

T.C.
İNÖNÜ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

EEG SİNYALLERİ İLE CİHAZ KONTROLÜ

Harun ÇİĞ

YÜKSEK LİSANS TEZİ
BİLGİSAYAR MÜHENDİSLİĞİ DONANIM ANABİLİMDALI

AĞUSTOS 2017

MALATYA

Tezin Başlığı: EEG Sinyalleri İle Cihaz Kontrolü

Tezi Hazırlayan: Harun ÇİĞ

Sınav Tarihi: 11.08.2017

Yukarıda adı geçen tez jürimizce değerlendirilerek Bilgisayar Mühendisliği Ana Bilim Dalında Yüksek Lisans Tezi olarak kabul edilmiştir.

Sınav Jüri Üyeleri

Tez Danışmanı: Doç. Dr. Davut HANBAY

İnönü Üniversitesi

.....

Prof.Dr. Ali Karcı

İnönü Üniversitesi

.....

Yrd.Doç.Dr. Ömer Faruk ALÇİN

Bingöl Üniversitesi

.....

Prof. Dr. Halil İbrahim ADIGÜZEL

Enstitü Müdürü

ONUR SÖZÜ

Yüksek Lisans Tezi olarak sunduğum “EEG Sinyalleri ile Cihaz Kontrolü” başlıklı çalışmanın bilimsel ahlak ve geleneklere aykırı düşecek bir yardıma başvurmaksızın tarafımdan yazıldığını ve yararlandığım bütün kaynakların, hem metin içinde hem de kaynakçada yöntemine uygun biçimde gösterilenlerden oluştuğunu belirtir, bunu onurumla doğrularım.

Harun ÇİĞ



ÖZET

Yüksek Lisans Tezi

EEG SİNYALLERİ İLE CİHAZ KONTROLÜ

Harun Çiğ

İnönü Üniversitesi

Fen Bilimleri Enstitüsü

Bilgisayar Mühendisliği Donanım Ana Bilim Dalı

55 + xii sayfa

2017

Danışman: Doç. Dr. Davut Hanbay

Beyinde meydana gelen elektriksel aktivitelerin ölçülmesinde ve analiz edilmesinde sırasıyla Elektroansefalografi (EEG), Pozitron Emisyon Tomografisi (PET), Tek Foton Emisyonlu Bilgisayarlı Tomografi (TFEBT), Magnetoensefalografi (MEG) ve fonksiyonel Manyetik Rezonans Görüntüleme (fMRG) teknikleri kullanılmaktadır. Ancak maliyet, boyut ve vücuda zarar verme riski açısından en güvenilir beyin sinyali ölçme ve analiz tekniği EEG olarak kabul edilmiştir. EEG sinyalleri beyin aktivitesinin analiz edilmesinde kullanılan en temel yöntemlerden biridir. EEG beyinde meydana gelen elektriksel aktiviteyi değerlendirmek için bir test aracı olarak kullanılmaktadır. 1929'da Hans Berger tarafından ilk kez insan EEG'sinin tanıtılmasıyla beyin aktivitelerinin ölçümü yapılmıştır. Yüzyıla yakın bir süredir EEG tanı aracı olarak kullanılmaktadır. EEG Beyin-Bilgisayar Arayüzü (BBA) denilen sistemlerde de kullanılmıştır. Nörologlar, bir hastanın beyin dalgası aktivitesindeki şekillere tanı koyarak epilepsi, nöbet veya diğer nörolojik rahatsızlıklara neden olan anormalliklerin bulunmasını sağlamışlardır.

BBA'nın gelişmesiyle kısmi engelliler ve kas sisteminde sağlık problemlerine maruz kalan bireylerin yaşam kaliteleri artırılmıştır. Bu bireylerin özellikle de hareket kabiliyetlerini yitirmiş felçli hastaların hayata tutunma olanakları artırılmış ve onlara yardımcı olacak sistemler geliştirilmiştir. Günümüzde birçok bilim insanı bu konu üzerinde çalışmaktadır. EEG tabanlı BBA'ya ait birçok yöntem literatürde mevcuttur. Bu yöntemler arasında gerçek zamanlı BBA'larda çoklu sınıf ve doğruluk oranı göz önüne alındığında en çok kullanılan görsel uyaran tabanlı yöntemlerdir.

Bu tez çalışmasında Sabit Durum Görsel Uyaran Potansiyel (SDGUP) tabanlı EEG sinyal analizi gerçekleştirilmiş. Amaca uygun olarak bireyin ekran üzerinde belli frekanslarda titreşen sol (6,66 Hz), sağ (8.57 Hz) ve yukarı (12 Hz) olmak üzere üç farklı yönü gösteren şekillere bakması istenilmiştir. Birey ekran üzerindeki titreşen şekillere bakarken Emotiv Epoc+ cihazı ile EEG sinyalleri bilgisayar ortamına alınmış, OpenVibe ve Matlab yazılım platformunda bu sinyaller analiz edilip sinyal anlamlandırma işlemi gerçekleştirilmiştir. OpenVibe'da kişisel EEG sinyal verileri kullanılarak sistem ağı eğitilmiştir. Daha sonra eğitilen bu ağı kullanılarak gerçek zamanlı EEG sinyalleri ile sistem online olarak test edilmiştir.

Matlab yazılım ortamına alınan EEG sinyalleri ise bant geçirgen filtreden geçirilmiş daha sonra Hilbert ve Kısa Zamanlı Fourier Dönüşüm işlemlerine tabi tutulmuştur. Deneğin baktığı farklı frekanstaki her şekil için görsel olarak uyarıldığı Oksipital bölgede SDGUP cevabı bulma işlemi yapılmıştır. SDGUP cevabı tespit edildikten sonra eğitim için Multimedia Authoring and Management using your Eyes and Mind (MAMEM) kuruluşu tarafından Emotiv Epoc+ cihazı ile on bir denekten toplanmış veri Yapay Sinir Ağları (YSA) ve Destek Vektör Makinaları (DVM) ile eğitim için kullanılmıştır. Eğitilen sınıflandırıcı ağını test için Emotiv Epoc+ cihazı ile kişisel EEG verileri kullanılmıştır. Bu şekilde bireyin ekran üzerinde hangi yöne baktığı beyin sinyalleri kullanılarak tespit edilmiş ve Lego Mindstorm EV3 robotu bu yönlere göre hareketi sağlanarak kontrol edilmiştir. Sonuçların başarılı bir şekilde test edilmesi gelecekte nano teknolojiler ve mobil cihazlar ile sistem bütünleştirilerek EEG tabanlı BBA çalışmalarında cihaz kontrolünün çok daha hassas, hızlı ve başarılı olacağı hakkında ümit vermektedir.

Bu tez çalışması, İnönü Üniversitesi Bilimsel Araştırma Projeleri Koordinasyon Birimi Tarafından 2016/29 numaralı ve “EEG Sinyalleri ile Cihaz Kontrolü” başlıklı proje olarak desteklenmiştir.

ANAHTAR KELİMELELER: SDGUP, Beyin Bilgisayar Arayüzü, Kısa Zamanlı Fourier Dönüşümü, Hilbert Dönüşümü, EEG, Yapay Sinir Ağları, Sınıflandırma, DVM



ABSTRACT

Master Thesis

DEVICE CONTROL WITH EEG SIGNALS

Harun ÇİĞ

Inonu University

Graduate School of Natural and Applied Sciences

Department of Computer Engineering

55 + xii page

2017

Supervisor: Asst. Prof. Davut Hanbay

Electroencephalography (EEG), Positron Emission Tomography (PET), Single Photon Emission Computed Tomography (TPEBT), Magnetoencephalography (MEG) and Functional Magnetic Resonance Imaging (fMRI) techniques are used in the measurement and analysis of electrical activities in the brain. However, the most reliable brain signal measurement and analysis technique has been accepted as EEG in terms of cost, size and risk of damage to the body. EEG signals are one of the most basic methods used to analyze brain activity. EEG is used as a test tool to evaluate the electrical activity in the brain.

In 1929, for the first time by Hans Berger, brain activities were measured by introducing human EEG. Nearly a century ago, EEG was used as a diagnostic tool. It was also used in systems called Brain-Computer Interface (BBA). Neurologists have been able to diagnose the shape of a patient's brain wave activity and have found abnormalities that lead to epilepsy, seizures or other neurological disorders.

With the development of the BBA, the quality of life of individuals with partial disabilities and health problems in the musculoskeletal system has been

increased. Patients with paralysis, especially those who have lost their mobility, have increased the possibilities of survival and have developed systems to assist them. Today, many scientists are working on this subject. Many methods of EEG-based BBA are available in the literature. These methods are the most commonly used visual stimulus based methods when multiple classes and accuracy rates are considered in real-time BBAs.

In this thesis, Steady State Visually Evoked Potential(SSVEP) based EEG signal analysis was performed. In accordance with the aim, the individual is asked to look at three different directions on the screen, left (6.66 Hz), right (8.57 Hz) and up (12 Hz), which oscillate at certain frequencies. When looking at the flickering shapes on the screen, the EEG signals were received with the Emotiv Epoc + device and the signals were analyzed and signals were analyzed in OpenVibe and Matlab software platform. OpenVibe also trained the system network using personal EEG signaling. Then, this network was trained and the system was tested online with real-time EEG signals.

The EEG signals received in the Matlab software platform were passed through a bandpass filter and then subjected to Hilbert and Short Time Fourier Transform operations. Visually stimulated in the occipital region the SSVEP response was made to find out for every shape that Subject look at in different frekans. After the SSVEP response was detected, data collected from eleven subjects by Emotiv Epoc+ device by Multimedia Authoring and Management using your Eyes and Mind (MAMEM) organization for training were used for training with Artificial Neural Networks (ANN) and Support Vector Machines (SVM). Emotiv Epoc+ device and personal EEG data were used to test the trained classifier network. In this way, the direction in which the individual looked on the screen was determined using brain signals, and the Lego Mindstorm EV3 robot was controlled according to these directions. Successful testing of the results is expected in the future to integrate the system with nanotechnologies and mobile devices, which will make the device control in EEG based BBA workings much more precise, faster and more successful.

This thesis is supported by Inonu University Scientific Research Projects Coordination Unit as project number 2016/29 entitled "Device Control with EEG Signals".

KEYWORDS: SSVEP, Brain Computer Interface, Short Time Fourier Transform, Hilbert Transform, EEG, Artificial Neural Networks, Classification, SVM



TEŞEKKÜR

Yüksek Lisans Tezi çalışmamda önerileri ve yönlendirmeleri ile akademik gelişmeye büyük katkı sağlayan, bana değerli zamanını ayıran danışman hocam Sayın Doç. Dr. Davut Hanbay'a;

Tez çalışmamda yönlendirme ve bilgilendirmeleriyle çalışmamı bilimsel temeller ışığında şekillendiren sayın hocam Doç. Dr. M.Emin Tağluk'a;

Tez çalışmamın test aşamasında önerdiği metodolojiyle yardımlarını esirgemeyen Arş. Gör. Dr. Nuh Alpaslan'a;

Tez çalışmamda robotik konusunda bana sunduğu teorik katkılarından dolayı Uzman Emrah Dönmez'e

Teşekkür ederim.

İÇİNDEKİLER

ÖZET	i
ABSTRACT	iv
TEŞEKKÜR	vii
İÇİNDEKİLER	viii
ŞEKİLLER DİZİNİ	x
ÇİZELGELER DİZİNİ	xi
SİMGELER VE KISALTMALAR	xii
1. GİRİŞ	1
1.1. Literatür Taraması ve Değerlendirilmesi	1
1.2. Tez Çalışmasının Amaç ve Kapsamı	3
1.3. Tezin Organizasyonu	4
2. BEYİN SİNYALLERİ ve GÖRÜNTÜLEME TEKNİKLERİ	5
2.1. Elektroansefalografi	5
2.1.1. EEG Frekans Bantları	6
2.1.2. EEG 10-20 Sistemi	7
2.2. ECoG	9
2.3. Fonksiyonel Manyetik Rezonans Görüntüleme	9
3. BEYİN BİLGİSAYAR ARAYÜZÜ	11
3.1. BBA Sistemlerinde Kullanılan Metotlar	11
3.1.1. Olayla İlişkili Potansiyeller	12
3.1.2. P300	12
3.1.3. Sabit Durum Görsel Uyarın Potansiyeller	14
3.1.4. Yavaş Kortikal Potansiyel	15
3.2. BBA’da Kullanılan Sınıflandırıcılar	16
3.2.1. Destek Vektör Makine Sınıflandırıcıları	16
3.2.2. K- En yakın Komşu (Nearest Neighbor) Sınıflandırıcı	19
3.2.3. Yapay Sinir Ağı Sınıflandırıcı	20
4. YAPILAN ÇALIŞMADA KULLANILAN SİNYAL İŞLEME TEKNİKLERİ	23
4.1. Kısa Zamanlı Fourier Dönüşümü	23
4.2. Hilbert Dönüşümü	25
4.3. Ampirik Mod Ayırıştırma	26
4.4. EEG Sinyali Gürültü Temizleme	27
4.4.1. Filtreleme	28
4.5. Öznitelik Çıkarma	30
5. UYGULAMA	33

5.1.	Emotiv	33
5.1.1.	Matlab_emotiv	35
5.1.2.	OpenVibe ile Emotiv Epoc+	35
5.2.	Lego Mindstorms Ev3 Robotu	43
6.	SONUÇLAR	45
	KAYNAKLAR	49
	ÖZGEÇMİŞ.....	56



ŞEKİLLER DİZİNİ

Şekil 2-1 EEG10-20 Sistemi.....	8
Şekil 2-2 ECoG Sinyal edinimi	9
Şekil 3-1 SDGUP Tabanlı BBA	12
Şekil 3-2 Beynin Üç Bölgesinde P300 Sinyali	13
Şekil 3-3 SDGUP Tabanlı BBA	15
Şekil 3-4 Destek Vektör Makineleri	17
Şekil 3-5 K-En Yakın Komşular Kümesi	19
Şekil 3-6 Yapay Sinir Ağları	21
Şekil 3-7 Çok Katmanlı İleri Beslemeli Ağlar	22
Şekil 4-1 Güç Spektrogram Yoğunluğu Analizi.....	24
Şekil 4-2 Hilbert Analitik Sinyal	26
Şekil 4-3 Bant Geçirgen Filtre Tasarımı.....	29
Şekil 4-4 Giriş Sinyalinin Genlik, Birim Dürtü Cevabı	30
Şekil 5-1 Emotiv Epoc + 14 Kanal	33
Şekil 5-2 Emotiv Sınıf Bağlantı Diyagramı.....	34
Şekil 5-3 OpenVibe Emotiv Epoc+ Bağlatı Ayarları	36
Şekil 5-4 OpenVibe- Emotiv Sinyal Edinimi Anlık Görüntüleme.....	37
Şekil 5-5 OpenVibe Sinyal Edinimi Konfigürasyon Ayarları.....	38
Şekil 5-6 OpenVibe Sinyal Edinimi SDGUP Ağ Eğitimi	39
Şekil 5-7 Farklı Frekanslarda Titreşen Kutular	40
Şekil 5-8 OpenVibe OAÖ Filtresi	41
Şekil 5-9 OpenVibe Sınıflandırıcı Eğitici.....	42
Şekil 5-10 BBA Online Test Ateş Etme Oyunu	43
Şekil 5-11 Lego Mindstorms EV3.....	44
Şekil 6-1 YSA Sınıflandırma ROC grafiği.....	47
Şekil 6-2 SDGUP tabanlı Mobil Robot Kontrol Akış Şeması.....	48

ÇİZELGELER DİZİNİ

Çizelge 1 EEG Sinyal Bantları	6
Çizelge 2 Beyin Loblarının İsimlendirilmesi	8
Çizelge 3 OpenVibe’da Oluşturulan 1.Data setin Sınıflandırma Test Sonuçları ..	45
Çizelge 4 OpenVibe’da Oluşturulan 2.Data setin Sınıflandırma Test Sonuçları ..	46



SİMGELER VE KISALTMALAR

AMA	Ampirik Mod Ayrıştırma
BBA	Beyin Bilgisayar Arayüzü
BPA	Bağımsız Parça Analizi
EEG	Elektroansefalografi
SSVEP	Steady-State Visual Evoked Potentials
SDGUP	Sabit Durum Görsel Uyarılmış Potansiyel
DVM	Destek Vektör Makineleri
YSA	Yapay Sinir Ağları
OAÖ	Ortak Alansal Örüntü
HD	Hilbert Dönüşümü
HFD	Hızlı Fourier Dönüşümü
KZFD	Kısa Zamanlı Fourier Dönüşümü
TFEBT	Tek Foton Emisyonlu Bilgisayarlı Tomografi

1. GİRİŞ

Teknolojinin gelişmesi ile günümüzde insanlar makinalarla iletişim kurmak için en kolay yolu ve yapılan işe göre kullanım uygunluğu daha iyi olanı tercih ediyorlar. İlk zamanlarda büyük boyutlu cihazlarla sadece kablolar ile bağla, komut yükle, çıkar gibi teknikler ile iletişim kurulurken günümüzde ses komutları, kas sinyalleri, göz hareketleri hatta beyin sinyalleri komutu vasıtasıyla kablosuz bir şekilde bilgisayarlı cihazlar ile iletişim kurulmaktadır. Bunun için klavyeler, fareler, dokunmaya duyarlı yüzeyler, özel eldivenler ve mikrofonlar gibi çeşitli araçlardan faydalanılır. Bu komut verme araçlarının bütünü kullanıcının beden fonksiyonlarının belli bir kısmını kontrol edebildiği varsayımına dayanır. Ancak durum her zaman böyle değildir. Söz gelimi motor nöron hastalıklarında bu sistem bozulur ve bundan sonra hasta ile iletişim genellikle Beyin Bilgisayar Arayüzü (BBA) sistemi ile devam ettirilebilir. Beyin sinyallerinin elde edilmesi ve anlam çıkarılması araştırma laboratuvarları ve hastane acil servislerinde kullanılan bir teknoloji iken, artık yeni nesil portatif EEG başlıklarıyla ve BBA programları ile bisiklet kaskları gibi basit ekipmanlar dahil her alanda yaygın olarak kullanılabilecek duruma gelmiştir.

1.1. Literatür Taraması ve Değerlendirilmesi

İnsan beyni 100 milyardan fazla nöronun karmaşık ağlarından oluşur. Beyindeki sinirsel bağlantılar kümesine bilim insanlarının ilgisi giderek artmaktadır [1]. Beyin işlevleri ve performansındaki bireysel farklılıkların arka planını incelemek için bu sinir bağlantılarındaki bireysel farklılıkların belirlenmesi önemlidir. EEG sinyallerinin temelde genlik, frekans ve bazen de faz yapısına dayalı olarak ortaya konan avantajları dikkate alınarak karakteristik özellikleri çıkarılır. EEG sinyallerinden öznitelikleri çıkarmak için çeşitli yöntemler geliştirilmiştir. Geliştirilen yöntemler arasında Zaman-Frekans (Z-F) tabanlı olanların daha başarılı olduğu tespit edilmiştir. Z-F tabanlı yöntemler, durağan olmayan sinyalleri zaman frekans alanı üzerindeki 2 boyutlu bir görüntüye dönüştürerek sinyallerin olası tüm özelliklerini açığa çıkarır [2].

EEG sinyalleri, Z-F alanında gösterilen bu görüntülerden istatistiksel veya dokusal bazı genel ve yerel özellikler çıkarılarak bu amaç için tasarlanmış herhangi bir sınıflandırıcı aracılığıyla sınıflandırılır [2].

SDGUP, denek belli frekansta titreşen bir uyarıya dikkat ettiğinde titreşim frekansı ile aynı frekansta Oksipital bölgede kafa derisi üzerindeki harmoniklerinde ortaya çıkan periyodik bir beyin aktivitesidir [3]. Beynin nöronal aktivitelerinin frekans tepki fonksiyonunu test etmek için SDGUP kullanılabilir. Ancak oküler motor bozuklukları veya ciddi nöromusküler problemleri olan hastalar için SDGUP tabanlı BBA kullanılamayabilir[4]. Göz retinası belirli bir frekansta bir uyarıcı tarafından uyarıldığında, beyin; bu frekansın katları veya harmonikleri ile aynı frekansta bir elektriksel aktivite üretir [4]. Bu uyarıcı küçük genlikte sabit bir Görsel Uyarılmış Potansiyel üretir. SDGUP' ler kullanıcının bakış yönüne de bağlıdır ve dolayısıyla kas kontrolünü gerektirir. Bu tür potansiyelleri üretmek için, kullanıcı belli bir frekansta salınım yapan titreşen bir uyarıcıya bakar[5]. Regan'a göre sabit yoğunluklu farklı frekanstaki titreşim bir uyarı, düşük (5-12 Hz), orta (12-25 Hz) ve yüksek (25-50 Hz) frekanstaki veya daha da yüksek frekans bantları ayrı ayrı sinyallerle SDGUP'leri tetikleyebilir [6].

BBA beyin faaliyetlerini doğrudan bilgisayar kontrol sinyallerine çeviren bir iletişim ve kontrol yoludur [7]. BBA sistemleri beyin sinyal analizinde matematiksel yöntemlerin geliştirilmesi için kullanışlı bir test alanı sunar[8]. BBA'lar son yıllarda SDGUP ile tasarlanmıştır. Olaya bağlı potansiyel veya sensorimotor ritim EEG ile kaydedilmiştir [9]. Görsel uyarılmış potansiyellerin saptanmasındaki iyileştirmeler Güç Spektrum Yoğunluk Analizi (GSYA) olarak bilinen Fourier güç spektrumu ile çok boyutlu analiz edilerek önemli gelişmeler kaydedilmiştir [10, 11].

Doğrusal ve durağan olmayan bir sinyalden zaman-frekans bilgisi çıkarmak için Ampirik Mod Ayırıştırması (AMA) ve Hilbert Dönüşümü (HD), sinyal analiz metodu olarak, Huang ve arkadaşları tarafından uygulamaya koyulmuştur [12]. Bu metot Hızlı Fourier Dönüşümü (HFD)'nden sonra önemli bir gelişme olarak görülmüştür. 2007'den beri, simüle edilmiş uyarı sinyallerin (şablonlar) kullanılması SDGUP'lerin tanımlanmasında etkili olmuştur ve standart öznelite çıkarma, eşik değeri ya da karar ağaçları kullanımına göre daha yüksek performans elde edilmiştir [13].

2014'te Zhang ve arkadaşları Multivariate Synchronization Index (MSI) adlı yeni bir yöntem geliştirdi [10]. MSI, uyarıcı frekansını tanımak için bir potansiyel indeks olarak karışık sinyaller ve referans sinyaller arasındaki mevcut senkronizasyonu tahmin eden bir tekniktir.

SDGUP tabanlı BBA, Kısa Zamanlı Fourier Dönüşümü (KZFD) ile GSYA kullanılıp SDGUP'i tanıyarak, denekten kaydedilen EEG sinyallerinin bilgisayar

komutlarına dönüştürülmesi için geliştirilmiştir. Sıradan bir SDGUP tabanlı BBA'da, kullanıcılara farklı frekanslarda yanıp sönen birkaç uyarı sunulmakta ve denekten bakış yönünü ve dikkatini uyarana vermesi istenmektedir. Bu tür SDGUP tabanlı BBA'lar genelde "bağımlı" olarak adlandırılır. Çünkü kas aktivitelerinden sayılan göz hareketlerinin farklı yönlerde değiştirilmesi istenmektedir [14]. Bununla birlikte "bağımsız" SDGUP tabanlı BBA'lar da vardır. Bunlar başın nöromusküler kontrolü veya göz hareketlerini yerine getiremeyen kişilerin dikkatleri tarafından kontrol edilir. Bu dikkatin gizli şekilde olduğu anlamına gelir. Bu tür SDGUP tabanlı BBA'lar da genelde "bağımsız" olarak adlandırılır.

Denek dikkatinin belirgin renklerde iki nokta kümesinden birine gizli kaydırılmasında SDGUP genlik ve faz tepkisinin modülasyon etkileri, Zhang ve arkadaşları tarafından araştırılmıştır [14]. Görsel dikkat çoğunlukla göz hareketleri aracılığıyla kontrol edilir ve dikkat edilen nesneler genellikle nettir, belirsiz değildir.

Robotun görev seçim kontrolü, SDGUP ile üç farklı frekansta salınım yapan uyarın kullanılarak bir Beyin Bilgisayar Arayüzü aracılığıyla gerçekleştirilir. EEG sinyal edinim sistemi ile kullanıcıların saçlı kafa derisi üzerinden beyin sinyalleri ölçülür. Ölçülen EEG sinyalleri işlenir YSA, DVM ve K-En Yakın Komşular tabanlı bir sistem ile sınıflandırma işlemi gerçekleştirilir. BBA çıktıları ile cihaz hareket yönleri kontrol edilir.

Kullanıcı, cihaz hareketlerini izleyerek sistemin kararlarını gerçek zamanlı olarak görebiliyor. Bu davranış, gönüllü için geribildirim olarak kullanılır.

1.2. Tez Çalışmasının Amaç ve Kapsamı

Dünya üzerinde çevresiyle iletişim kuramayan, kurmakta zorlanan veya kendi ihtiyacını kendisi göremeyen başta felçli hastalar, kısmi engelliler ve yaşlılar olmak üzere birçok hasta/birey bulunmaktadır. Bu bireylerin çevreleriyle iletişim kurabilmeleri ve kişisel bazı temel ihtiyaçlarını kendilerinin görebilmeleri hem bu bireylere hem de aile ve yakınlarına önemli derecede rahatlık sağlayacaktır.

Bu tez çalışmasında gerçek-zamanlı beyin EEG sinyalleri bilgisayar ortamında işlenerek Lego Mindstorms EV3 robot hareket kontrolü amaçlanmıştır. Kullanıcıya ekran üzerinde belli frekanslarda titreşen sağ, sol ve ileri olmak üzere 3 farklı yönü gösteren kutu şekillerine bakması istenilmiştir. Kullanıcı ekrana bakarken beyin

oksipital bölgesinde meydana gelen beyin aktiviteleri incelenmiş ve alınan beyin sinyallerinde SDGUP cevabı bulma işlemi yapılmıştır. Bu şekilde bireyin hangi yöne baktığı beyin sinyalleri kullanılarak tespit edilmiş ve Lego Mindstorms EV3 robot hareketi bakılan yönler göre kontrol edilmiştir.

EEG analiz parametreleri arasında bulunan beyin sinyali ile cihaz kontrolü için literatürde geçen birçok çalışma yapılmıştır. Bu çalışmalarda efektif yöntemler araştırılmış ve beyin sinyal kümesi sınıflandırılmalarında belirli başarımlar yüzdelere ulaşılmıştır.

1.3. Tezin Organizasyonu

Tez çalışması altı bölümden oluşmaktadır.

Birinci bölümde tez çalışmasının amaç ve kapsamından bahsedilmiş ve literatür taraması ve değerlendirilme çalışmaları sunulmuştur. İkinci bölümde beyin sinyalleri ve görüntüleme teknikleri hakkında detaylı bilgilere yer verilmiştir. Üçüncü bölümde BBA sisteminden bahsedilmiş ve BBA içerisinde kullanılan sınıflandırıcılar anlatılmıştır. Dördüncü bölümde EEG beyin sinyal analizi ile ilgili bilgilere yer verilmiştir ve tezin uygulama aşamasında kullanılan sinyal işleme tekniklerine ait metotlardan sırasıyla bahsedilmiştir. Beşinci bölümde tez kapsamında yapılan uygulamadan ve uygulamada kullanılan yazılım ve donanımın özelliklerinden bahsedilmiştir. Bunun yanı sıra yapılan çalışmanın sistem tasarımı ve yapılan uygulamanın çalışma mantığı anlatılmıştır. Son bölümde ise elde edilen sonuçlar sunulmuştur.

2. BEYİN SİNYALLERİ ve GÖRÜNTÜLEME TEKNİKLERİ

Beyin sinyallerinin incelenmesinde EEG, PET, TFEBT, MEG ve son olarak fMRG teknikleri kullanılmaktadır. Bu yöntemler çoğunlukla beyin işlevleri hakkında doğrudan veya dolaylı bilgi sağlayıp sağlamadığına göre kategorize edilir. Doğrudan yöntemler; her biri beyin elektromanyetik aktivitesinin doğrudan sonucunu izleyen MEG, EEG, olay tetiklemeli EEG ve Olaya İlişkin Potansiyelleri (OİP) içerir. EEG ve OİP, nöronal aktivite tarafından üretilen elektrik alanlarını kaydederken, MEG bu tür aktiviteler tarafından uyarılan manyetik alanları kaydeder. Manyetoensefalografi, serebral nöronların popülasyonları tarafından uyarılan küçük manyetik alan dalgalanmalarını ölçmek için kullanılan invaziv olmayan bir tekniktir. MEG'in zamansal çözünürlüğü EEG'nin çözünürlüğü ile kıyaslanabilir [15].

PET, TFEBT ve fMRG dolaylı yöntemlerdir. Bunlar genellikle beyin elektriksel aktivitesinden kaynaklanan hemodinamik değişiklikleri izlerler. PET ve TFEBT beyin görüntüleme, kan yoluyla taşınan radyoaktif izotopların beyinden geçerken çürümesini izler. fMRG ise dayatılan manyetik alanlar üzerindeki etkisiyle deoksihemoglobinin lokal konsantrasyonundaki değişiklikleri tespit eder [16]. Bu teknikler kendine özgü dezavantajlara da sahip olabilirler.

MEG, PET ve fMRG hala teknik açıdan zorlayıcı ve pahalıdır. Ayrıca, kan akışına bağlı PET ve fMRG uzun zaman sabitlerine sahiptir bu nedenle hızlı iletişim için uygun değildir [17].

Doğrudan yöntemler mekansal çözünürlük açısından sınırlı olma eğilimindedir. Dolaylı yöntemler ise yalnızca kompleks ve anlaşılabilirliği zayıf bir nörovasküler bağlantı fonksiyonuyla filtrelendikten sonra nöronal aktiviteyi saptayabilir.

2.1. Elektroansefalografi

Karmaşık bir yapıya sahip olan EEG sinyali, beyin fonksiyonlarını ve nörolojik bozuklukları incelemek için kullanılan en yaygın bilgi kaynaklarından biridir [18].

EEG, çevrimiçi uygulamalar için zamansal çözünürlük açısından yüksek bir değere sahiptir. Mekânsal çözünürlüğü baş dokusunun bulanıklaştırma etkisi nedeniyle düşüktür. Ayrıca, ölçülen EEG sinyali, elektrotların hareketi, göz kırpması veya kas aktivitesinden kaynaklanan artefaktlar içerebilir. Bunlar pratik kullanım

açısından bir dezavantajdır. Fakat EEG, düşük maliyet, düşük risk, düşük yan etki ve taşınabilirlik nedeniyle BBA çalışmalarının çoğunda kullanılır [15].

Bu sinyallerin içerdiği bilgiler kullanılarak kas aktivitesini kullanamayan ve temel ihtiyaçlarını karşılama sıkıntısı çeken bireyler için BBA ile robot, araba ve makine gibi cihazlar kontrol edilerek hayatlarını kolaylaştıracak EEG tabanlı çalışmalar yapılmaktadır.

2.1.1. EEG Frekans Bantları

EEG sinyalleri farklı frekans bantlarına ayrılmıştır. Çizelge 1’de EEG sinyallerinin farklı frekans bantlarındaki değerleri verilmiştir.

Çizelge 1 EEG Sinyal Bantları

Bant İsmi	Bant Frekans Aralığı (Hz)
Delta (δ)	0.5-3.5
Teta (θ)	4-7
Alfa-I(α -I)	8-9
Alfa-II(α -II)	10-12
Beta-I(β -I)	13-17
Beta-II(β -II)	18-30
Gamma-I (γ -I)	31-40
Gamma-II (γ -II)	41-50

Genelde delta, teta, alfa, beta ve gama ile tanımlanan EEG dalga boyları biyomedikal, sağlık ve mühendislik gibi birçok alanda kullanılmaktadır. Dalga çeşitleri aşağıdaki gibi açıklanmıştır:

Delta dalgaları: Bu yavaş dalgalar 3.5 Hz veya daha düşük frekansa sahiptir. Normalde yetişkinlerde derin uykuda olduğu gibi bebekler ve çocuklar da görülürler. Çoğu zaman, tüm dalgaların en büyük genliklerine sahiptirler.

Teta dalgaları: Teta dalgaları her yaşta uyku evresinde görülür. 4-7 Hz arasında frekans değerlerine sahip EEG dalgalarıdır. Bu dalga frekans aktivitesi genelde

parietal ve temporal bölgelerde görülür. Uyanık yetişkinlerde, aşırı dalgalanmalar görülürse bu durum anormaldir [19]. Teta ve delta dalgaları genelde yavaş dalgalar olarak bilinir.

Alfa dalgaları: Alfa dalgaları genel olarak tüm yaş gruplarında görülmesine rağmen yetişkinlerde daha yaygın görülür. Bu dalgalar 8-12 Hz arasında frekansa sahip EEG dalgalarıdır. Uyanık, normal ve sakin durumlarda görülür. Alfa aktivitesi bir dikkat odaklanma söz konusu olduğunda kaybolur. Çoğu durumda normal bir dalga şekli olarak kabul edilir. Başın her iki tarafında ritmik olarak ortaya çıkarlar. Kafanın arka (posterior) bölgelerinde bir alfa frekans harmoniği oluştuğunda normal bir alfa varyantı görülür. Posteriora var olma eğilimi anterior (ön bölge)'dan daha fazladır.


Beta dalgaları: Beta dalgaları tüm yaş gruplarında görülür. 12-22 Hz arasında frekans değerlerine sahip EEG dalgalarıdır. Genlik açısından bakıldığında küçük olma eğilimi gösterirler. Beta dalgaları genellikle simetriktir ve beyin anterior bölgesinde daha belirgin görülürler. Beta-I (BI) ve Beta-II (BII) olarak iki ayrı durumda incelenir. BII işaretleri BI işaretlerinin yaklaşık olarak iki kat frekans bant değerine sahiptir. Sinir sisteminin zorlanması, kasılması ve gerginliği artıran durumlarda belirgin hale gelir [20].

Gamma dalgaları: Gamma dalgaları genellikle 30 Hz veya daha yüksek frekanslara sahiptir. Bu dalgaların frekansı (40 Hz-70 Hz) son derece hızlıdır. Bu beyin dalgaları, esasen nöronal devrenin kurulmasıyla bilinçli dikkatin içine girer. Bunlar, en hızlı beyin dalgalarıdır ve farklı beyin bölgelerindeki bilgilerin eşzamanlı olarak işlenmesiyle ilişkilidir. Genellikle çalışma bellek uyumu ve genişletilmiş bilinç ve aynı zamanda hipnoz halleri sırasında bulunurlar [21].

2.1.2. EEG 10-20 Sistemi

Uluslararası 10/20 sistemi kafa derisi elektrotlarının lokasyonlarını belirlemek için uluslararası kabul görmüş sistemdir.

Şekil 2-1'de gösterilen bu sistem elektrotun yeri ile Serebral korteksin altında yatan alan arasındaki ilişki tabanlıdır. '10' ve '20' numaraları, komşu elektrotlar arasındaki mesafenin kafatasının ön-arka veya sağ-sol toplam mesafesinin %10'u veya % 20'si olarak kabul görülmesine dayanmaktadır.



Şekil 2-1 EEG10-20 Sistemi


Elektrotların konumlandırılması için dört anatomik yer işareti kullanılır: önce alın ile burun arasındaki nokta olan nasion; sonra, başın arkasından kafatasının en alt noktasına kadar olan ve normal olarak belirgin bir yumru ile gösterilen inion; kulak öncesi ve kulak iliği noktaları olmak üzere konumlandırılmıştır. Mevcut 10/20 sistemi arasındaki boşlukları kullanarak ekstra pozisyonlar da eklenebilir [22, 23]. Çizelge 2’de beyindeki lokasyonları bilinen elektrot isimleri verilmiştir.

Çizelge 2 Beyin Loblarının İsimlendirilmesi

Elektrot	Beyin Lobu
F	Frontal
T	Temporal
C	Central
P	Parietal
O	Oksipital

2.2. ECoG

BBA araştırmasında kullanılan diğer bir sinyal toplama tekniği de Elektrokortikografi (ECoG) dur. Şekil 2-2’de gösterildiği gibi beyin sinyalleri, kafatasının içine cerrahi olarak yerleştirilen elektrotların yardımı ile ölçülür [24]. Bu teknik EEG’ye kıyasla daha yüksek sinyal-netlik oranına ve daha yüksek mekansal çözünürlüğe sahiptir.



Şekil 2-2 ECoG Sinyal edinimi

ECoG BBA dâhil olmak üzere beyin araştırmalarında önemli rol oynamaktadırlar [25], [26]. Fakat uygulanan cerrahi operasyonun riski nedeniyle yaygın değildirler.

2.3. Fonksiyonel Manyetik Rezonans Görüntüleme

Fonksiyonel bağlantının fMRG özellikle istirahat hali dönemlerinde değerlendirilmesi, beynin makro ölçekte spatiotemporal organizasyonu hakkında çok miktarda bilgi ortaya çıkarmıştır [27].

Gerçek zamanlı fMRG'ye dayanan bir beyin-bilgisayar ara yüzü; deneklerin kendi kan oksijen seviyelerine bağlı tepkilerini izlemelerine ve kontrol etmelerine olanak tanır [28].

FMRG cihazı büyük, taşınabilirliği olmayan ve maliyeti yüksek olması sebebiyle beyin bilgisayar arayüzü için kullanışlı değildir. Ancak bazı bilimsel çalışmalarda güvenilir veri toplamak için kullanılır.

Dinlenme durumundaki fMRG çalışmaları, Alzheimer hastalığı, şizofreni, otizm, dikkat eksikliği hiperaktivite bozukluğu, epilepsi, kronik ağrı ve daha fazlasını içeren geniş bir patoloji yelpazesıyla ilişkili fonksiyonel değişiklikleri değerlendirmek için de kullanılır [29].



3. BEYİN BİLGİSAYAR ARAYÜZÜ

BBA beyin sinyal okuyucusu aracılığı ile okunan beyin sinyallerinin bir bilgisayar yardımıyla işlenip nöromüsküler tabanlı sistemler kullanılmadan harici bir cihazın kontrol edilmesine olanak sağlayan bir platformdur [17].


BBA beyin sinyallerini dış dünya ile etkileşim kurulmasını sağlayan kontrol sinyallerine dönüştüren sistemlerdir [30]. BBA, Felçli hastalar için yoğun fizyoterapiden önce robotik terapi ile birleştirildiğinde önemli klinik avantajlar gözlemlenmiştir [31] .

BBA sistemi, kişinin devam etmekte olan beyin aktivitesine bağlı olarak gerekli hareketi algılar ve ilgili sistemleri tetikler, çeşitli sinyal işleme teknikleri ile anlamlı kontrol komutlarına dönüştürür [32].

3.1. BBA Sistemlerinde Kullanılan Metotlar

BBA sistemlerinde EEG sinyali değerlendirmelerinde sensorimotor aktivite, P300, Görsel Uyarılmış Potansiyeller, Yavaş Kortikal Potansiyeller (YKP) ve sinir hücresi aktivitesi özellikleri ve bu özelliklerin kombinasyonları ile elde edilen yöntemler kullanılır [33].

BBA'nın temel öğeleri ve çalışması Şekil 3-1'de verilmektedir. Bu öğeler, bu bölümde detaylı olarak analiz edilecektir. İlk aşamada, BBA uygulamalarında kullanılan sinyal toplama teknikleri hakkında bilgi verilecektir.



Şekil 3-1 SDGUP Tabanlı BBA

3.1.1. Olayla İlişkili Potansiyeller


Olayla İlgili Potansiyeller(OİP) duysal, bilişsel ve motor olaylarla senkronize edilen uyarılmış beyin yanıtlarıdır. Diğer bir ifadeyle bir iç veya dış uyarının işlenmesinden kaynaklanan elektrofizyolojik yanıtıdır. BBA uygulamalarında yaygın olarak kullanılan uyarılmış yanıtlar P300, SDGUP ve YKP dir. Bu yanıtlar bir uyarana denegin verdiği geri dönüş tepkisidir.

3.1.2. P300

P300 bileşeni, sinyalin genliği ve gecikmesi hesaplanarak ölçülür. Genlik (μV), ortalama ön uyarı taban çizgisi voltajı ile bir zaman penceresi içindeki OİP dalga formunun en büyük pozitif gidiş pik değeri arasındaki fark olarak tanımlanır.

Gecikme (ms), uyarı başlangıcından maksimum pozitif genlik noktasına bir zaman penceresi içindeki zaman olarak tanımlanır. P300'ün saç derisi üzerindeki dağılımı, tipik olarak frontal ve parietal elektrot lokasyon bölgeleri ile orta hat elektrotlarındaki (Fz, Cz, Pz) sinyalde artan genlik değişikliği olarak ifade edilir[34].

OİP'lerin bilişsel araştırma ve klinik değerlendirmeler için en yaygın kullanılan bileşeni P300 yanıtıdır. Sutton ve arkadaşları tarafından tarif edilen P300 deneysel olarak nispeten büyük genlik ve kolay belirlenme nedeniyle, dikkat tespiti ve bilgi işlem araştırmalarında en çok çalışılan OİP bileşenidir [35]. Şekil 3-2'de beyin üç bölgesinde P300 sinyali gösterilmiştir. Frontal-Central bölgede, sinyal edinimi başladıktan yaklaşık 300 ms sonra zirve yapan P300, durdurma sinyali görevindeki yanıt engelleme işlemi ile ilişkilendirilmiştir [36]. Bununla birlikte, mevcut BBA uygulamalarının çoğunun üç temel elektrofizyolojik kaynağı vardır: bunlar P300 potansiyeli, motor görüntüleri ve sabit durum görsel uyarılmış potansiyellerdir.




Şekil 3-2 Beynin Üç Bölgesinde P300 Sinyali

3.1.3. Sabit Durum Görsel Uyarın Potansiyeller

Sabit durum görsel uyarılmış potansiyel tabanlı BBA'lar, her biri benzersiz frekanslarda titreşen birkaç sabit osilasyonlu ışık kaynağı (örn. Titreşen LED'ler) kullanır. SDGUP, belirli frekanslarda sürekli titreşen ışık kaynağına bakılması ile görsel uyarılma altında beynin oksipital ve parietal kortikal bölgelerinde belirli sabit bir frekansta ortaya çıkan sürekli beyin yanıtlarıdır. Bir kişi bu ışıklardan birine baktığında veya ona dikkat ettiğinde, oksipital lobdaki EEG etkinliği ile ilgili frekans gücünde bir artış meydana gelir.

SDGUP'ler önışleme, artefakt tespiti, öznitelik çıkarma ve sınıflandırması gibi sinyal işleme teknikleri ile otomatik olarak algılanabilir. Şekil 3-3'de gösterilen sürekli titreşen görsel uyarılardan oluşan şekil grubu içerisinde odaklanılan hedef, beyin sinyallerine karşılık gelen frekans ile modüle edilir. Bu sinyaller daha sonra invaziv olmayan EEG ile kaydedilir ve gerçek zamanlı olarak tanımlanır [37].

Yaşa bağlı olarak SDGUP genliklerinde değişiklikler ve bellek performansı ile ilgili gecikmeler görülebilir. Macpherson ve arkadaşları çalışmalarında 24-25'li yaş grubunda olanların diğer yaş gruplarında göre daha iyi performans gösterdiklerini gözlemlemişlerdir [38].



Şekil 3-3 SDGUP Tabanlı BBA

Mevcut SDGUP tabanlı BBA sistemlerinde, SDGUP'yi elde etmek için genelde zamansal çözünürlüğü ve kolaylığı nedeniyle EEG kullanılır [39].

BBA uygulamasında SDGUP bilgisini EEG'den çıkarmak için çeşitli yöntemler önerilmiştir [40]. BBA sistemlerinde SDGUP'a karşılık gelen frekans değeri saptama için çoğunlukla GSYA kullanılmıştır[41]. Güç spektrum yoğunluğunun tepe noktası görsel ışık kaynağı tarafından uyarılan SDGUP bileşeni olarak düşünülen EEG spektrumu, HFD yöntemiyle tahmin edilebilir. Bu yöntem için yüksek frekans çözünürlüğü ile spektrum kestirimi için uzun pencere boyutu gereklidir.

3.1.4. Yavaş Kortikal Potansiyel

Olayla ilişkili potansiyellerin özel bir türü YKP'dir. EEG korteks hücre gruplarının uyarılma eşiğini yansıtır. YKP'ler de bu hücre gruplarında işlevselliğe sahip EEG'nin yavaş DC-kaymalarıdır. YKP elektriksel negatif yöndeki kaymalar, uyarılma eşiğinde bir azalmayı gösterirken, elektriksel pozitif yöndeki kaymalar uyarılma eşiğinde artışı göstermektedir [42].

Rockstroh, Elbert, Lutzenberger ve Birbaumer, dikkat sorunları yaşayan çocukların YKP'lerini düzenleme yetersizliğine sahip olduğunu gözlemlemişlerdir [43].

Banaschewski ve arkadaşları Hiperventilasyon gibi pro-konvulsif prosedürlerin artmış yüzey negatifliği ile sonuçlandığı ve antikonvülzanların yüzey negatifliğinin azalmasına neden olduğu gözlemine dayanarak, YKP prosedürü, ilaca dirençli epilepsi hastalarında araştırılmıştır. Bu araştırmalarının bir parçası olarak YKP neurofeedback'i alfa-arttırma neurofeedback ile karşılaştırılmış ve YKP neurofeedback alan hastaların nöbet sıklığında önemli bir azalma olduğunu göstermişlerdir [44].

3.2. BBA'da Kullanılan Sınıflandırıcılar

BBA sisteminde kullanılan birçok kümeleme ve sınıflandırma algoritmaları vardır. Bunlardan bazıları alt başlıklar halinde açıklanmıştır.

3.2.1. Destek Vektör Makine Sınıflandırıcıları

Destek Vektör Makineleri hem sınıflandırma hem de regresyon analizi için kullanılabilen bir makine öğrenme algoritmasıdır. Şekil 3-4'de bu algorithmada lineer ve çekirdek fonksiyonu kullanımı gösterilmiştir. Bir düzlemde bulunan sınıflandırılacak veri grupları arasında bir sınır çizgisi belirlenir. Bu sınırın belirleneceği yer ise bu veri gruplarının üyelerine en uzak bir yer olmalıdır. Basit bir şekilde tanımlamak gerekirse DVM bu sınırın nasıl çizileceğini belirler.


$$\frac{1}{2} w^T w + C \sum_{i=1}^N \zeta_i \quad (3-1)$$

Denklem (3-1) de;

$$y_i (w^T \phi(x_i) + b) \geq 1 - \zeta_i \text{ ve } \zeta_i \geq 0, i = 1, \dots, N \text{ dir.}$$

Burada C, kapasite sabitidir, C ne kadar büyük olursa hata oranı o kadar büyük olur. w, katsayıların vektörü, b bir sabit ve ζ_i giriş verilerini işlemek için gerekli parametreleri temsil eder. i İndeksi N eğitim durumlarını etiketler. $y \in \pm 1$ sınıf etiketlerini temsil eder, X_i bağımsız değişkenleri temsil eder. ϕ Çekirdeği, veriyi girdiden özellik alanına dönüştürmek için kullanılır.

Sınıflandırma için kullanıldığında, belirli ikili etiketli eğitim kümesini kendilerinden en uzak olan bir hiper düzlemle ayırırlar bu şekilde sınıflandırma işlemi gerçekleşmiş olur. Doğrusal ayrılmanın mümkün olmadığı durumlar için, "çekirdek" tekniği ile birlikte çalışabilir.



Şekil 3-4 Destek Vektör Makineleri

DVM'ye ait çekirdek fonksiyonları, düşük boyutlu girdi alanını daha yüksek boyutlu bir alana dönüştüren işlevlerdir; diğer bir deyişle, ayrıştırılamayan problemi ayrıştırılabilir problemlere dönüştürmektedir, bu işlevlere çekirdek denmektedir [45]. Bunun nedeni esas olarak, gerçek x-ekseninin tüm aralığındaki yerel ve sınırlı yanıtlardır.

$$K(X_i, X_j) = \left\{ \begin{array}{ll} X_i, X_j & \text{Lineer} \\ (\gamma X_i \cdot X_j + C)^d & \text{polinomal} \\ \exp(-\gamma |X_i - X_j|^2) & \text{Radyal Fonksiyon} \\ \tanh(\gamma X_i \cdot X_j + C) & \text{Sigmoid} \end{array} \right\} \quad (3-2)$$

Denklem (3-2) de $K(X_i, X_j) = \phi(X_i) \cdot \phi(X_j)$ bu bir çekirdek fonksiyonudur, ϕ dönüşümü ile daha yüksek boyutlu özellik alanına eşlenen girdi veri noktalarının bir nokta çarpımını temsil eder. Gamma (γ), belirli çekirdek işlevlerinin ayarlanabilir bir parametresidir.

DVM için hata fonksiyonu: $\frac{1}{2} w^T w + C \sum_{i=1}^N \zeta_i + C \sum_{i=1}^N \zeta_i^*$, ve

$$y_i - w^T \phi(x_i) - b_i \leq \varepsilon + \zeta_i,$$

$\zeta_i, \zeta_i^* \geq 0, i = 1, \dots, N$ olarak ifade edilir. Radial Fonksiyonlar, DVM’de kullanılan en popüler çekirdek türlerinden biridir.


Doğrusal olmayan ayırma probleminde çoğunlukla yararlıdır. Basitçe söylemek gerekirse, son derece karmaşık veri dönüşümleri yapar ve veriyi tanımladığınız etiketler veya çıktılara dayalı olarak ayıran işlemi öğrenir.

$$c = \sum_i a_i k(s_i, x) + b \quad (3-3)$$

Denklem(3-3)’da verilen S_i , destek vektörleri, a_i ağırlıkları, b , eşik değeri ve k , bir çekirdek fonksiyonudur. Doğrusal bir çekirdek durumunda, k , nokta ürünüdür. $C \geq 0$ ise, x birinci gruba üye olarak sınıflandırılır, yoksa ikinci gruba üye olarak sınıflandırılır.

3.2.2. K- En yakın Komşu (Nearest Neighbor) Sınıflandırıcı

Büyük ölçekli bir veri kümesinden, bir sorgu örneğine en çok benzer bir veri alt kümesi bulmayı amaçlayan En yakın komşu (KNN) algoritmaları; boyut indirgeme, model sınıflama ve görüntü alımı gibi geniş kapsamlı uygulamalarda temel bir bileşen olarak kullanılmaktadır[46], [47]. Şekil 3-5’de gösterildiği gibi bu algoritma ile yeni bir nokta verisini sınıflandırmak için bu nokta verisine en yakın k tane eğitim noktası bulunur. Sınıflandırma işlemi, komşularının oy çoğunluğuyla yapılır; sınıflandırma işlemi yapılacak bir eleman, bir uzaklık fonksiyonuyla ölçülen en yakın komşular arasında en yakın olan sınıfa dağıtılır.



Şekil 3-5 K-En Yakın Komşular Kümesi

KNN algoritması bir vektörün en yakın k komşuluktaki vektör elemanları ile sınıflandırma işleminin çıktısı olan denetlemeli öğrenme algoritmasıdır. K-NN algoritması ilk önce bazı gösterimler getirilerek uygulanır, eğitim seti olarak kabul edilir, burada d-boyutlu özellik vektörü bulunur ve gözlenen sınıf etiketleri ile ilişkilendirilir [48], [49].

$$x(x, y) = \sqrt{\sum_{j=1} w_j (x_j - z_j)^2}, \quad (3-2)$$

Denklem (3-2)’de; w_j - j boyutuyla ilişkilendirilen ağırlıktır. Her boyut için ağırlık seçilir ve karesel uzaklık fonksiyonunu belirtilir. Giriş argümanı olan x, z’nin

her satırıyla karşılaştırılır. N uzunluğunda olan bir D vektörü döndürür. Burada, N Z'nin satır sayısıdır. D'nin her bir elemanı, x'e karşılık gelen gözlem ile Z'nin her bir satırına karşılık gelen gözlemler arasındaki mesafedir.


Ayrıca, mesafenin yalnızca sürekli değişkenler için geçerli olduğuna dikkat edilmelidir. Kategorik değişkenler söz konusu olduğunda Hamming mesafesi kullanılmalıdır.

3.2.3. Yapay Sinir Ağı Sınıflandırıcı

YSA yapay zekânın önemli bir parçasıdır[50]. Birçok nöron içeren, fiziksel olarak insan beyninden ilham alınan ve ondan karakterize edilen, matematiksel bir model olan YSA modeli ve ilişkili nöron bağlantılarının da gösterildiği tipik bir mimari Şekil 3-6'da gösterilmiştir. Bu nöronlar genelde ağ oluşumunda kullanılırlar. Ayrıca, her bağlantı ağırlık denen sayısal bir değer ile ilişkilendirilir. Her ağırlık, ağda transfer edilen ve sinyal ile çarpılan belirli bir değere sahiptir [51], [52].

YSA'lar, problem hakkında bilgi sahibi olmaksızın, girdi ve çıktı verileri arasındaki doğrusal olmayan ilişkileri tanımak için eğitilebilirler. Eğitimden sonra YSA'nın çalışma süresi son derece hızlıdır, çünkü yalnızca birkaç basit, birbirine bağlı işlem birimi içermektedir.

Nöronun çıktısı, aktivasyon fonksiyonuyla belirlenir. Literatürde doğrusal, tanjant sigmoid gibi birçok aktivasyon fonksiyonu kullanılır. YSA'ların model tanıma, genelleme ve enterpolasyon yapabilme kabiliyeti vardır; Bu nedenle eğitilen ağa bilinmeyen bir girdi uygulandığında uygun bir çıktı üretebilirler. Deterministik hata ve sistem modelleri yerine yalnızca simüle edilmiş eğitim verileri gerektirirler [53].



Şekil 3-6 Yapay Sinir Ağları

$$y(t+1) = a \left(\sum_{j=1}^n w_{ij} x_j(t) - \theta_i \right) \quad (3-3)$$


Ve

$$f_i \triangleq net_i = \sum_{j=1}^n w_{ij} x_j - \theta_i \quad (3-4)$$

Denklem (3-3) ve denklem (3-4)'da $x = (xX_1, xX_2, \dots, xX_n)$ nöronun n giriş parametrelerini, W_i , X_i girişi için ağırlıkları, θ_i bias değeri, $a(i)$ aktivasyon fonksiyonunu temsil eder. Şekil 3-7'da gösterilen YSA'lar; veri madenciliği, iletişim, doğrusal olmayan sistemlerin modellenmesi, tıbbi uygulamalar ve paralel işleme yetenekleri nedeniyle desen eşleştirmeleri için kullanılmışlardır [54].

Çok katmanlı YSA nöronları en az bir giriş katmanı, bir iki veya üç saklı katman ve son olarak en az bir çıkış katmanından oluşur. Bir YSA modelinde en önemli bulgular düğümler arası bağlantılardır. Ağ topolojisinin oluşumu her katmanda belli sayıda nöronun sonraki katmanlardaki nöronlarla bağlanmasıyla elde edilir.

Çok Katmanlı Algılayıcılar (ÇKA) sinir ağının ileri beslemeli türüne aittir. Tipik ÇKA ağ modeli, giriş nöronları, gizli nöronlar ve çıktı nöronları olmak üzere üç kategoriye sahip bir grup nöronlardan oluşur. Her nöron bir katmandadır ve ayarlanan katmanın tüm nöronlarıyla bağlantılıdır [55].



Şekil 3-7 Çok Katmanlı İleri Beslemeli Ağlar

İyi performans elde edebilmek için problemin durumuna uygun sinir ağı modeli belirlemek önemlidir. Uygun bir eğitim algoritması, katmanlar ve her katmandaki birim sayısı belirlendikten sonra kullanılır. Seçilen eğitim algoritması ile ağıdaki tahmin hatasını en aza indireyecek ağırlık ve eşik değerleri bulunur. N adet örnekten oluşan belirli bir eğitim seti için (x_i, y_i) , $x_i \in R^d$, $y_i \in R^d$, N adet gizli düğüm ve y_i çıktı fonksiyonu olarak aşağıdaki formülde gösterilmiştir.

$$y_i = \sum_{j=1}^M \beta_j g(\omega_j x_i + b_j), \quad 1 \leq j \leq N \quad (3-5)$$

Denklem (3-5)'de β_j çıkış ağırlıkları, ω_j giriş ağırlıkları, b_j i. gizli düğümün bias değeri ve $g(.)$ aktivasyon fonksiyonudur.

4. YAPILAN ÇALIŞMADA KULLANILAN SİNYAL İŞLEME TEKNİKLERİ

BBA sistemleri sinyal işleme tekniklerini kullanarak analiz işlemlerinde görsel uyaranların beyinde oksipital bölgede oluşturdukları cevaplarından faydalanma temeline dayanır. BBA sisteminde kullanılan ve en önemli veri olan EEG sinyalleri zaman-frekans domeninde kullanılabilir hale gelmesi için birçok teknik kullanılmıştır. Bunlardan bazıları aşağıda açıklanmıştır ve tez çalışmasında analiz işlemleri için kullanılan materyaller hakkında bilgi verilecektir.

4.1. Kısa Zamanlı Fourier Dönüşümü

Kısa Zamanlı Fourier Dönüşümü (KZFD) spektrogramı normalize edilmiş ve KZFD katsayılarının karesi alınmış olarak tanımlanır. Matematiksel olmayan bir tanıma göre, KZFD katsayıları, sinyali küçük parçalara bölmek için zaman domeninde kayan bir pencere kullanarak elde edilebilir ve daha sonra frekansları belirlemek için her bir parça Fourier dönüşümü ile analiz edilir [56]. Böylece zamanla değişen bir spektrum elde edilebilir. Matematiksel görünümde, KZFD şu şekilde tanımlanabilir:


$$X(n, \omega) = \sum_{m=-\infty}^{\infty} x[m]w[n-m]e^{-j\omega n} \quad (4-1)$$

Denklem (4-1)'de $x[m][n-m]$, $x[m]$ giriş sinyalinin n zamanındaki kısa süreli bir parçasıdır. Ayrıca ayrık KZFD;

$$X(n, k) = X(n, \omega) \Big|_{\omega = \frac{2\pi}{N}k} \quad (4-2)$$

Olarak tanımlanan denklem (4-2)'de, N , ayrık zamandaki örnek sayısını gösterir. Bu nedenle, logaritmik ölçekte spektrogramı; $S(n, k) = \log|X(n, k)|^2$ olarak tanımlanır.

Her iki frekans da zaman fonksiyonları olarak gösterilmek istenilirse spektrogram kullanılabilir. Şekil 4-1’de gözükten çıkıntılar, güç spektrum yoğunluğunun zirve yaptığı noktalar.



Şekil 4-1 Güç Spektrogram Yoğunluğu Analizi

Bir de HFD tabanlı Welch yöntemi vardır. Parametrik olmayan klasik bir yöntem olarak tanımlanmaktadır. Periyodogram spektrumu kestirimcisinin, periyodogramın hesaplanmasından önce pencere veri bölümlerine ikinci modifikasyonu yapılır [57].

Welch yönteminde, sinyaller üst üste gelerek örtüşecek şekilde parçalara bölünür, her veri bölümü pencerelenir, periodogramlar hesaplanır ve daha sonra periodogramların ortalaması bulunur [58].

Geleneksel Fourier analizinde katsayılar, orijinal sinyalin sinüs dalgaları ile bağlanmasıyla elde edilir. Bu dalgalar doğrusal zaman operatörlerin öz vektörleridir. Dolayısıyla, Fourier analizinin kullanılması esas olarak doğrusal zaman sinyallerin işlenmesi için uygundur. Fakat sürekliliği olmayan olayları incelemek için Fourier dönüşümü ideal değildir [59]. Fourier dönüşümü sinyalin frekans içeriğini belirtir, ancak bu frekansların ne zaman yayınlandığına dair bilgi sağlamaz [60].

4.2. Hilbert Dönüşümü

Hilbert dönüşümü, Hızlı Fourier Dönüşümü'ün aksine, durağan olmayan ve doğrusal olmayan zaman serilerinin analiz edilmesi için çok uygundur. HD'nin kullanılması ile, analitik düzlemdeki sinyalin faz farkı ve potansiyel anomalinin kompleks gradyanları arasındaki dönüşümü hesaplanır.

$$H(u(t)) = \lim_{\epsilon \rightarrow 0} \frac{1}{\pi} \int_{|s-t| > \epsilon} \frac{u(s)}{t-s} ds \quad (4-3)$$

$$y(t) = \frac{1}{\pi} P \int_{-\infty}^{\infty} \frac{x(\tau)}{t-\tau} d\tau, \quad (4-4)$$

Denklem (4-3) ve denklem


(4-4)'de; P, tekil integralin Cauchy temel değeridir. X (t) fonksiyonunun Hilbert Dönüşümü y(t) ile analitik fonksiyonu elde ederiz,

$$z(t) = x(t + iy(t)) = a(t)e^{j\theta(t)}, \quad (4-5)$$

Denklem (4-5)'de; $i = \sqrt{-1}$ dönüşümde a anlık genlik, θ ise anlık faz fonksiyonudur. Anlık frekans basitçe

$w = \frac{d\theta}{dt}$, olarak gösterilir. Hem genlik hem de frekans zamanın bir fonksiyonudur. Hem genlik hem de frekans zamanın bir fonksiyonu olmasıyla, genlik (Veya enerji, genlik karesi) zaman ve frekans fonksiyonu açısından H (ω , t) olarak ifade edilebilir[61], [62].

Şekil 4-2'de her bir zaman noktasının iki bileşenin varlığını gösterir. Analitik sinyalin fazı şekilde olduğu gibi ayırt edilebilir. Sinüzoidlerin frekanslarını çevreleyen bölge şekil deki gibi görülür. Analitik sinyal, sinüzoidal frekansların ortalaması olan anlık bir frekansı öngörür.



Şekil 4-2 Hilbert Analitik Sinyal

4.3. Ampirik Mod Ayırıştırma

Ampirik Mod Ayırıştırma, doğrusal olmayan sistemlerden kaynaklanan durağan olmayan ve nonlinear zaman serileri için geliştirilen yöntemdir [63].

AMA, önceki yöntemlerin hemen hemen hepsinin aksine, ilgili frekans alanından ziyade zaman domeninde çalışır; Veriden türetilen bir deney sonucu ile tanımlanmış temeller ile sezgisel, doğrusal ve uyarlanabilir. Ayırıştırma, dolaylı olarak, herhangi bir zamanda biri diğeri üzerine bindirilen veriler önemli ölçüde farklı frekansların bir arada var olan basit salınımlı modlarına sahip olabilir, gibi basit bir varsayıma sahiptir [64].

Her bileşen, aşağıdaki koşulları sağlayan bir içsel mod fonksiyonu olarak tanımlanır: Tüm veri kümesinde, aşırılık sayısı ve sıfır geçiş sayısı, en fazla bir eşit veya en fazla bir fark olmalıdır. Herhangi bir veri noktasında, yerel maksimum ve yerel minimum kullanılarak tanımlanan zarfın ortalama değeri sıfırdır.

4.4. EEG Sinyali Gürültü Temizleme

Göz hareketleri, göz kırpmaları, kas hareketleri ve kalp hareketi gibi sinyal gürültüleri EEG kayıtlarında büyük ve dikkat dağıtıcı artefaktlar üretir. Kaydedilmiş EEG verileri içerisinde isteğe bağlı mevcut bir değerden daha büyük olan sinyal değerlerini artefakt olarak görüp isteğe bağlı olarak bu artefaktları kaldırmak veya silmek, araştırma ortamlarında en sık kullanılan yöntemlerden biridir. Ancak bazı hasta gruplarında olduğu gibi, sınırlı veriler olduğunda, kas hareketleri çok sık gerçekleştiğinde veya ışık kaynağına bakıldığında, bu durum artefakt olarak görülüp silindiğinde bazen farklı boyutlarda veri kaybı olabilir. Göz hareketi artefaktlarının kaldırılması için önerilen bazı yöntemler zaman-frekans alanındaki regresyonlara dayanır [34].

Bant geçiren filtreleme, otonom harekete sahip iç organ hareketleri gibi tepki sinyal bandı ile örtüşen frekansları, örneğin solunum nedeniyle fizyolojik sesleri filtrelemek için kullanılamaz, fakat Temel Bileşen Analizi (TBA), Bağımsız Parça Analizi (BPA) ve adaptif filtrelemeye sahip diğer metotlar kullanılabilir.

TBA çok kanallı EEG'den göz artefaktlarını kaldırmak için önerilir ancak, TBA, göz artefaktlarını beyin sinyallerinden, özellikle benzer genliklere sahip olduklarında tamamen ayıramaz. Sistemik dalgalanmalar, farklı kanallardan gelen Fonksiyonel Yakın Kızılötesi Spektroskopi ölçümleri arasında eş değişke olduğu için TBA fizyolojik gürültüleri ayırtmak için kullanılabilir [65]. Bu nedenle, bu tür eş değişkenleri azaltmak, sinyallerdeki sistemik fizyolojik gürültüleri filtrelemektir. TBA'nın performansı kanal sayısına ve kaldırılacak öz vektörlerin sayısına önemli ölçüde bağlıdır; bu nedenle, kanal sayısı az olduğunda TBA, fizyolojik gürültünün giderilmesi için önerilmez [66].

Ayrıca, fizyolojik gürültünün giderilmesi için BPA'nın gerçek zamanlı bir uygulaması halen araştırılmaktadır. Fizyolojik sinyallerle bağlantılı bağımsız bileşenler (BP)'ler, spektral yoğunlukları ile tanımlanabilir. Özgün otonom hareket tepki ile ilişkili ana BP'nin izole edilmesi fizyolojik-gürültüsüz bir sinyal ile sonuçlanır[67]. Santosa ve arkadaşları fizyolojik gürültüyü orijinal sinyallerden ayırmak için BPA kullandı [68].

$$\Delta W \propto \frac{\partial H(y)}{\partial W} W^T W = [I + \hat{p} u^T] W \quad (4-6)$$

Denklem (4-6)'deki doğal gradyan $W^T W$ terimi, matris terslemelerini önler ve yakınlaşmayı hızlandırır[69]. Burada;

$$\hat{p}_i = (\partial / \partial v_i) \ln(\partial y_i / \partial v_i) \quad \text{dir.}$$


4.4.1. Filtreleme

Kurallara göre, filtreler test sinyali olarak tek bir keskin dürtü ile test edilir. Bu girdiye verilen filtre tepkisi, daha sonra dürtü yanıtı olarak adlandırılır. Frekans tepkisi, dürtü tepkisinin Fourier dönüşümüdür. Bu büyüklük ve faz tepkisi olmak üzere iki kısımdan oluşur. Tüm bu tepkiler, filtrenin özelliklerini tanımlamak için kullanılır. Dürtü ve frekans yanıtı, bir filtrenin zaman veya frekans domenindeki transfer fonksiyonunu tanımlar[70]. Diğer bir deyişle, bir filtrenin sinyal girişi üzerindeki etkisini filtrelenmiş bir sinyal çıktısına dönüştürme olarak tanımlanır. Bu nedenle, iyi filtre tasarımı için filtre tepkilerini doğru tespit etmek gereklidir.

Bant Geçirgen Filtre

Bant geçirgen filtreler, pencereleme yöntemi kullanılarak tasarlanmıştır [71].

Şekil 4-3'de tasarımı verilen bu yöntem ile frekans domeninde ideal bir filtre oluşturulur ve daha sonra ayırık zaman domenine çevrilmektedir. Fakat bu sonsuz bir dürtü yanıtı verecektir. Bunu telafi etmek için, bir pencere fonksiyonu ideal impuls cevabı üzerine çarpılır. Bant geçirgen filtre tasarımında, filtrenin sırası pencerenin uzunluğunu belirler.



Şekil 4-3 Bant Geçirgen Filtre Tasarımı

$$H_d(e^{j\omega}) = \begin{cases} e^{-j\omega \frac{M}{2}} & \text{if } -w_c - w_b < \omega < -w_c + w_b \\ 0 & \text{if } -w_c - w_b < \omega < w_c + w_b \end{cases} \quad (4-7)$$

Diğer durumlarda

Denklem (4-7)'de verilen;

$$H_d(e^{j\omega})$$


İdeal cevap fonksiyonunda;

w_c Kesme frekansı,

w_b Geçirgenlik frekansı olarak bilinir.

Kesme frekansı filtrenin geçiş bandını ve duraklamasını ayırır ve daima geçiş bandında bulunur. Optimal olarak, kesme frekansı; sinyali frekans alanında gürültü bileşenlerinden ayırmalıdır. İstenmeyen sinyal bozulmalarını önlemek için, uygun kesme frekansının seçilmesi önemlidir. Böylece uygun kesim frekansı ile sinyalin herhangi bir spektral bileşeni zayıflatılmamış ve sinyal gürültüden mümkün olduğunca temizlenmiş olur [72]. Bant geçirgen filtreler için öncelikle uygun bir pencere işlevi seçilir. İdeal bir cevap fonksiyonu belirtilir sonra İdeal filtrenin katsayıları hesaplanır. Filtre katsayılarını bulmak için ideal katsayılar pencere fonksiyonuyla çarpılır. Böylece ortaya çıkan filtrenin frekans tepkisi kullanılabilir hale gelmiş olur. Bu Bant Geçirgen Filtrede faz tipi doğrusal yani sabit grup gecikmesi kullanılır. Bant geçirgen filtresini test etmek için oluşturulan bir giriş sinyalinin genlik, birim dürtü cevabı ve gecikme durumu gösterilmiştir. Şekil 4-4'de bant geçiren filtre sıfır ortalama rastgele parazit ve 2.35 GHz'de bir engelleyicinin dahil edilmesi ile oluşturulan 2.45 GHz'de

gürültülü bir sinüzoidal sinyale uygulanmıştır ve bu sinyal kurtarılabilir olmalıdır. Zaman domeninde giriş sinyali ve filtre yanıtı görüntülenmiştir.



Şekil 4-4 Giriş Sinyalinin Genlik, Birim Dürtü Cevabı

4.5. Öznitelik Çıkarma

Bir BBA sistemi kullanımında en uygun sınıflandırıcıyı seçmek için hangi özniteliklerin kullanılacağı önemlidir. Bu özniteliklerin karakteristik ve spesifik özellikleri hakkında hangi özelliklerin nasıl kullanıldığı açık bir şekilde anlaşılması gerekir. Bu bölüm, BBA’da kullanmak üzere öznitelik çıkarımı ve EEG zaman değişimlerini göz önüne alarak kullanma biçimini tarif etmeyi amaçlamaktadır.

Genlik, frekans ve bazen faz yapı özelliklerine göre alınarak karakteristik özellikleri belirlenen EEG sinyallerinden öznitelikler çıkarmak için çeşitli yöntemler geliştirilmiştir.

Entropi: Rastlantı ve düzensizlik olarak tanımlanan entropi, bu çalışmada örüntülerin ne sıklıkta tekrarlandığını ifade eder. Entropi formülü Denk. (4-8)'de verilmiştir.

$$\text{Entropi} = - \sum_{i,j}^N P(i, j) * \log P(i, j) \quad (4-8)$$

Ortalama: Ortalama, sinyalin frekans yoğunluğunun ortalama değeridir. Ortalama formülü Denk.(4-9)'de verilmiştir.

$$\text{Ortalama} = \mu = \sum_{i=0}^{N-1} iP(i) \quad (4-9)$$

Standart sapma: Verilerin ne kadarının ortalamaya yakın olduğunu bulmak için standart sapma değeri hesaplanır. Eğer standart sapma küçükse veriler ortalamaya yakın yerlerde dağılmışlardır. Eğer standart sapma büyükse veriler ortalamadan uzak yerlerde dağılmışlardır. Standart Sapma formülü Denk.(4-10)'de verilmiştir.

$$\sigma = \sqrt{\sum_{i=0}^{N-1} (1 - \mu)^2 P(i)} \quad (4-10)$$

EEG sinyallerinin genlik değerleri, bant güçleri, güç spektrum yoğunluğu değerleri, uyarlanabilir otoregresif parametreler, zaman frekansı özellikleri ve ters modele dayalı özellikler gibi BBA sisteminde kullanılması için çeşitli özellikler denenmiştir. Bir BBA sisteminin tasarımı ile ilgili olarak, bu özniteliklerin bazı özellikleri göz önüne alınmalıdır. Bunun için aykırı gürültü, yüksek boyutluluk, Durağanlık, zaman varyasyon özellikleri bilinmelidir[73, 74].

BBA sistemlerinde, öznitelik vektörleri çoğunlukla yüksek boyuttadır [75]. Özellikler genellikle birkaç kanaldan ve birkaç zaman diliminden çıkarılır ve tek bir özellik vektörüne eklenir [76].

Belirli bir özellik kümesi için en uygun sınıflandırıcıyı kullanmak gereklidir bunun için mevcut sınıflandırıcıların özellikleri bilinmelidir. Bunlar aşağıdaki gibi değerlendirilebilir;

Üretici: Bir özellik vektörünü sınıflandırmak için, üretici sınıflandırıcılar her sınıfın olasılığını hesaplar ve en olası sınıfı seçerler (örneğin ikinci derece bayes sınıf modelini öğrenir).

Ayırıcı: Destek Vektör Makineleri, bir özellik vektörünü doğrudan sınıflandırmak için sınıfları veya sınıf üyeliğini ayırt etme yolunu öğrenirler[77].

Statik-dinamik: Statik sınıflandırıcılar, sınıflandırmada tek bir özellik vektörünü sınıflandırdıkları için zamansal bilgileri dikkate almaz (örneğin çok katmanlı Perceptron). Ancak dinamik sınıflandırıcılar, bir dizi özellik vektörünü sınıflandırabilir ve bu nedenle zamansal dinamikleri yakalar [78] (örneğin Gizli Markov Modeli).

5. UYGULAMA

Bu tez çalışması kapsamında yapılan uygulamada kullanılan cihaz ve uygulama editörleri hakkında aşağıda alt başlıklar halinde detaylı olarak açıklamalar yapılmıştır.

5.1. Emotiv

Ödül kazanan Emotiv Epoc+, bağlamsallaştırılmış araştırma ve BBA uygulamaları için tasarlanmış, 14 kanallı bir kablosuz EEG'dir.




Şekil 5-1 Emotiv Epoc + 14 Kanal

Emotiv Epoc+, abonelik tabanlı yazılımı kullanılarak yoğun dizi, yüksek kaliteli ham EEG verilerine erişim sağlanır. Şekil 5-1'de gösterildiği gibi Emotiv Epoc +, 14 EEG kanalı artı 2 referans kanalına sahiptir ve doğru mekansal çözünürlük için optimal konumlandırma sunar.

Esnek tasarımı, kablosuz ve şarj edilebilirliği, Salin çözelti esaslı ıslak algılayıcıları, 12 saate kadar sürekli kullanım sağlayan lityum pili ve Windows, OSX, Linux, Android ve iOS işletim sistem platformlarıyla uyumlu olması ile kullanıcılara deney yapma ve uygulama geliştirme imkânları sağlamıştır. Kendi platformunda geliştirilen uygulamada yazılım aboneliği ile ham EEG verileri tedarik edilebilir. Bu platformda kullanılabilecek oyun, yüz ifadeleri, zihinsel komutlar ve beyin sinyal haritalanması gibi birçok paket mevcuttur. Bunun yanı sıra Matlab, C#, Python gibi

platformlarda yazılım desteği bulunur. Şekil 5-2’da Emotiv sınıf bağlantı diyagramı verilmiştir.



Şekil 5-2 Emotiv Sınıf Bağlantı Diyagramı

- ✓ Windows sisteminde Epoc+ için gereksinimler
- ✓ GHz Intel Pentium 4 işlemci (eşdeğeri veya üstü)
- ✓ Microsoft Windows XP Service Pack 2, Windows Vista, Windows 7, Windows 8 veya Windows 10, 2GB RAM ve en az 200MB kullanılabilir disk alanı gerekmektedir.
- ✓ Teknik özellikleri
- ✓ 14 kanal: AF3, F7, F3, FC5, T7, P7, O1, O2, P8, T8, FC6, F4, F8, AF42
- ✓ Referanslar: CMS / DRL gürültü giderme yapılandırmasında P3 / P4 konumları.
- ✓ Örneklem yöntemi: Sıralı örneklem.
- ✓ Örneklem hızı: 128 SPS veya 256 SPS * (2048 Hz dahili)
- ✓ Çözünürlük: 14 bit 1 LSB = 0.51µV (16 bit ADC, 2 bit enstrümantal gürültü zemini atılır) veya 16 bit *
- ✓ Bant genişliği: 0,2 - 43Hz, 50Hz ve 60Hz’de dijital çentik filtreleri
- ✓ Filtreleme: Dahili dijital 5. Sinc filtre
- ✓ Dinamik aralık (referans girdi): 8400µV (s)
- ✓ Kaplin modu: AC kuplajlı
- ✓ Bağlantı: Kablosuz: Bluetooth® Akıllı Özel kablosuz: 2.4GHz bant

5.1.1. Matlab_emotiv

Matlab dizinine edk.dll ve edk.h kütüphane dosyaları eklenir. Bu kütüphane dosyaları kullanılarak Matlab da Emotiv Epoc+ cihazı ile edinilen ham EEG sinyalleri görülebilir ve EEG sinyal verileri aynı zamanda kaydedilebilir.

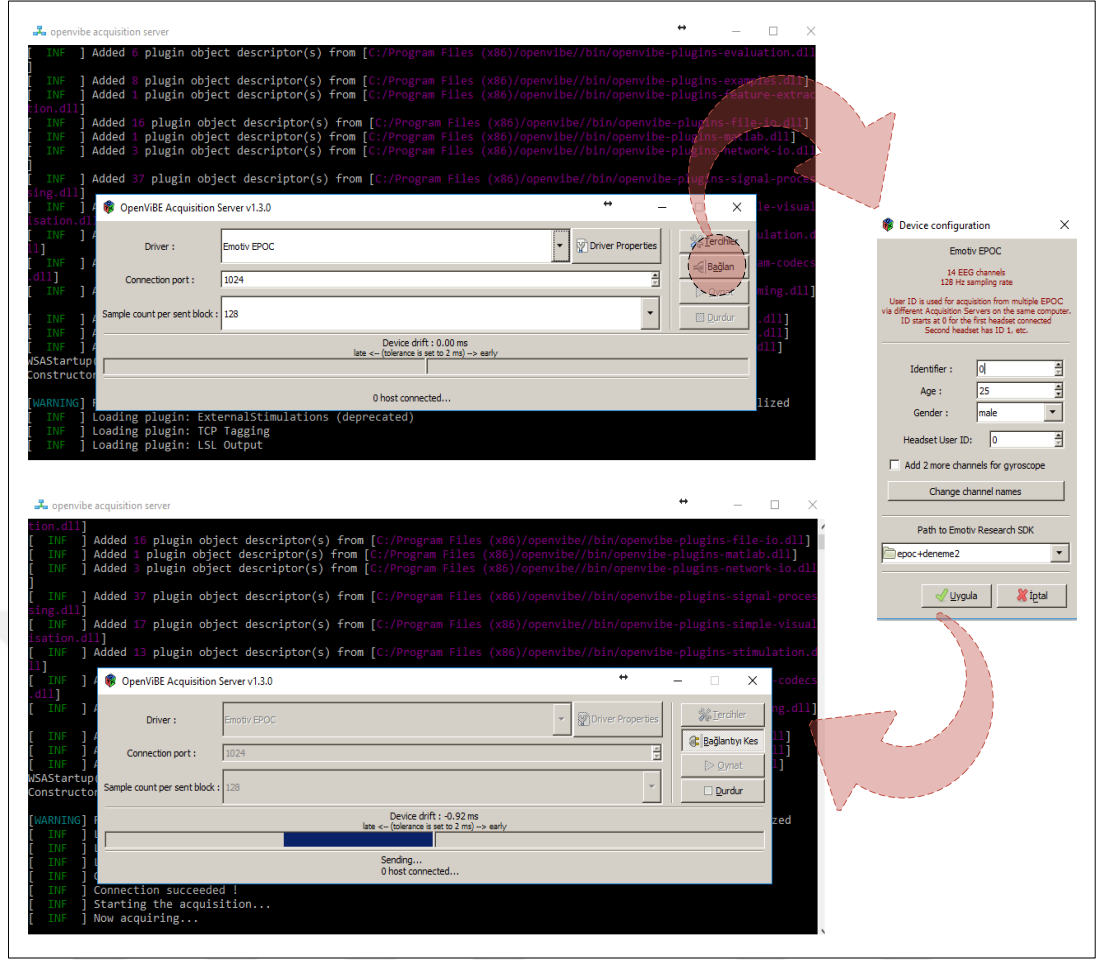
5.1.2. OpenVibe ile Emotiv Epoc+

OpenVibe, Beyin-Bilgisayar Arayüzleri olarak kullanılan bir yazılım platformudur. Beyin sinyallerini elde etmek, filtrelemek, işlemek, eğitmek, test etmek, sınıflandırmak ve görüntülemek için gerçek zamanlı olarak kullanılabilir. Windows ve Linux işletim sistemlerinde çalışan ücretsiz ve açık kaynaklı bir yazılımdır.

OpenVibe da SSVEP ile bu konuda araştırma yapmak isteyen herkes kendi data setini oluşturabilir. OpenVibe editörü Emotiv, Neurosky, OpenBCI, OpenEEG ve gTec gibi birçok EEG cihazı ile gerekli kütüphaneleri yüklenerek bağlantı kurulabilir ve EEG sinyalleri kaydedilebilir.

HFD, Ortak Alansal Örüntü (OAÖ), Bant Geçirgen filtre, gibi birçok sinyal işleme yöntemleri hazır paket olarak kullanılabilir. Lineer Diskriminant Analizi (LDA), DVM ve ÇKA gibi sınıflandırıcılar oluşturulan veri seti için kullanılabilir. Bu da araştırma yapılan alan üzerinde daha düzenli ve hızlı işlem yapılmasını sağlar.


Önce OpenVibe da 'Acquisition Server' sayfasında driver bölümünde Emotiv seçilir, ardından 'Driver Properties' kısmından device configuration sayfası açılıp gerekli parametreler doldurulur ve en önemlisi de emotiv research sdk dizinine emotiv sdk dosyasının bulunduğu klasör dizini eklenilir. Bu durum Şekil 5-3'de gösterilmiştir.



Şekil 5-3 OpenVibe Emotiv Epoc+ Bağlatı Ayarları

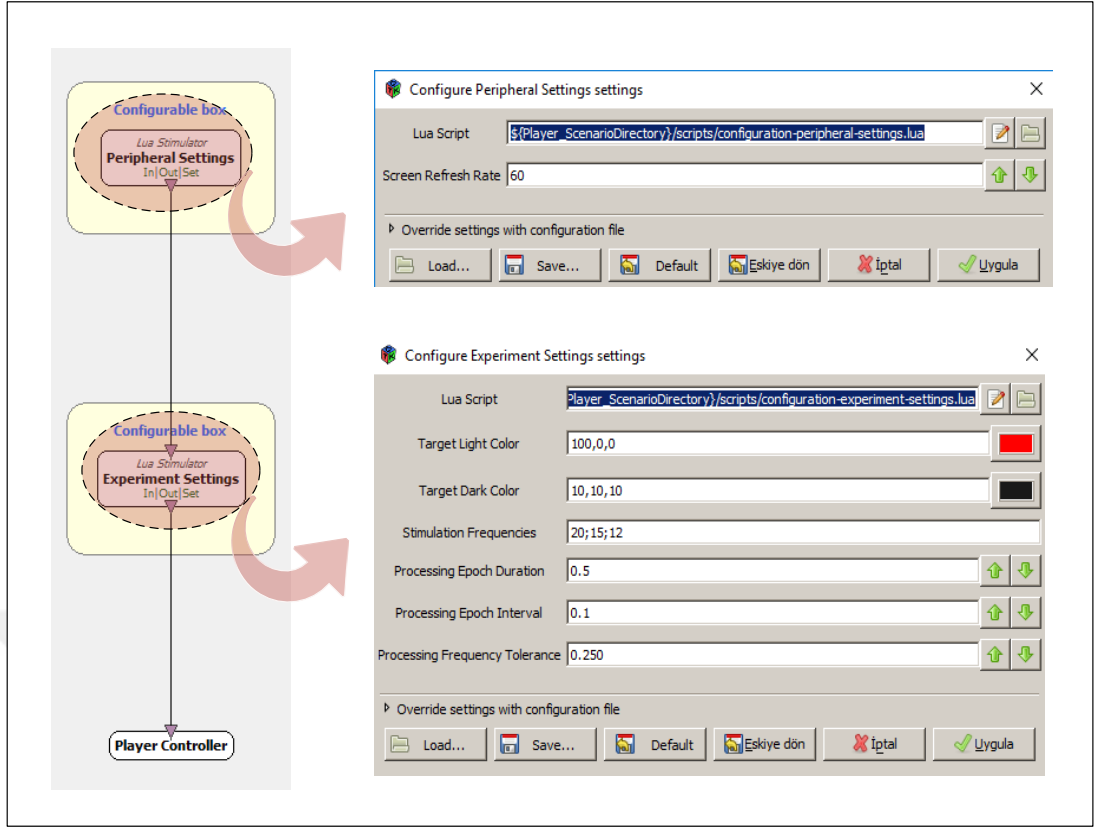
Bu çalışmada OpenVibe yazılım platformunda SDGUP'yi test etmek için kullanılan 5 işlem sırasıyla açıklanmıştır. SDGUP tabanlı BBA birkaç adımda OpenVibe ile test edilebilir. Bu adımlar, konfigürasyon, eğitim edinimi, OAÖ filtre eğitimi, sınıflandırıcı eğitimi ve çevrimiçi testten oluşur.

Şekil 5-4'de OpenVibe anlık sinyal edinimi, ham sinyal, filtrelenmiş sinyal ve HFD görüntüleme işlemi gösterilmiştir.



Şekil 5-4 OpenVibe- Emotiv Sinyal Edinimi Anlık Görüntüleme

Şekil 5-5’de yapılandırma parametrelerini içeren Çevresel ve Deneysel Ayar gösterilmiştir. İlk adım, en az bir kez çalıştırılmalıdır; çünkü SDGUP deneyi yapılandırılmış bir senaryodur.




Şekil 5-5 OpenVibe Sinyal Edinimi Konfigürasyon Ayarları

Çevresel kutudaki ayarlar, donanım yapılandırması olan ekran yenileme hızına göre ayarlanmalıdır. Deneme kutusundaki ayarlar, SDGUP'nin genel ayarları ile ilgili birden fazla parametre içerir.


Simülatör ekranında titreşen kutuların renkleri, her kutunun frekans değeri, SDGUP yanıtını bulmak için kullanılacak sinyal uzunluğu, sinyal bölgeleri arasındaki hız aralığı ve sınıflandırma için kullanılan uyaran frekansı etrafındaki frekans bandının toleransı gibi ayarlamalar yapılır. Bu adımda SDGUP/SSVEP cevabı ile sınıflandırıcıların eğitmesi için, farklı frekanslarda titreşen uyarılara bakan kullanıcının eşzamanlı EEG sinyal verileri belirlenen süre içerisinde kaydedilerek gerekli eğitim verileri elde edilir.

Şekil 5-6'da kaydedilen verilerin eğitilmek için kullanıldığı senaryo gösterilmiştir.



Şekil 5-6 OpenVibe Sinyal Edinimi SDGUP Ağ Eğitimi


SDGUP Eğitim Denetçisi bu adımda önemli bir role sahiptir. Şekil 5-7’de gösterildiği gibi, SDGUP uyarın düzeniğinin ayarlanması gereken parametreleri vardır. Bunlar farklı frekanslarda titreşen kutular arasında bakılacak hedef kutusunu gösteren hedef sırası, hedeflerin titreşeceği dizinin süresini gösteren uyarılma süresi, nesnelerin süresince geçen süreyi temsil eden kopma süresi, ekranda titremenin ve hedefi işaretleyen ok ile titreşimin başlangıcı arasındaki gecikmeyi temsil eden titreşen gecikme, olarak tanımlanabilir.



Şekil 5-7 Farklı Frekanslarda Titreşen Kutular

Şekil 5-8’da gösterilen üç farklı sinyal işleme durum değerlendirme platformu bulunur. Bu işlemlerin ilki birinci titreşim frekansına (6.66 Hz), ikincisi ikinci titreşim frekansına (8.57Hz) ve üçüncüsü üçüncü titreşim frekansını (12Hz) gösterme temeline dayanılarak yapılır. Önceki adımda kaydedilen veriler, genel akış okuyucusuna yüklenir.

Ardından hangi elektrot kanallarının en verimli kombinasyonunu otomatik olarak seçen OAÖ filtresi eğitim için kullanılır.



Şekil 5-8 OpenVibe OAÖ Filtresi

3 farklı beyin sinyal frekans cevabının beyinde yoğun olarak görüldüğü ve bu sinyallerin ayrıştırılabilir öznelitliklerinin baskın olduğu bölgeye denk gelen Emotiv Epoc+ başlığının en uygun kanalları seçilir. Her bir kanaldan edinilen EEG frekansına Butterworth metotlu bant geçiren filtre tipi uygulanır.


Üç farklı sınıflandırıcı, DVM, Doğrusal Diskriminant Analizi ve Çok Katmanlı Algılayıcı kullanılabilir. En etkili kanal kombinasyonları içinde OAÖ filtre olarak kullanılır. Bu, her titreşim kutusu için ayrı olarak yapılır.

Son olarak, uyarılan ve uyarılamayan periyotların genlik değerleri sınıflandırıcı tarafından alınır ve ikisi arasında ayırım yapmak için eğitilir. Bir sınıflandırıcı, her uyarım frekansı için eğitilir. Her frekans ayrı olarak değerlendirilir. İşlem zincirinde iki önemli kutu vardır:

Zamansal Filtre; tek bir frekans bandını çıkarır. Yapılandırma işlemi tarafından oluşturulan bir dosya ile yapılandırılır.

Hedef Ayırıcı: bir frekansı diğerlerinden ayırmak için kullanılan hedefleri ayırır ve her uyarı yanıtları frekanslarına göre ilgili sınıflara gönderilir.


Şekil 5-9’da Önceki adımlarda eğitim için kaydedilen ve ön işleme yapılan EEG sinyallerinin LDA, ÇKA ve DVM ile sınıflandırılma işleminin yapıldığı senaryo gösterilmiştir. Önceki adımlarda işlenmiş ve kaydedilmiş sinyaller, çevrimiçi BBA uygulamasında kullanılabilecek sınıflandırıcılar oluşturmak için kullanılır.



Şekil 5-9 OpenVibe Sınıflandırıcı Eğitici

Şekil 5-10’da anlık kaydedilen EEG sinyalleri kullanılıp hedefe online ateş etme oyunu oynanarak sistem performansı test edilmiştir. Bu adımda çevrimiçi test ayarları yapılır. Sınıflandırıcıların ağ yapısı önceki adımda eğitilmiştir. Sistemin test edildiği oyunda 3 hamle bulunur. Sol kareye bakıldığında sistem saat yönünde hareket eder.

Sağ kareye bakıldığında sistem saatin tersi yönünde hareket eder. Üçgen şekle baktığınızda, sistem hedefe ateş etmektedir.




Şekil 5-10 BBA Online Test Ateş Etme Oyunu

Ham EEG sinyali, edinim sunucusu tarafından çevrimiçi olarak Emotiv Epoc+ cihazı ile elde edilir, sinyal belirli zaman aralıklarında işlenir, filtrelenir, eğitilmiş ağ üzerinden geçirilir ve Deneğin flicker'a bakması ile ortaya çıkan sinyal cevabının hangi sınıfa ait olduğuna sistem tarafından karar verilir.

5.2. Lego Mindstorms Ev3 Robotu

EV3 Mindstorm Brick lego, ARM9 işlemciye sahip, WiFi ve internet bağlantısı için USB portu, Micro SD kart okuyucu, interaktif servo motor, arka aydınlatmalı düğmeler ve 4 motor portuna sahiptir.

Şekil 5-11’de gösterilen Lego Mindstorms EV3 robotunun Port Görünümünde ilk ekranda portlara hangi sensör veya motorların takıldığı görülür. Dolu portlardan birine gitmek için EV3 Brick Düğmeleri kullanılıp ve sensör veya motordan okunan değerler görülebilir.



Şekil 5-11 Lego Mindstorms EV3

EV3 Brick’te Bluetooth veya wifi etkinleştirilir ve kablosuz bir şekilde robot kontrol edilebilir. Bu çalışmada Matlab editörüne Lego MindStorms Ev3 Kütüphanesi yüklenerek Lego Mindstorm EV3 motor kontrolü yapılmıştır.

6. SONUÇLAR

Bu çalışmada 14 kanala sahip Emotiv Epoc+ cihazı kullanılarak Matlab yazılımı ve OpenVibe BBA uygulaması ile iki farklı platformda veri seti oluşturulmuştur. Veri seti içerisinde yön ve uyaran frekansına göre kümeleme işlemi yapılmıştır. Her iki platformda da kutu şekillerinin belirli frekanslarda (6,66, 8,57, 12 Hz) titreşmesi bir uyaran olarak beyinde özellikle oksipital bölgede bir uyarı oluşturur. Her bir uyaran frekansının oksipital bölgede kendi uyaran cevabını oluşturmasıyla sistem testi yapılmıştır.

Uygulama 1

OpenVibe’da işlem süresince kullanılan terimler aşağıda ifade edilmiştir.

Epoc işlem Süresi: Sinyal diliminin uzunluğu, SDGUP cevabını bulmak için kullanılmıştır. Daha uzun süreli hassasiyet olumsuzluk olarak değerlendirilen gecikme süresini artıracaktır.

Süre Dilimi Aralığı: Sinyal dilimleri arasındaki hız aralığı olarak ifade edilir.

Frekans Toleransı İşlemi: Sınıflandırma için kullanılan uyarım frekansı etrafındaki frekans bandının genişliği olarak ifade edilir.

Sinyal edinimi için gerekli ayarlamalar yapıldıktan sonra EEG ile kaydedilen beyin sinyal verilerini bant geçiren filtreden geçirerek gürültü temizleme işlemi yapılmıştır. En etkili kanal kombinasyon tespiti için OAÖ filtre olarak kullanılmıştır. Bu işlem, farklı uyaran frekansına sahip her bir titreşim kutusu için ayrı ayrı yapılır. Destek Vektör Makinesi, Lineer Diskriminant Analizi ve Çok Katmanlı Algılayıcı olmak üzere üç farklı sınıflandırıcı, kullanılmıştır.

Çizelge 3 OpenVibe’da Oluşturulan 1.Data setin Sınıflandırma Test Sonuçları

Frekanslar	LDA	ÇKA	DVM
<i>1.Titreşeme Frekansı (6.66Hz)</i>	92%	89%	97%
<i>2.Titreşeme Frekansı (8.57Hz)</i>	89%	87%	91.7%
<i>3.Titreşeme Frekansı (12Hz)</i>	90%	85%	89%
<i>Ortalama</i>	90.33%	87%	92.56%

İşlenmiş veri kümesinde eğitilen ağıın başarı yüzdeleri hesaplanır. Çizelge 3’de gösterildiği gibi kayıtlı veriler üzerinde LDA ile %92, ÇKA ile %89 ve DVM ile %97 doğruluk oranı ilk titreşim için elde edilmiştir. İkinci titreşim için doğruluk oranı LDA ile %89, ÇKA ile %87 ve DVM ile %91.7 olarak elde edilmiştir. Üçüncü titreşim için doğruluk oranı LDA ile %90, ÇKA ile %85 ve DVM ile %89 doğruluk elde edilmiştir. Beşinci adımda bu sınıflandırma doğruluk oranları ile oyun yapılandırması yapılmış ve EEG sinyalleri ile çevrimiçi oyun oynanarak sistemin performansı test edilmiştir. Buna ek olarak uyarıların frekans değeri 12,15,20 Hz olarak ayarlanıp sistem aynı şekilde tekrar test edilmiştir. Ancak frekans değeri 6.66,8.57,12 Hz olarak ayarlanan sistemin doğruluk oranı ve online sistem test değerlendirmesi daha başarılı sonuç verdiği gözlemlenmiştir ve test sonuçları Çizelge 4’te gösterilmiştir.


Çizelge 4 OpenVibe’da Oluşturulan 2.Data setin Sınıflandırma Test Sonuçları

Frekanslar	LDA	ÇKA	DVM
<i>1.Titreşeme Frekansı (12Hz)</i>	90.2%	86.8%	91%
<i>2.Titreşeme Frekansı (15Hz)</i>	84%	87%	91.7%
<i>3.Titreşeme Frekansı (20Hz)</i>	87.4%	84%	82%
<i>Ortalama</i>	88.17%	85.9%	88.23%

Uygulama 2

Matlab da ise ön işlemler aynı olmakla beraber eğitim için kaydedilen sinyaller ayrıştırılarak aynı frekans ve yönde uyarı sinyalleri üç sınıf oluşturacak şekilde bir araya getirilmiştir. Sinyal kümesi haline getirilen bu sinyallere 4-20 Hz bant geçiren filtre uygulanarak veriler istenmeyen gürültülerden ayrıştırılmıştır. Daha sonra, HD ile sinyal analitik düzleme aktarılmış ve ardından ve KZFD’si alınmıştır. Ayrıca her sınıf


için ayrı ayrı entropi, ortalama ve standart sapma değeri hesaplanarak öznelilik vektörü elde edilmiştir. Deneğin baktığı farklı frekanstaki her bir uyaran şekil için görsel olarak uyarıldığı Oksipital bölgede SDGUP cevabı bulma işlemi yapılmıştır. SDGUP cevabı tespit edildikten sonra eğitim için MAMEM kuruluşu tarafından Emotiv Epoc+ cihazı ile on bir denekten toplanmış veri YSA ve DVM sınıflandırıcıları kullanılarak sistem eğitimi için kullanılmıştır. Şekil 6-1’de sınıflandırma sonucunun ROC eğrisi gösterilmektedir.



Şekil 6-1 YSA Sınıflandırma ROC grafiği

Eğitilen sınıflandırıcı ağını test için Emotiv Epoc+ cihazı ile kişisel EEG verileri kullanılmıştır. Edinilen beyin sinyalleri gerçek zamanlı olarak eğitilen ağ üzerinden geçirilmiştir. Daha sonra ve deneğin ekran üzerinde hangi yöne baktığı sistem tarafından karar tespit edilmiştir.

Şekil 6-2’de gösterildiği gibi eğitilen ağa 5 er saniyelik sinyal örneği verilerek Lego EV3 Robotu sağ-sol ve ileri yönlerine hareket ettirilerek yön kontrolü sağlanmıştır.



Şekil 6-2 SDGUP tabanlı Mobil Robot Kontrol Akış Şeması

SDGUP tabanlı farklı frekanslardaki (6,66, 8,57, 12 Hz) görsel uyaranlar sol, sağ ve ileri olmak üzere üç farklı yönü gösteren titreme halinde üç farklı uyaran şekillerine bakılması ile beyinde meydana gelen SDGUP cevabı BBA sistemi tarafından tespit edilmiş ve ortalama %89 oranında doğruluk başarı oranı elde edilmiştir. Sonuçların başarılı bir şekilde test edilmesi gelecekte nano teknolojiler ve mobil cihazlar ile sistem bütünleştirilerek EEG tabanlı BBA çalışmalarında cihaz kontrolünün çok daha hassas, hızlı ve başarılı olacağı hakkında ümit vermektedir.

KAYNAKLAR

- [1] H. Takao, N. Hayashi, and K. Ohtomo, *Brain diffusivity pattern is individual-specific information*, **Neuroscience**, 301 (2015) 395–402.
- [2] A. Şengür, Y. Guo, and Y. Akbulut, *Time–frequency texture descriptors of EEG signals for efficient detection of epileptic seizure*, 3:2 (2016) 101–108.
- [3] G. R. Müller-Putz, R. Scherer, C. Brauneis, and G. Pfurtscheller, *Steady-state visual evoked potential (SSVEP)-based communication: impact of harmonic frequency components*, **J. Neural Eng.**, 2:4 (2005) 123–130.
- [4] R. M. G. Tello, S. M. T. Müller, M. A. Hasan, A. Ferreira, S. Krishnan, and T. F. Bastos, *An independent-BCI based on SSVEP using Figure-Ground Perception (FGP)*, **Biomed. Signal Process. Control**, 26 (2016) 69–79.
- [5] B. He, S. Gao, H. Yuan, and J. R. Wolpaw, *Brain–Computer Interfaces*, **Neural Engineering**. Springer US, pp. 87–151, 2012.
- [6] D. Zhu, J. Bieger, G. Garcia Molina, and R. M. Aarts, *A Survey of Stimulation Methods Used in SSVEP-Based BCIs*, **Comput. Intell. Neurosci.**, 2010 (2010) 1–12.
- [7] Y. Li et al., *An EEG-Based BCI System for 2-D Cursor Control by Combining Mu/Beta Rhythm and P300 Potential*, **IEEE Trans. Biomed. Eng.**, 57:10 (2010) 2495–2505.
- [8] J. P. Donoghue, *Connecting cortex to machines: recent advances in brain interfaces*, **Nat. Neurosci.**, 5:Supp (2002) 1085–1088.
- [9] X. Chen, Y. Wang, S. Gao, T.-P. Jung, and X. Gao, *Filter bank canonical correlation analysis for implementing a high-speed SSVEP-based brain–computer interface*, **J. Neural Eng.**, 12:4 (2015) 46008.
- [10] Y. Zhang, P. Xu, K. Cheng, and D. Yao, *Multivariate synchronization index for frequency recognition of SSVEP-based brain–computer interface*, **J. Neurosci. Methods**, 221 (2014) 32–40.
- [11] Z. Lin, C. Zhang, W. Wu, and X. Gao, *Frequency Recognition Based on Canonical Correlation Analysis for SSVEP-Based BCIs*, **IEEE Trans. Biomed. Eng.**, 53:12 (2006) 2610–2614.
- [12] Z. N. Han and J. X. Gao, *Gear Local Fault Diagnosis with Empirical Mode Decomposition and Hilbert Huang Transformation*, **Adv. Mater. Res.**, 199–

200 (2011) 899–904.

- [13] R. M. G. Tello, S. M. T. Muller, T. Bastos-Filho, and A. Ferreira, A comparison of techniques and technologies for SSVEP classification, *5th ISSNIP-IEEE Biosignals and Biorobotics Conference (2014): Biosignals and Robotics for Better and Safer Living (BRC)*. IEEE, 2014.
- [14] D. Zhang, X. Gao, S. Gao, A. K. Engel, and A. Maye, An independent brain-computer interface based on covert shifts of non-spatial visual attention, *2009 Annual International Conference of the IEEE Engineering in Medicine and Biology Society*. IEEE, 2009.
- [15] N. J. Hill *et al.*, Classifying Event-Related Desynchronization in EEG, ECoG and MEG Signals, *Lecture Notes in Computer Science*. Springer Berlin Heidelberg, pp. 404–413, 2006.
- [16] G. Strangman, D. A. Boas, and J. P. Sutton, *Non-invasive neuroimaging using near-infrared light*, **Biol. Psychiatry**, 52:7 (2002) 679–693.
- [17] J. R. Wolpaw, N. Birbaumer, D. J. McFarland, G. Pfurtscheller, and T. M. Vaughan, *Brain–computer interfaces for communication and control*, **Clin. Neurophysiol.**, 113:6 (2002) 767–791.
- [18] N. Hazarika, J. Z. Chen, A. C. Tsoi, and A. Sergejew, *Classification of EEG signals using the wavelet transform*, **Signal Processing**, 59:1 (1997) 61–72.
- [19] P. Tewarie *et al.*, *Structural degree predicts functional network connectivity: A multimodal resting-state fMRI and MEG study*, **Neuroimage**, 97 (2014) 296–307.
- [20] A. A. Ioannides, V. Poghosyan, J. Dammers, and M. Streit, *Real-time neural activity and connectivity in healthy individuals and schizophrenia patients*, **Neuroimage**, 23:2 (2004) 473–482.
- [21] B.-G. Lee, B.-L. Lee, and W.-Y. Chung, *Mobile Healthcare for Automatic Driving Sleep-Onset Detection Using Wavelet-Based EEG and Respiration Signals*, 14:10 (2014) 17915–17936.
- [22] M. Okamoto *et al.*, *Three-dimensional probabilistic anatomical cranio-cerebral correlation via the international 10–20 system oriented for transcranial functional brain mapping*, **Neuroimage**, 21:1 (2004) 99–111.
- [23] C. Kabdebon, F. Leroy, H. Simmonet, M. Perrot, J. Dubois, and G. Dehaene-Lambertz, *Anatomical correlations of the international 10–20 sensor placement system in infants*, **Neuroimage**, 99 (2014) 342–356.

- [24] M. van Gerven *et al.*, *The brain–computer interface cycle*, **J. Neural Eng.**, 6:4 (2009) 41001.
- [25] F. Lotte, M. Congedo, A. Lécuyer, F. Lamarche, and B. Arnaldi, *A review of classification algorithms for EEG-based brain–computer interfaces*, **J. Neural Eng.**, 4:2 (2007) R1–R13.
- [26] J.-P. Lachaux, N. Axmacher, F. Mormann, E. Halgren, and N. E. Crone, *High-frequency neural activity and human cognition: Past, present and possible future of intracranial EEG research*, **Prog. Neurobiol.**, 98:3 (2012) 279–301.
- [27] N. Weiskopf *et al.*, *Physiological self-regulation of regional brain activity using real-time functional magnetic resonance imaging (fMRI): methodology and exemplary data*, **Neuroimage**, 19:3 (2003) 577–586.
- [28] E. A. Allen, E. Damaraju, S. M. Plis, E. B. Erhardt, T. Eichele, and V. D. Calhoun, *Tracking Whole-Brain Connectivity Dynamics in the Resting State*, **Cereb. Cortex**, 24:3 (2012) 663–676.
- [29] A. S. Fleisher, A. Sherzai, C. Taylor, J. B. S. Langbaum, K. Chen, and R. B. Buxton, *Resting-state BOLD networks versus task-associated functional MRI for distinguishing Alzheimer’s disease risk groups*, **Neuroimage**, 47:4 (2009) 1678–1690.
- [30] T. Misawa, J. Matsuda, and S. Hirobayashi, *A Single-Trial Multiclass Classification of Various Motor Imagery Tasks for EEG-Based Brain-Computer Interface Communication*, **Electron. Commun. Japan**, 100:1 (2016) 18–26.
- [31] A. Ramos-Murguialday *et al.*, *Brain-machine interface in chronic stroke rehabilitation: A controlled study*, **Ann. Neurol.**, 74:1 (2013) 100–108.
- [32] A. Bashashati, M. Fatourehchi, R. K. Ward, and G. E. Birch, *A survey of signal processing algorithms in brain–computer interfaces based on electrical brain signals*, **J. Neural Eng.**, 4:2 (2007) R32–R57.
- [33] M. Fatourehchi, A. Bashashati, R. K. Ward, and G. E. Birch, *EMG and EOG artifacts in brain computer interface systems: A survey*, **Clin. Neurophysiol.**, 118:3 (2007) 480–494.
- [34] E. Donchin *et al.*, *The Relationship between P300 and the CNV*, *The Responsive Brain*. Elsevier, pp. 222–234, 1976.
- [35] S. Sutton, M. Braren, J. Zubin, and E. R. John, *Evoked-Potential Correlates of Stimulus Uncertainty*, **Science (80-.)**, 150:3700 (1965) 1187–1188.

- [36] R. K. Chikara and L.-W. Ko, Classification of EEG-P300 Signals Using Phase Locking Value and Pattern Recognition Classifiers, *2015 Conference on Technologies and Applications of Artificial Intelligence (TAAI)*. IEEE, 2015.
- [37] I. Volosyak, F. Gembler, and P. Stawicki, *Age-related differences in SSVEP-based BCI performance*, **Neurocomputing**, 250 (2017) 57–64.
- [38] H. Macpherson, A. Pipingas, and R. Silberstein, *A Steady State Visually Evoked Potential Investigation of Memory and Ageing*, **Brain Cogn.**, 69:3 (2009) 571–579.
- [39] B. Allison, T. Luth, D. Valbuena, A. Teymourian, I. Volosyak, and A. Graser, *BCI Demographics: How Many (and What Kinds of) People Can Use an SSVEP BCI?*, **IEEE Trans. Neural Syst. Rehabil. Eng.**, 18:2 (2010) 107–116.
- [40] F.-B. Vialatte, M. Maurice, J. Dauwels, and A. Cichocki, *Steady-state visually evoked potentials: Focus on essential paradigms and future perspectives*, **Prog. Neurobiol.**, 90:4 (2010) 418–438.
- [41] H.-J. Hwang, J.-H. Lim, Y.-J. Jung, H. Choi, S. W. Lee, and C.-H. Im, *Development of an SSVEP-based BCI spelling system adopting a QWERTY-style LED keyboard*, **J. Neurosci. Methods**, 208:1 (2012) 59–65.
- [42] L. E. Roberts, N. Birbaumer, B. Rockstroh, W. Lutzenberger, and T. Elbert, *Self-Report During Feedback Regulation of Slow Cortical Potentials*, **Psychophysiology**, 26:4 (1989) 392–403.
- [43] U. Leins, G. Goth, T. Hinterberger, C. Klinger, N. Rumpf, and U. Strehl, *Neurofeedback for Children with ADHD: A Comparison of SCP and Theta/Beta Protocols*, **Appl. Psychophysiol. Biofeedback**, 32:2 (2007) 73–88.
- [44] M. Arns, H. Heinrich, and U. Strehl, *Evaluation of neurofeedback in ADHD: The long and winding road*, **Biol. Psychol.**, 95 (2014) 108–115.
- [45] N. Cristianini and J. Shawe-Taylor, *An Introduction to Support Vector Machines and Other Kernel-based Learning Methods*, Cambridge University Press, 2000 .
- [46] Y. Zhang, M. Xiang, and B. Yang, *Graph regularized nonnegative sparse coding using incoherent dictionary for approximate nearest neighbor search*, **Pattern Recognit.**, 70 (2017) 75–88.
- [47] H. Jégou, M. Douze, and C. Schmid, *Product Quantization for Nearest Neighbor Search*, **IEEE Trans. Pattern Anal. Mach. Intell.**, 33:1 (2011) 117–128.

- [48] C. Li et al., *Using the K-Nearest Neighbor Algorithm for the Classification of Lymph Node Metastasis in Gastric Cancer*, **Comput. Math. Methods Med.**, 2012 (2012) 1–11.
- [49] C. Ding and H. Peng, *Minimum Redundancy Feature Selection From Microarray Gene Expression Data*, **J. Bioinform. Comput. Biol.**, 3:2 (2005) 185–205.
- [50] L. Wang and Y. He, *A New Web Service Ranking Method Based on QoS Independent Components and ANN*, *2010 International Conference on Computational Intelligence and Software Engineering*. IEEE, 2010.
- [51] S. M. J. Pappu and S. N. Gummadi, *Artificial Neural Network and Regression Coupled Genetic Algorithm to Optimize Parameters for Enhanced Xylitol Production By Debaryomyces Nepalensis in Bioreactor*, **Biochem. Eng. J.**, 120 (2017) 136–145.
- [52] Q. Yang, S. Le Blond, R. Aggarwal, Y. Wang, and J. Li, *New ANN method for multi-terminal HVDC protection relaying*, **Electr. Power Syst. Res.**, 148 (2017) 192–201.
- [53] D. Niebur and A. J. Germond, *Power flow classification for static security assessment*, *Proceedings of the First International Forum on Applications of Neural Networks to Power Systems*. IEEE.
- [54] G. Yang, *A Novel Method for Mining Association Rules from Continuous Attributes Based on Cultural Immune Algorithm*, **J. Inf. Comput. Sci.**, 10:9 (2013) 2845–2853.
- [55] N. M. Hewahi and E. Abu Hamra, *A Hybrid Approach Based on Genetic Algorithm and Particle Swarm Optimization to Improve Neural Network Classification*, **J. Inf. Technol. Res.**, 10:3 (2017) 48–68.
- [56] *9 Analysis of Sequences: Power Spectra and Periodograms*, *Data Analysis for Scientists and Engineers*. Princeton University Press, 2016.
- [57] D. H. Evans, *Doppler signal analysis*, **Ultrasound Med. Biol.**, 26 (2000) S13–S15.
- [58] P. J. Vaitkus, R. S. C. Cobbold, and K. W. Johnston, *A comparative study and assessment of doppler ultrasound spectral estimation techniques part II: Methods and results*, **Ultrasound Med. Biol.**, 14:8 (1988) 673–688.
- [59] *Book Reviews Bendectin and Birth Defects*, reviewed by S. Bartlett Foote * *The Mismeasure of Man* * *The World According to Wavelets* * *Wavelets* * *Vignette*

* *Books Received*, **Science (80-.)**, 273:5272 (1996) 196–197.

- [60] A. Aballe, M. Bethencourt, F. J. Botana, and M. Marcos, *Using wavelets transform in the analysis of electrochemical noise data*, **Electrochim. Acta**, 44:26 (1999) 4805–4816.
- [61] P. A. Hwang, *Doppler frequency shift in ocean wave measurements: Frequency downshift of a fixed spectral wave number component by advection of wave orbital velocity*, **J. Geophys. Res.**, 111:C6 (2006).
- [62] N. E. Huang, S. R. Long, and Z. Shen, *The Mechanism for Frequency Downshift in Nonlinear Wave Evolution*, *Advances in Applied Mechanics*. Elsevier, p. 59–117C, 1996.
- [63] F. G. Schmitt, Y. Huang, Z. Lu, S. Z. Brizard, J. C. Molinero, and Y. Liu, *Analysis of Nonlinear Biophysical Time Series in Aquatic Environments: Scaling Properties and Empirical Mode Decomposition*, *Nonlinear Dynamics in Geosciences*. Springer New York, pp. 261–280.
- [64] L. Cui, B. Xue, and F. Zhou, *Atmospheric turbulence MTF for infrared optical waves' propagation through marine atmospheric turbulence*, **Infrared Phys. Technol.**, 65 (2014) 24–29.
- [65] N. Naseer and K.-S. Hong, *fNIRS-based brain-computer interfaces: a review*, **Front. Hum. Neurosci.**, 9 (2015).
- [66] G. Pfurtscheller and R. Cooper, *Frequency dependence of the transmission of the EEG from cortex to scalp*, **Electroencephalogr. Clin. Neurophysiol.**, 38:1 (1975) 93–96.
- [67] T. Funane *et al.*, *Quantitative evaluation of deep and shallow tissue layers' contribution to fNIRS signal using multi-distance optodes and independent component analysis*, **Neuroimage**, 85 (2014) 150–165.
- [68] H. Sato *et al.*, *A NIRS–fMRI investigation of prefrontal cortex activity during a working memory task*, **Neuroimage**, 83 (2013) 158–173.
- [69] H. H. Yang and S. Amari, *A stochastic natural gradient descent algorithm for blind signal separation*, *Neural Networks for Signal Processing VI. Proceedings of the 1996 IEEE Signal Processing Society Workshop*. IEEE.
- [70] *Time-Frequency Synthesis and Filtering*, *Time-Frequency Signal Analysis and Processing*. Elsevier, pp. 637–691, 2016.
- [71] A. V Oppenheim and R. W. Schafer, *Zeitdiskrete Signalverarbeitung*, De Gruyter, 1998 .

- [72] A. Widmann, E. Schröger, and B. Maess, *Digital filter design for electrophysiological data – a practical approach*, **J. Neurosci. Methods**, 250 (2015) 34–46.
- [73] J. del R. Millan and J. Mourino, *Asynchronous bci and local neural classifiers: an overview of the adaptive brain interface project*, **IEEE Trans. Neural Syst. Rehabil. Eng.**, 11:2 (2003) 159–161.
- [74] M. Kaper, P. Meinicke, U. Grossekhoefer, T. Lingner, and H. Ritter, *BCI Competition 2003—Data Set Iib: Support Vector Machines for the P300 Speller Paradigm*, **IEEE Trans. Biomed. Eng.**, 51:6 (2004) 1073–1076.
- [75] A. Rakotomamonjy, V. Guigue, G. Mallet, and V. Alvarado, *Ensemble of SVMs for Improving Brain Computer Interface P300 Speller Performances*, *Artificial Neural Networks: Biological Inspirations – ICANN 2005*. Springer Berlin Heidelberg, pp. 45–50, 2005.
- [76] T. Wang, J. Deng, and B. He, *Classifying EEG-based motor imagery tasks by means of time–frequency synthesized spatial patterns*, **Clin. Neurophysiol.**, 115:12 (2004) 2744–2753.
- [77] T. Pranckevičius and V. Marcinkevičius, *Comparison of Naive Bayes, Random Forest, Decision Tree, Support Vector Machines, and Logistic Regression Classifiers for Text Reviews Classification*, **Balt. J. Mod. Comput.**, 5:2 (2017).
- [78] L. R. Rabiner, *A tutorial on hidden Markov models and selected applications in speech recognition*, **Proc. IEEE**, 77:2 (1989) 257–286.

ÖZGEÇMİŞ

Adı Soyadı: Harun ÇİĞ

Doğum Yeri ve Tarihi: Malatya-1991

Adres: Harran Üniversitesi Mühendislik Fakültesi Bilgisayar Mühendisliği Bölümü,
Haliliye/Şanlıurfa

E-Posta: haruncig@harran.edu.tr

Lisans: Mustafa Kemal Üniversitesi Bilgisayar Mühendisliği Bölümü (2010-2014)

Mesleki Deneyim: Harran Üniversitesi (2017- Devam Ediyor)

TEZDEN TÜRETİLEN YAYINLAR SUNUMLAR

- Cig H., Hanbay D. (2017)., Classification of Visual Stimuli for SSVEP-Based Brain Computer Interface, *International Conference on Advances and Innovations in Engineering*, Fırat University ,May 10-12 .
- Cig H., Hanbay D., Tuysuz M. F.(2017)., Robot Arm Control With for SSVEP-Based Brain Signals In Brain Computer Interface, *International Artificial Intelligence and Data Processing Symposium '17*, İnönü University, September 16-17.
- Cig H.,Tüysüz M.F.(2017), Performance Analysis of EEG Signal Classification and SSVEP in OpenVibe, *3rd International Conference on Science Ecology and Technology*, Rome-Italy, August 14-16.