01 öğrenme oranı ile ÇKA’ dan çok az fazladır.

Tüm bu test sonuçları dikkate alındığında sınıflandırma başarının üzerinde kişisel P300 işareti karakteristiğinin belirgin bir etkisi olduğu görülmektedir. Bu sebeple; herhangi bir algoritmanın başarı düzeyinin yüksekliğini ifade etmektense P300 heceleyici sistemindeki her bir oturum kişiye özel olarak gerçekleştirilmelidir. Bu özel analiz sonucunda kişiye bağlı olarak optimum başarıyı verdiği değerlendirilen algoritma ve parametreler çevrimiçi uygulamada kullanılmalıdır.

BÖLÜM 7

SONUÇ VE ÖNERİLER

Bu çalışmada bir BMA uygulamasının laboratuvar ortamında simulasyonundan ziyade gerçek hayata uyarlanabilir çevrimiçi bir uygulamanın ilk fazı, çevrimdışı analiz kısmı gerçekleştirilmiştir. Bu amaçla daha sonraki çalışmalarda da kullanılabilecek bağımsız ve esnek bir P300 heceleyici uygulaması geliştirilmiştir. Bu uygulama kullanılarak 10 farklı denekten EEG verileri toplanmıştır. Bu verilerde her bir uyarana ait segment 150ms uyaran süresi ve 350ms uyaranlar arası zaman aralığı olmak üzere her biri 500ms' lik 125 örnek x 6 kanal' dan oluşmaktadır. Her bir oturumda bir sette 12 uyaran olmak üzere; 10 setten oluşmaktadır. Bu şekilde elde edilen verilerin 5 adedinin sağlıklı olduğu değerlendirilmiş ve bu veriler çevrimdışı analiz amacıyla kullanılmıştır. Elde edilen veriler daha sonra analiz amacıyla Matlab ortamına aktarılmış ve bu verilere sırasıyla kanal seçimi, kayar ortalama filtre, detrend, normalizasyon ve her segment için kanal verilerinin yanyana birleştirilme işlemi uygulanmıştır. Daha sonra bu verilere sınıf bilgileri de eklenerek bu veri küreleri WEKA uygulama ortamında kullanılabilir hale getirilmiştir.

Daha sonra Weka ortamında sınıflandırılan bu veri kümelerinde maksimum %85.8333 civarında başarı elde edilmiştir. Toplam başarı %74.1667 ve %85.8333 arasında değişmekle birlikte maksimum doğru pozitif oranı %60' a ulaşmıştır. Genel başarı durumu yüksek görünmesine rağmen doğru pozitiflerin 0 olduğu durumlar çevrimiçi çalışma için anlam ifade etmemektedir.

Hatalı pozitiflerin SSVEP gibi bir geçerleme mekanizmasıyla değerlendirilebilmesiyle daha etkili bir P300 uygulaması geliştirilebileceği değerlendirilmektedir.

Sınıflandırma ve ilgili parametrelerin her bir denek için P300 karakteristiğine bağlı olarak ayrı ayrı değerlendirilmesi, her denek için çevrimiçi uygulamada en yüksek başarıyı sağlayacağı değerlendirilmektedir.

Bu aşamada geliştirilen P300 heceleyici uygulamasının sadece çevrimdışı analiz özelliği kullanılmıştır. Fakat uygulama daha sonraki çalışmalar amacıyla, çevrimiçi analiz özelliğine de sahiptir. Daha sonra değerlendirilen şekilde bir mekanizma eklenmesi ve dikkat kaybı gibi zorlukların azaltılması amacıyla "Edges Paradigm"' [17] yöntemi de eklenerek P300 heceleyici uygulamasında daha yüksek başarı edilebileceği değerlendirilmektedir.

Ayrıca gürültü azaltımı için mastoid kanalların ortalamasının tüm kanallardan çıkarılması, windsorization [64] gibi istatistiksel yöntemlerin kullanılması ile başarı düzeyinin daha da artırılabileceği değerlendirilmektedir. Daha sonra bu aktivitelerin yazmış olduğumuz uygulama üzerinde çevrimiçi olarak test edilmesiyle, çalışmanın daha da zenginleştirilmesi planlanmaktadır.

KAYNAKLAR

[1] Vidal, J. J., (1973). "Toward Direct Brain Computer Communication", Annual Review of Biophysics and Bioengineering, 2:157-180.

[2] Geddes, L. A., (2006). “Retrospectroscope”, Engineering Contributions to the Life Sciences IEEE Engineering in Medicine and Biology Magazine, 88-89.

[3] Schmidgen, H., (2002). “Of Frogs And Men: The Origins Of Psychophysiological Time Experiments”, Endeavour, 26:142-148.

[4] Seyfarth, E., (2005). “Julius Bernstein (1839–1917): Pioneer Neurobiologist and Biophysicist”, Biological Cybernetics, 94:2-8.

[5] Coenen, A. ve Zayachkivska, O., (2013). “Adolf Beck: A pioneer in Electroencephalography in Between Richard Caton and Hans Berger”, Advances in Cognitive Psychology, 9:216-221.

[6] La Vaque, T. J., (1999). “The History of EEG Hans Berger: Psyshophysiologist. A Historical Vignette”, Journal of Neuroteraphy, 1-9.

[7] Schomer, D. L. ve Da Silva, F. L., (2011). Bergers Contemporaries Niedermeyer's Electroencephalography: Basic Principles, Clinical Applications, and Related Fields, Sixth Edition, Lippincott Williams & Wilkins, a Wolters Kluwer business, Philadelphia.

[8] Hodgkin, A. L. ve Huxley, A. F., (1952). “A Quantitative Description of Membrane Current and its Application to Conduction and Excitation in Nerve”, J. Physiol., 117:500-544.

[9] Walter, W. G. ve Shipton, H. W., (1951). “A Toposcopic Display System Applied to Neurophysiology”, Journal of the British Institution of Radio Engineers, 11:260-273.

[10] Klem, J.H., Lüders, H.O., Jasper, H. H. ve Elger, C., (1991). “The Ten-Twenty Electrode System of the International Federation”, Recommendations for the Practice of Clinical Neurophysiology: Guidelines of the International Federation of Clinical Physiology.

[11] Fetz, E. E., (1969). “Operand Conditioning of Cortical Unit Activity”, Science, 163:955-958.

[12] Georgepoulos, A. P., Schwartz, A. B. ve Kettner, R, E., (1986). “Neuronal Population Coding of Movement Direction”, Science, 223:1416 - 1419.

[13] Georgepoulos, A. P., Schwartz, A. B. ve Kettner, R. E., (1988). “Primate Motor Cortex and Free Arm Movements to Visual Targets in Three-Dimensional Space II. Coding of the Direction of Movement by a Neuronal Population”, The Journal of Neuroscience, 8:2928-2937.

[14] Kennedy, P. R. ve Bakay, R. E., (1998). “Restoration of Neural Output from a Paralyzed Patient by a Direct Brain Connection”, Neuroreport, 9:1707-1711.

[15] Chapin, J. K., Moxon, K. A., Markovitz, R. S. ve Nicolelis, M. A., (1999). “Real-Time Control of a Robot Arm Using Simultaneously Recorded Neurons in the Motor Cortex”, Nature Neuroscience, 2:664-670.

[16] Farwell. L. ve Donchin, E., (1988). “Talking off the top of your head: Toward a mental prosthesis utilizing event-related brain potentials”, Electroencephalography and Clinical Neurophysiogy,70:510-523.

[17] Obeidat, Q. T., Campbell, T. A. ve Kong, j., (2015). “Introducing the Edges Paradigm: A P300 Brain–Computer Interface for Spelling Written Words”, IEEE Transactions On Human-Machine Systems, 45:727-738.

[18] Regan, D., (1966). “Some Characteristics of Average Steady-State and Transient Responses Evoked by Modulated Light”, Electroencephalography and Clinical Neurophysiology, 20:238-248.

[19] Cheng, M., Gao, X., Gao, S. ve Xu, D., (2002). “Design and Implementation of a Brain-Computer Interface with High Transfer Rates”, IEEE Transactıons on Biomedical Engineering, 49:1181-1186.

[20] Yin, E., Zhou, Z., Jiang J., Chen, F., Liu, Y. ve Hu, D., (2014). “A Speedy Hybrid BCI Spelling Approach Combining P300 and SSVEP”, IEEE Transactions on Biomedical Engineering, 61:473-483.

[21] McFarland, D., Krusienski, D. J. ve Wolpaw, J., (2006). “Brain-Computer Interface Signal Processing at the Wadsworth Center: Mu and Sensorimotor Beta Rhythms”, Progress in Brain Research, 159:411-419.

[22] Hinterberger, T., Schmidt, S., Neumann, N., Mellinger, J., Blankertz, B., Curio, G. ve Birbaumer, N., (2004). “Brain-Computer Communication and Slow Cortical Potentials”, IEEE Transactions on Biomedical Engineering, 51:1011-1018.

[23] Sparknotes, Structure and Function of Animals, www.sparknotes.com/testprep/books/sat2/biology/chapter9section1.rhtml, 10 Temmuz 2016.

[24] Collura, T. F., (1993). “History and Evoluation of Electroencephalographic Instruments and Techniques”, Journal of Clinical Neurophysiology, 10:476-504.

[25] Kirkland, K., (2010). Biological Sciences: Notable Research and Discoveries, First Edition, Facts On File, New York.

[26] Millett, D., (2001). “Hans Berger: From Psychic Energy to the EEG”, Perspectives in Biology and Medicine, 44:522-542 .

[27] Hubpages, What are Beta Brain Waves? Improve Focus and Motivation with Beta brainwave entrainment, mbyl.hubpages.com/hub/What-are-Beta-Brain-Waves-Focus-and-Motivation-with-Beta-brainwave-entrainment, 10 Temmuz 2016.

[28] Walter, W. G. ve Dovey, V. J., (1944). “Electro-encephalography in cases of Sub-Cortical Tumor”, J. Neurol. Neurosurg. Psychiatry, 7: 57-65.

[29] Kim, D. K., Lee, K. M., Kim, J., Whang, M. C. ve Kang, S. W., (2013). “Dynamic Correlations Between Heart and Brain Rhythm During Autogenic Meditation”, Frontiers in Human Neuroscience, 7:1-8.

[30] Panayiotopoulos, C. P., National Center for Biotechnology Information, The Epilepsies: Seizures, Syndromes and Management, www.ncbi.nlm.nih.gov/books/NBK2601, 10 Temmuz 2016.

[31] Sanei, S., ve Chambers J. A., (2007). Eeg Signal Processing, John Wiley & Sons Ltd, West Sussex.

[32] Ucmas, Left Brain Vs Right Brain, ucmas.ca/our-programs/whole-brain-development/left-brain-vs-right-%20brain 10 Temmuz 2016.

[33] Felsefe Dersliği, II. Ünite: Psikolojinin Temel Süreçleri, www.felsefedersligi.com/FileUpload/op30412/File/2.unite giris bl..pdf, 10 Temmuz 2016.

[34] Mayfield Brain & Spine, Anatomy of the Brain, www.mayfieldclinic.com/PE-AnatBrain.htm, 10 Temmuz 2016.

[35] About, Anatomy of the Brain - Cerebral Cortex, biology.about.com/od/anatomy/p/cerebral-cortex.htm, 10 Temmuz 2016.

[36] Walter, W. G., (1964). “Contingent Negative Variation: An Electrical Sign of Sensorimotor Association And Expectancy in the Human Brain”, Nature, 203:380-384.

[37] Luck, S. J., (2005), An Introduction o Event-Related Potentials and Their Neural Origins, biology.mit.edu/sites/default/files/Luck_chap1.pdf, 10 Temmuz 2016.

[38] Karagöz, M., Alkaç, İ. Ü., Ergen, N., Eradamlar, N. ve Alpkan L., (2005). “Psikiyatrik Hastalıklarda Elektrofizyolojik (P300) Yöntemler”, Düşünen Adam 18: 210-216.

[39] Creel, J. C., Webvision, Visually Evoked Potentials by Donnell J. Creel., webvision.med.utah.edu/book/electrophysiology/visually-evoked-potentials, 10 Temmuz 2016.

[40] Teplan, M., (2002). “Fundamentals of EEG Measurement”, Measurement Science Review, 2:1-11.

[41] Electroencephalography, www.webdepot.umontreal.ca/Usagers/jolicop/MonDepotPublic/Jolicoeur_files/PJ_EEGlab.html, 10 Temmuz 2016.

[42] www.martinos.org, EEG Cap Instructions, www.martinos.org/meg/manuals/EEG_Cap_Instructions.pdf, 10 Temmuz 2016.

[43] Jurcak, V., Tsuzuki, D. ve Dan, I., (2006). "10/20, 10/10, and 10/5 systems revisited: Their validity as relative head-surface-based positioning systems", NeuroImage, 34:1600-1611.

[44] 10-20 system (EEG), https://en.wikipedia.org/wiki/10-20_system_(EEG), 10 Temmuz 2016.

[45] Chatrian, G. E., Lettich, E. ve Nelson P. L., (1985). "Ten Percent Electrode System for Topographic Studies of Spontaneous and Evoked EEG Activities", American Journal of EEG Technology, 25:83-92.

[46] Electroencephalography, http://www.bem.fi/book/13/13.htm, 10 Temmuz 2016.

[47] Aparna C., Murthy J.V.R. ve Babu B. R., (2012). "Energy Computation For Bci Using DCT And Moving Average Window For Noise Smoothening", International Journal of Computer Science, Engineering and Applications, 2:15-21.

[48] Özkan, Y., (2008), Veri Madenciliği Yöntemleri, Papatya Yayıncılık, İstanbul.

[49] Öztemel, E., (2012), Yapay Sinir Ağları, Papatya Yayıncılık, İstanbul.

[50] Linear SVM, https://en.wikipedia.org/wiki/Support_vector_machine, 10 Temmuz 2016.

[51] Kavzoğlu, T. ve Çölkesen, İ., (2010). "Destek Vektör Makineleri ile Uydu Görüntülerinin Sınıflandırılmasında Kernel Fonksiyonlarının Etkilerinin İncelenmesi", Harita Dergisi, 144:73-82.

[52] Pfurtscheller, G. ve Silva, L., (1999). "Event-Related EEG/MEG Synchronization and Desynchronization: Basic Principles", Clinical Neurophysiology, 110:1842-1857.

[53] Kooi O. V. D., Identifying Individuals Using Event Related Synchronization and Desynchronization, referaat.cs.utwente.nl/conference/13/paper/7199/identifying-individuals-using-event-related-synchronization-and-desynchronization.pdf, 10 Temmuz 2016.

[54] Friman O., Volosyak I. ve Gräser A., (2007). "Multiple Channel Detection of Steady-State Visual Evoked Potentials for Brain-Computer Interfaces", Gräser Experimental Brain Research, 54:742-750.

[55] Herrmann, C. S., (2001). "Human EEG responses to 1-100 Hz flicker: resonance phenomena in visual cortex and their potential correlation to cognitive phenomena", Experimental Brain Research, 137:346-353.

[56] Shigezumi, S., Hara, H, Namba, H. ve Serizawa, C., Dobashi, Takemoto, A. ve Matsumoto, E., Bayesian Sequential Learning for EEG-Based BCI Classification Problems, cdn.intechopen.com/pdfs-wm/44183.pdf, 10 Temmuz 2016.

[57] Plong, M., Shen, K., Vliet, V. M., Robben, A. ve Hulle, M. V., (2012), Accurate Visual Stimulus Presentation Software for EEG Experiments, https://gbiomed.kuleuven.be/english/research/50000666/50000669/50488669/neuro_research/neuro_research_mvanhulle/comp_pdf/ACIS.pdf, 10 Temmuz 2010.

[58] AVI SSVEP Dataset, www.setzner.com/avi-ssvep-dataset, 15 Temmuz 2015.

[59] Wolpaw, J. R., Birbaumer, N., McFarland, D. J., Pfurtscheller G. ve Vaughan T. M., (2002). "Brain-Computer Interfaces for Communication and Control", Clinical Neurophysiology, 113:767-791.

[60] Riboccon, D., (2009), Product Development, http://www.brainproducts.com/files/public/products/brochures_material/pr_articles/0902_actiCAP_DR.pdf, 10 Temmuz 2016.

[61] V-Amp: The BCI Amplifier, www.brainproducts.com/bci_pack.php, 15 Temmuz 2015.

[62] www.brainvision.co.uk, Brazil will showcase not just one but two historic events, (2014), www.brainvision.co.uk/blog/2014/06/brazil-will-showcase-not-just-one-but-two-historic-events, 10 Temmuz 2016.

[63] S-link SL-PP01 PCI Paralel 1 Port Kart, www.s-link.com.tr/urunler/s-link-sl-pp01-pci-paralel-1-port-kart-oewtx, 15 Temmuz 2016.

[64] Amcalar, A., 2010, Design, Implementation And Evaluation of A Real-Time P300-Based Brain-Computer Interface System, Yüksek Lisans Tezi, Sabancı Üniversitesi, İstanbul.

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : Sabit ÇAKIR

Doğum Tarihi ve Yeri : 06.05.1984

Yabancı Dili : İngilizce

E-posta : sabit.c@yahoo.com

ÖĞRENİM DURUMU

Derece	**Alan**	**Okul/Üniversite**	**Mezuniyet Yılı**
Lisans	Bilgisayar Müh.	Maltepe Üniversitesi	2012

İŞ TECRÜBESİ

Yıl	**Firma/Kurum**	**Görevi**
2014 - …	Netaş	Yazılım Tasarım Müh.
2013 - 2014	Kuveyt Turk	Yazılım Destek Müh.
2010 - 2012	VBT	Yazılım Uzmanı

YAYINLARI

Proje

1. Yülap **EEG Sinyallerinin Beyin Makine Arayüzü Amaçlı Kullanılması**

2. Kap **P300 Tabanlı Karar Destek Sistemi Geliştirilmesi**