

**BEYİN BİLGİSAYAR ARA YÜZ SİSTEMİNDE UYGULANAN
STEADY-STATE GÖRSEL UYARILMIŞ POTANSİYEL İÇİN
ÖZELLİK ÇIKARMA VE SINIFLANDIRMA**

Akbar ALIPOUR

**YÜKSEK LİSANS TEZİ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ**

**GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**HAZİRAN 2011
ANKARA**

Akbar ALIPOUR tarafından hazırlanan “BEYİN BİLGİSAYAR ARA YÜZ SİSTEMİNDE UYGULANAN STEADY-STATE GÖRSEL UYARILMIŞ POTANSİYEL İÇİN ÖZELLİK ÇIKARMA ve SINIFLANDIRMA” adlı bu tezin yüksek lisan tezi olarak uygun olduğunu onaylarım.

Yrd. Doç. Dr. Fırat HARDALAÇ

Tez danışmanı, Elektrik Elektronik Mühendisliği Anabilim Dalı

Bu çalışma, jürimiz tarafından oy birliği ile Elektrik-Elektronik Mühendisliği Anabilim Dalında Yüksek Lisans Tezi olarak kabul edilmiştir.

Prof. Dr. Mübeccel DEMİREKLER

Elektrik Elektronik Mühendisliği Anabilim Dalı, ODTÜ

Yar. Doç. Dr. Fırat HARDALAÇ

Elektrik Elektronik Mühendisliği Anabilim Dalı, G.Ü.

Prof. Dr. M. Cengiz TAPLAMACIOĞLU

Elektrik-Elektronik Mühendisliği Anabilim Dalı, G.Ü.

Tarih: 08/06/2011

Bu tez ile G.Ü. Fen Bilimleri Enstitüsü Yönetim Kurulu Yüksek Lisan derecisini onaylamıştır.

Prof. Dr. Bilal TOKLU

Fen Bilimleri Enstitüsü Müdürü

TEZ BİLDİRİMİ

Tez içindeki tüm bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edilerek sunulduğunu, ayrıca tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

Akbar ALIPOUR

**BEYİN BİLGİSAYAR ARA YÜZ SİSTEMİNDE UYGULANAN STEADY-
STATE GÖRSEL UYARILMIŞ POTANSİYELİ İÇİN ÖZELLİK ÇIKARMA
VE SINIFLANDIRMA
(Yüksek Lisans Tezi)**

Akbar ALIPOUR

**GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
Haziran 2011**

ÖZET

Beyin bilgisayar ara yüz sistemleri hiçbir harekete gerek kalmadan, insanlara mesaj veya komut göndermeyi sağlıyor. Ayrıca felç olan kişilere dış dünyayla irtibatına imkân yaratıyor. Bu çalışmada beyinden elde edilen steady-state görsel uyarılmış potansiyel (SSVEP) sinyallerin üzerinde çeşitli işaret işleme yöntemleri incelenmiştir. Süzgeçleme, özellik çıkarma, sınıflandırma elde edilen sinyallerin işaret işleminde önemli aşamalarından sayılmaktadır. Süzgeçleme için Butterworth süzgeçleme, Uygulamalı Süzgeç, LMS Algoritması ele alınmıştır. Özellik çıkarmada TF- tabanlı özellik çıkarma and Single Value distribution (SVD) kullanılan önemli yöntemlerden sayılmaktadır. Sınıflandırmada K En Yakın Komşuluk, sinaptik sinir ağında Dalgacık Dönüşüm Paketi, Destek Vektör Makineleri göz önünde bulunmuştur. Daha sonra Graz Teknik Üniversitesi beyin bilgisayar ara yüz labın dan elde edilen gerçek SSVEP sinyaller işleme alınıp ve sonuçlar kıyaslanarak önemli bilgiler elde edilmiştir.

Bilim kodu : 905.1.021
Anahtar sözcükler : Steady-state görsel uyarılmış potansiyel, öznitelik çıkarım, beyin bilgisayar ara yüzü, sınıflandırma, data çıkarma, motor imagery, Elektroansefalografi, süzgeçleme
Sayfa adedi : 70
Tez Yöneticisi : Yrd. Doç. Dr. Fırat HARDALAÇ

**FEATURE EXTRACTION AND CLASSIFICATION OF STEADY-STATE
VISUAL EVOKED POTENTIAL IN APPLICATION FOR BRAIN
COMPUTER INTERFACE SYSTEMS
(M.Sc. Thesis)**

Akbar ALIPOUR

**GAZI UNIVERSITY
INSTITUTE OF NATURAL AND APPLIED SCIENCE**

June 2011

ABSTRACT

Brain Computer Interface (BCI) system improves people ability to send messages and commands without movement, in the same time BCI system assists disabled people to contact with their environment by removing motor function limitation. In this study, different signal processing methods are applied over steady-state visual evoked potential (SSVEP) signals, induced from brain electrical activity. Filtering, feature extraction, classification are main steps of signal processing. For filtering; Butterworth filter, applied filter, LMS algorithm are investigated. TF- based feature extraction and Single Value distribution (SVD) are used for feature extraction. For classification K-Nearest Neighbor, wavelet transform packet and vector machine methods are concentrated. The result of these methods is investigated over acquired real data from laboratory of technical university of Graz. The results are compared to each other and significant information is obtained.

Science Code : 905.1.021
Key Words : Steady state visual evoked potential, Brain computer interface, feature extraction, classification, data acquisition, filtering, motor imagery, electroencefalography
Page Number : 70
Adviser : Assit. Prof. Fırat HARDALAÇ

TEŐEKKÜR

Çalıőmalarım boyunca deęerli yardım ve katkılarıyla beni yönlendiren hocam Yar. Doç. Dr. Fırat HARDALAÇ 'a sonsuz teőekkürlerimi bildirmek istiyorum. Ayrıca bu çalıőmada bana yardımcı olan ve destek veren, deęerli Prof. Dr. Mübeccel DEMİREKLER, Doç. Dr. Bülent YILMAZ' a ve Uęur CUNEYTOęLU' ya teőekkür etmek isterim.

İÇİNDEKİLER

	Sayfa
ÖZET.....	iv
ABSTRACT.....	v
TEŞEKKÜR.....	vi
İÇİNDEKİLER.....	vii
ÇİZİLGELERİN LİSTESİ.....	viii
ŞEKİLLERİN LİSTESİ.....	ix
RESİMLERİN LİSTESİ.....	x
SİMGELER ve KISALTMALAR.....	xi
1. GİRİŞ.....	1
2. ELEKTROANSEFALOGRAFİNİN (EEG) BİYOFİZİK YAPISI.....	3
2.1. Beynin İşlevleri ve Elektriksel Aktivite.....	3
2.2. Merkezi Sinir Sistemi (MSS).....	3
2.2.1. Beyin sapı.....	4
2.2.2. Beyincik.....	4
2.2.3. Cerebrum.....	5
2.3. EEG'nin Nörofizyolojik Esasları.....	5
2.3.1. Postsinaptik potansiyel (PSP).....	7
2.3.2. İnhibitör postsinaptik potansiyel (IPSP).....	7
3. BEYİN ELEKTRİKSEL AKTİVİTESİ VE EEG.....	9
3.1. Elektroansefalografi (EEG).....	9
3.2. Elektroansefalografi Tarihçesine Bakış.....	10

Sayfa

3.3. EEG nin Kullanım Alanı.....	10
3.3.1. EEG sinyallerinin gözlenmesi.....	11
3.4. EEG Sinyal Özellikleri.....	11
3.5. EEG de Elektrot Konumları.....	12
3.6. Elektro-Kartiyografi (ECoG).....	13
3.7. EEG Dalgaları.....	14
3.7.1. Delta (δ) dalgaları.....	14
3.7.2. Teta (θ) dalgaları.....	15
3.7.3. Alfa (α) dalgaları.....	15
3.7.4. Beta (β) dalgaları.....	16
3.8. Beyin Elektriksel Aktivite Haritası.....	16
3.9. Magnetoansefalografi (MEG).....	17
3.9.1. MEG ve EEG nin kıyaslaması.....	17
3.10. Biyolojik Geri Bildirim (Biofeedback) ve EEG.....	18
4. EEG VE BEYİN BİLGİSAYAR ARA YÜZ (BBA).....	20
4.1. BBA.....	20
4.2. EEG tabanlı BBA.....	20
4.3. P300 Tabanlı BBA.....	21
4.4. Steady State Visual Evoked Potentials – SSVEP.....	22
4.5. Beynin duyu – motor değişimi.....	22
4.6. EEG eğrilerinin değerlendirme yöntemleri.....	23
4.7. Uyarılmış Potansiyeller.....	24
4.7.1. EEG verileri.....	24

	Sayfa
4.7.2. Beyin işlevlerinin lokalize edilmesi.....	24
4.8. EEG Tekniklerinin Uygulamaları.....	26
4.9. Niceleştirilmiş EEG.....	27
5. BBA SİSTEMLERİNDE SİNYAL İŞLEME.....	29
5.1. BBA Sistemlerinde Elektroansefalografinin Kullanımı	29
5.1.1. BBA nın Tanımı.....	29
5.2. Butterworth süzgeçleme yöntemi.....	31
5.3. Uygulamalı Süzgeç.....	32
5.4. LMS Algoritması.....	33
5.5. Öznitelik Çıkarımı.....	36
5.5.1. TF- tabanlı öznitelik çıkarımı.....	36
5.5.2. SVD.....	36
5.5.3. TF-Tabanında SVs kullanımıyla sinyal karakterize etme.....	37
5.6. Ortalama.....	38
5.7. Sınıflandırma.....	40
5.7.1. K En Yakın Komşuluk.....	41
5.7.2. Dinamik Sinaps Sinir Ağları.....	41
5.7.3. Destek Vektör Makineleri.....	44
6. SONUÇ VE ÖNERİLER.....	47
6.1. LMS Algoritması İçin Doğrulama Sonuçlar.....	48
6.2. SSVEP-Tabanlı BBA'de Dataset II Denemesi.....	54
6.2.1. Deney açıklaması.....	54
6.2.2. Özelliklerin açıklaması.....	55

	Sayfa
6.2.3. Ön hesaplanmış özelliklerin sonuçları.....	56
6.2.4. SVM Sınıflandırma için doğrulama Sonuçlar.....	57
6.3. Sinaptik Sinir Ağları Sınıflandırma İçin Doğrulama Sonuçları.....	59
KAYNAKLAR.....	63
ÖZGEÇMİŞ.....	70

ÇİZELGELERİN LİSTESİ

Çizelge	Sayfa
Çizelge 6.1. Tek boyutlu özelliği (F1) kullanan deneyler için elde edilen Değerler.....	54
Çizelge 6.2. İki boyutlu özelliği (F2) kullanan deneyler için elde edilen Değerler.....	54
Çizelge 6.3. Bir deney için, eğitim verileri üzerinde farklı γ , C ve PCA katsayıları kombinasyonu, doğrulama ayrı.....	57
Çizelge 6.4. Deney Üzerinde farklı düğüm sayısı ve PCA-katsayı, kombinasyonları için eğitim verileri üzerinde hesaplamalar.....	59
Çizelge 6.5. DSSA Sınıflandırmasıyla ilgili sonuçlar	60
Çizelge 6.6. SSA ve DVM sınıflandırma yöntemlerinin karşılaştırılması	60

ŞEKİLLER LİSTESİ

Şekil	Sayfa
Şekil 2.1. Cerebrumun farklı anatomik kesimleri ve beyin şematik yapısı ve bazı bölgeleri ve beyin kabuğunda (cortex) alanlar	6
Şekil 2.2. Nöron, synaps, postsinaptik potansiye.....	6
Şekil 3.1. EEG’de Elektrot Konumları	18
Şekil 3.2. EEG birleşeninde Delta dalgası.....	14
Şekil 3.3. EEG birleşeninde Teta dalgası.....	15
Şekil 3.4. EEG birleşeninde Alfa dalgası.....	15
Şekil 3.5. EEG bileşeninde farklı dalga şekilleri, şekelinde görüldüğü gibi dalgalar farklı frekanslara sahipler.....	16
Şekil 4.1. Beyin bilgisayar ara yüzü nün temel bileşenleri	21
Şekil 4.2. İşitsel uyarılmış potansiyeller	26
Şekil 5.1. Beyin bilgisayar ara yüzünde sinyal işleme şeması	29
Şekil 5.2. Sınıflandırma için geliştirilmiş ortalama yönteminin Şeması	40
Şekil 5.3. İki ayrı kanalın etkileşiminden oluşabilecek Kanallardaki latans farklılıklarının toplam SSVEP sinyaline etkileri.....	41
Şekil 5.4. (a) Örnek bir EEG dalga (b) Dalgacık paket ayrıştırması.....	43
Şekil 5.5. Maksimum marjinli hiperdüzlem.....	44
Şekil 6.1. Bir SSVEP-EEG işaretinin zamana göre değişimi	48
Şekil 6.2. Gürültülü SSVEP-EEG işareti	49
Şekil 6.3. Gürültülü SSVEP-EEG işaretinin Uyarlamalı süzgeç çıkışı.....	49
Şekil 6.4. Gürültülü SSVEP- EEG işaretinin güç spektrumu	50
Şekil 6.5. Uyarlamalı süzgeç çıkışından alınan işaretin güç spektrumu	50
Şekil 6.6. 26 yaşındaki bir deneyden alınan normal EEG işareti	51

Şekil 6.7. Gürültü bindirilmiş normal EEG işareti	52
Şekil 6.8. Gürültülü normal EEG işaretinin süzgeç çıkışı	52
Şekil 6.9. Gürültü bindirilmiş normal EEG işaretinin güç spektrumu.....	53
Şekil 6.10. Gürültüden arındırılmış normal EEG işaretinin güç spektrumu.....	53

RESİMLER LİSTESİ

Resim	Sayfa
Resim 3.1. Elektrot ve kayıt biçiminde bağlı olarak beyinden ve beyin hücrelerinden kayıt edilebilecek elektriksel sinyaller	13
Resim 3.2. EEG ile ilgili biyolojik geri bildirim.....	18

SİMGELER ve KISATILMALAR

Bu çalışmada kullanılmış bazı simgeler ve kısaltılmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

Simgeler	Açıklama
E	Beyin ağırlılığı
P	Vücut ağırlılığı
δ	Delta dalgası
θ	Teta dalgası
α	Alfa dalgası
β	Beta dalgası
F	Frekans
T	Perido süresi
$V_i(t)$	Doğal fon aktivitesi
$e(t)$	Uyarılmış aktiviteye
$W(n)$	Değişen ağırlaştırıcı katsayı vektörü
μ	Adım boyu parametresi
λ	Giriş oto korelasyon matrisinin öz değerleri
P	Ölçekli indeksi
L	Çeviri indeksi
h	Low-pass filtre
g	High-pass fitler

Kısaltılmalar	Açıklama
BBA	Beyin Bilgisayar Ara yüzü
EEG	Elektroansefalografi
MSS	Merkezi Sinir Sistemi
FM	Frekans Modülasyonlu
PSP	Postsinaptik Potansiyel
IPSP	İnhibitör Postsinaptik Potansiyel
EPSP	Eksitator postsinaptik potansiyel
DC	Doğru akım
REM	Devamlı göz hareketidir
CT	Bilgisayarlı Tomografi
MR	Manyetik Rezonans
ECoG	Elektro-Kartiyografi
MEG	Magnetoansefalografi
ALS	Amiyotrofik Lateral Sklerozis
SSVEP	Steady State Visual Evoked Potentials
LMS	Least Mean Square
DAQ	Veri Toplama Kartı
FFT	Hızlı Fourier Dönüşümü
TFD	Zaman - frekans dağılımı
RID	Düşük girişim dağılımları
SVD	Single Value distribution
SV	Single Value

TZ

Zaman – Frekans

DVM

Destek Vektör Makineleri

RTK

Radyal tabanlı kernel

1. GİRİŞ

Beyin Bilgisayar Ara yüz (BBA), kişinin sadece beyin aktivitesini yorumlayarak bazı elektronik cihazların kontrol edilebilmesini amaçlayan bir sistem ve bir araştırma konusudur. Bu sistem ile, felç nedeniyle vücudunun büyük bir kısmını kontrol edemeyen fakat bilinci açık olan kişilerin dış dünya ile iletişim kurabilmeleri, tekerlekli sandalye, bilgisayar gibi cihazları düşünerek ve odaklanarak kontrol etmeleri mümkündür [15]. Basit olarak, beyindeki bazı nörofizyolojik olguların algılanmasına dayanan bu sistemin temel yapı taşlarını, biyoaktivite ölçüm donanımları, sinyal işleme yöntemleri ve örüntü sınıflandırma algoritmaları oluşturmaktadır. BBA konusunda dünyada yapılan çalışmalar 30 yıllık bir geçmişe sahiptir. Ülkemizde de son 10 sene içinde bu alanda gerçekleştirilen çalışmalar mevcuttur.

BBA araştırmalarında birçok non-invaziv ve invaziv sinyal elde etme teknikleri kullanılmaktadır. Non-invaziv elektroensefalografi (EEG) ve magnetoensefalografi (MEG) de, beyin elektromanyetik faaliyeti, kafatası üzerine yerleştirilen elektrotlar ile ölçülür. İnvazif elektrokortikografi (ECOG), tek mikro elektrot (ME), mikro-elektrot dizi (MEA) ve yerel alan potansiyelleri (LFPs), yöntemlerinde, beyin kortikal aktivitesini ölçmek için elektrotlar kafatası içine cerrahi olarak yerleştirilir. Fonksiyonel Manyetik Rezonans Görüntüleme (fMRI) ve Yakın Kızılötesi Spektroskopi (NIRS) yöntemlerinde, beyin kan oksijenlenme düzeyi bölgesel değişiklikleri non-invaziv olarak algılanır. Bu yöntemler BBA araştırmalarında kullanılan non-invaziv yöntemlerdir. Bu teknikler arasında EEG, donanım düşük maliyetli, düşük riskli ve taşınabilirlik nedeniyle, bu çalışmada tercih edilir. Aynı zamanda temporal çözünürlük online BBA uygulamalar için yeterince yüksek.

BBA uygulamalar için yararlı olduğu gösterilmiş, çeşitli nörofizyolojik mekanizmalar mevcuttur. Bu mekanizmalar bir olay veya bir olaydan bağımsız konulara göre beynin oluşturduğu yanıtı olabilir. Bu mekanizmalar arasında Stady-State Visual Evoked Potential (SSVEP), bu çalışmada ele alınmaktadır. BBA uygulamalarda, dış dünya ile etkileşim sağlamak için, SSVEP sinyalleri kontrol sinyallerine dönüştürülür.

SSVEP sinyalleri BBA kontrol sinyallerine dönüştürmek için çeşitli sinyal işleme teknikleri literatürde kullanılmıştır. Bu teknikler üç adımda analiz edilebilir. Birincisi işaret geliştirme adımdır. Bu bölümde sinyal kalitesi örnekleme, filtreleme, vb gibi teknikler uygulanarak artırılır. İkinci adım öznitelik çıkarımıdır. Bu bölümde, uygulama için gerekli bilgileri data set'ten elde edilir. Son adım sınıflandırmadır, bu aşamada bir önceki adımda elde edilen özelliklerini kullanarak, alınan sinyaller çeşitli sınıflara ayrılırlar. Böylece bir kontrol sinyali ilgili uygulamaya dönüştürülür. Özellikle bu çalışmada, Butterworth, Uygulamalı süzgeç ve Least Means Square (LMS) süzgeçleme yöntemini kullanarak, EEG sinyallerinin işleminde kolaylık saydık. Öznitelik çıkarımı için; TF- Tabanlı özellik çıkarımı, Single Value Decomposition (SVD), TF-Tabanında SVs Kullanımıyla Sinyal Karakterize Etme yöntemleri uygulanmaktadır. K En Yakın Komşuluk, Dinamik Sinaps Sinir Ağları ve Destek Vektör Makineleri (DVM) yöntemleri sınıflandırma için düşünülmüştür. Daha sonra bu yöntemlerin performansı data set II de değerlendirilmiştir.

Bu çalışmada, felçli kişilere, çevresel cihazları kontrol etmek için yardımcı olan bir SSVEP-Tabanlı BBA tasarlanmıştır ve tasarım için bir test uygulaması yapılmaktadır.

Tez, tanıtım bölümünde BBA sistemlerinin literatürde araştırmasıyla başlar. Bölüm 2 ve 3'te sırasıyla beyin nerofizyolojik aktivitesi ve Elektroansefalografi'nin (EEG) temel bileşenleri ile ilgili bilgiler verilmektedir. Daha sonra bölüm 4'te BBA temeli ile ilgili bahis edilmekte. Bölüm 5'te, BBA araştırmalarında sinyal işleme teknikleri incelenmiştir, özellikle bu çalışmada uygulanan yöntemlerin üzerinde detaylı şekilde odaklanmıştır. Son olarak bölüm 6'da deneyler ve sonuçlar vurgulanmıştır.

1. ELEKTROANSEFALOGRAFNN (EEG) BİYOFİZİK YAPISI

1.1. Beynin İşlevleri ve Elektriksel Aktivitesi

Hayvanlarda beyin, merkezi kontrol organı olarak, tüm diğer organların işlevlerini denetler ve yönetir. Bu işlevlerini yürütürken, beyin faaliyetlerine elektriksel olayların eşlik ettiği yüzyılımızın başlarından beri bilinmektedir. Kafatası çevresinde yerleştirilen elektrotlar yardımı ile, beyin faaliyeti sırasında kendiliğinden oluşan, sürekli ritmik elektriksel potansiyel değişimlerinin veya reseptör faaliyetlerine bağlı olarak uyarılmış (Evoked) durumda iken biraz daha farklı olan potansiyel değişimlerinin yazdırılması yöntemine elektroensefalografi (EEG) denir. Fiziksel anlamda tam periyodik olmayan, ancak ritmik olarak adlandırılan bu potansiyel dalgalanmalarının frekansları, beynin aktivite durumuna göre, 0,5-70 Hz arasında, genlikleri ise 5-400 μV arasında değişir[5]. İnsan veya hayvanın canlılığı sürdükçe, EEG sinyalleri her koşul altında gözlenir. EEG eğrilerinin biçimi ise beyin fizyolojik ve psikolojik koşullarına bağlı olduğu gibi kayıtlama biçimine de bağlıdır.

1.2. Merkezi Sinir Sistemi (MSS)

Beyin ve omurilikten (medulla spinalis) oluşur. Çeşitli biyolojik reseptörler tarafından vücudun dış ve iç ortamı hakkında derlenen enformasyon, MSS' inde çıkan veya duyuşal yol olarak adlandırılan sinirsel yollarla omurilikten beyne doğru taşınır. Benzer şekilde MSS' inde inen veya motor yol olarak adlandırılan yollarla, beynin değişik kesimlerinden kaynaklanan enformasyonlar, omuriliğin ön boynuzundaki moto-nöronlarda sonlanırlar [4]. Moto-nöronlar iskelet kaslarının aktivitelerini denetlerler. Böylece bu iki yöllü iletişim ağı ile beyin, çevresel olaylar hakkında bilgi alır, çevresel uyarılara karşı spinal reflex şeklindeki yanıtları denetler ve değiştirir. Beyne doru frekans modülasyonlu (FM) sinir uyarıları sağanağı şeklinde gelen enformasyon ulaştığı bölgedeki diğer nöronları aktive eder. Benzer şekilde, dış uyarılara karşı alınan motor eylem kararı, eyleme göre, beyin çeşitli alanlarındaki nöronların aktiviteleri olarak kendini gösterir. Beyindeki nöronların her tür aktivitelerinin hacim iletkeninde oluşturduğu potansiyel

değişimleri EEG olarak kaydedilir. MSS' in üç temel işlevi vardır:

- Duyusal enformasyonların alınması.
- Nöronlar arası bağlantılarla enformasyonun entegrasyonu ve işlenmesi.
- Kaslar ve bezler gibi uygulayıcı organlara enformasyon gönderilmesi.

Beynin belirli bir kesimi belirli bir işlevde başat rol üstlenirse de bu işlevle ilgili olarak diğer kesimlerine de bazı görevler almaktadır. Bunlar, yapısal ve işlevsel bakımdan, beyin sapı (truncus encephali, brain stem), beyincik (cerebellum) ve cerebrum şeklinde üç ana parça olarak düşünülmektedir.

1.2.1. Beyin sapı

Omuriliğin kısa bir uzantısıdır ve aşağıdan yukarıya doğru üç kesime ayrılır. Bu kesimler:

- Solunum, kalp ve böbrek fonksiyonlar gibi bazı önemli işlevlerin kontrolünde entegrasyonunda rol alan soğan ilik (medulla oblongata).
- Daha çok, beyincik, omurilik ve beyin kabuğu (cerebral cortex) arasında bağlantıları sağlayan pons.
- Orta beyin (mesencephalon).


Orta beynin biraz üstünde ve öne doğru thalamus ve hypothalamus bulunur. Thalamus, canlılık için gerekli her türlü duyusal ve motor değerlendirmelerin yapıldığı yerdir. Hypotalamus ise otonom sistem ile endoktrin sistemi kontrol ve entegre eder. Örneğin vücut sıcaklığı, kan basıncı, nabız vb. Parametrelerin düzenlemesi işlevleri hypotalamus tarafından yönetilir.

1.2.2. Beyincik

Beyin kabuğu ve beyin sapı ile işbirliği içinde, dengeyi sürdürmek ve uyumlu hareketleri sağlamak üzere, istemli kas sisteminin eylemlerini koordine etmektedir.

1.2.3. Cerebrum

Orta beyin, thalamus ve hypothalamusu tamamen kapsar. Yapısı aynı, ancak insan da işlevleri biraz farklı olan sağ ve sol beyin yarı kürelerini bağlayan kesime corpus callosum adı verilir. Beyinde üst düzey faaliyetlerin sürdüğü ve nöronların yaklaşık $\frac{3}{4}$ ünü içeren, cerebrumun dış yüzeyi beyin kabuğu (cortex cerebri, cerebral cortex) olarak adlandırılır. Bütün duyuşsal enformasyonlar, sonunda beyin kabuğuna ulaşır. Beyin kabuğunun bazı alanları ise motor işlevlerle ilgilidir. Cerebrumun farklı anatomik kesimleri ile beyin kabuğunun bazı duyuşsal ve motor alanları Şekil 2.1 de görülmektedir [11].

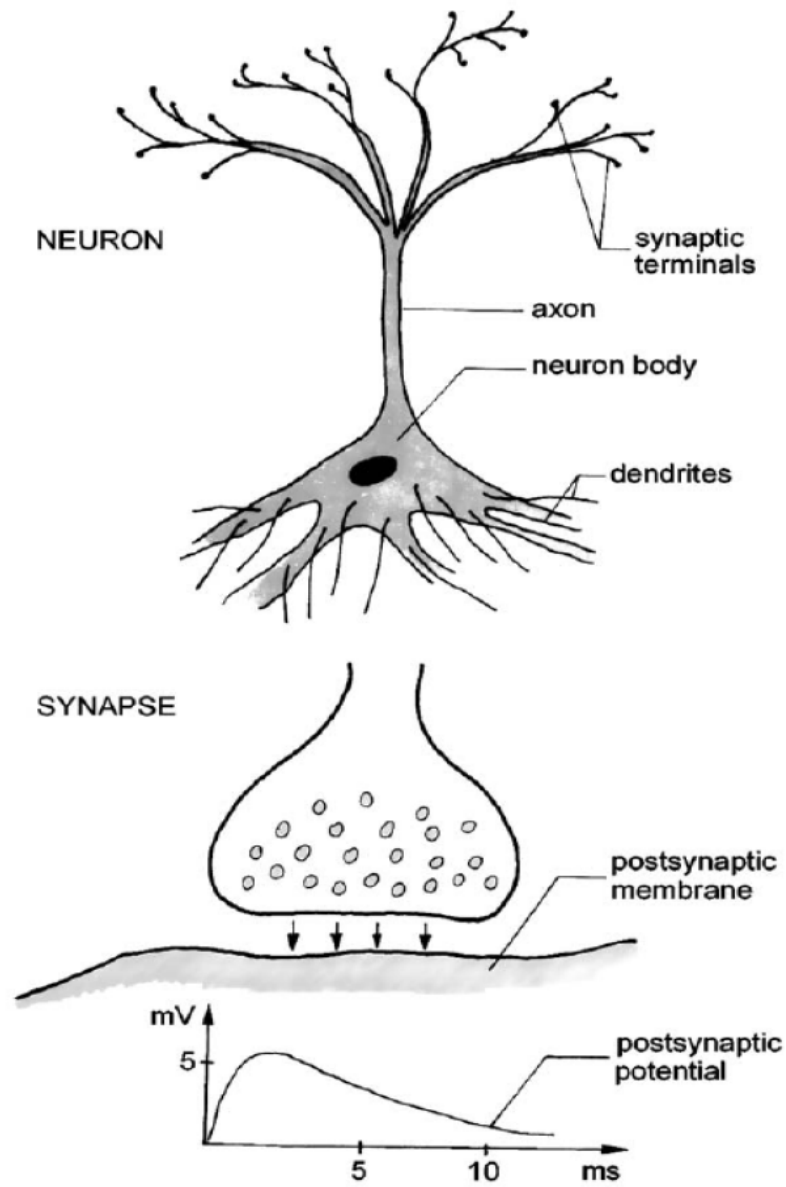


Şekil 2.1. Cerebrumun farklı anatomik kesimleri ve beyin şematik yapısı ve bazı bölgeleri ve beyin kabuğunda (cortex) alanlar [11].

1.3. EEG'nin Nörofizyolojik Esasları

Beyin de, hücreler iki ana sınıfa ayrılır: sinir hücreleri denilen nöronlar (şekil 2.2) ve glial hücrelerdir. Her ikisinde de dinlenme potansiyeli yaklaşık -80 mV dur. Hücre

zarı üzerindeki potansiyel farkı K^+ , Na^+ , katyonların, Cl^- anyonları ve büyük organik anyonlar konsantrasyonu farkından kaynaklanır. Ca^{++} iyonları daha az verimlidir, ancak önemli bir düzenleyici rol oynamaktadır. Potansiyel farkı, metabolik süreçler üzerinden sağlanan enerjini kullanarak, K^+ katyonları hücre içine ve Na^+ hücre dışına aktif taşınması ile sağlanır.



Şekil 2.2. Nöron, synaps, postsinaptik potansiyel [12].

1.3.1. Postsinaptik potansiyel (PSP)

Nöronların elektrik faaliyeti aksiyon potansiyeller ve postsinaptik potansiyel (PSP) ile ortaya çıkar. Aksiyon potansiyelleri, membranın elektriksel uyarım, bir eşiği aştığında meydana gelir. Postsinaptik potansiyeller eşik altı kavramlardır. Aksiyon potansiyellerinin ortaya çıkması Na^+ iyonları permeabilitesinin hızlı artışı ile bağlantılıdır. Onların hücre içine akın etmesi, hücre içinde potansiyel artışına neden olur, o da nöron içindeki polariteni negatiften pozitive (+30mV) değişmesine sebep olur. K^+ iyonları için membran geçirgenliğinin bir sonraki artışı (dışarıya akımı) ve Na^+ iyonlarına karşı membran geçirgenliğinin azalması, çevreleyen ortama göre hücre içi tekrar negatif olur. Bu durumda, karakteristik spike-like şeklinde (yaklaşık 1 ms süreyle) bir aksiyon potansiyeli oluşturulur.

1.3.2. İnhibitör postsinaptik potansiyel (IPSP)

PSP'ler postsinaptik membran üzerinde meydana gelen olaylar ile bağlantılıdır. Aksiyon potansiyeli sinapsa geldiğinde, sonraki nöronun postsinaptik membran geçirgenliğinde değişikliğe neden olacak bir arabulucu veya verici denilen bir kimyasal madde, salgılar. Sonuç olarak, iyonlar membran'den geçip zarda potansiyel farkı oluşturulur. Nöron içinde negatifleşme (örneğin, Na^+ iyonlarının akını) azaldığı zaman, atış imkânı yükselir ve eksitör postsinaptik potansiyel (EPSP) oluşur. Nöron içindeki negatifleşmenin artması ve onun hiperpolariz olmasıyla, inhibitör postsinaptik potansiyel (IPSP) oluşur. Aksiyon potansiyeli aksine, PSP potansiyelleri sınıflandırmışlar, onların genlikleri salgılanan arabulucunun miktarıyla orantılıdır, buda giriş nöronun uyarmasına bağlıdır. Postsinaptik potansiyellerin genlikleri 5-10 mV ve zaman aralıkları 10-50 mSec olmaktadır. Supra-eşik uyarma elde etmek için, birçok postsinaptik potansiyeller genlikleri bir nöronun soma da üst üste olmak zorunda olduğundan, nöronların elektriksel aktivitesi hücre içi ve dışı alanlarda hücre zarı boyunca akımları oluşturur ve dipol için yaklaşık uygun bir elektrik alanı üretir. Bu elektrik alanının makroskobik gözlenilmesi için paralel olarak, odaklı çok sayıda dipol elektriksel aktivitesinin senkronizasyonu gerekmektedir [6]. Senkronizasyon PSP tarafından yerine getirilmektedir. Aksiyon potansiyellerden elektrik alana

yapılan katkının deęeri önemsizdir. EEG eşzamanlı üretilen postsinaptik potansiyellerin toplamından ortaya çıkmaktadır [12].

3. BEYİN ELEKTRİKSEL AKTİVİTESİ ve EEG

3.1. Elektroansefalografi (EEG)

Beynin elektriksel aktivitesinin kaydedilmesi EEG olarak bilinir. Klinik arařtırmalarında EEG sinyallerinin geniř bir kullanım alanı vardır. EEG sinyallerinin ortalamasıyla beynin deęiřik bölümlerinin fonksiyonlarını incelemek için yöntemler geliřtirilmiřtir. Üç çeřit kayıt řekli kullanılır. Derin kayıt beynin sinir dokularına ine elektrotlar batırılarak yapılır. Elektrotlar beynin belirlenen yüzeylerine yerleřtirilir. Bu metoda elektrokortikogram denir. En genel kullanım yöntemi ise yüzey elektrotları kullanılarak kafatası derisinden kayıtlar alınmasıdır. Beynin elektriksel aktivitesinin incelenmesi genel olarak iki moda bölünmüřtür. Birincisi; beynin kendi kendine yaptıęı aktivitelerdir. Bu aktiviteler özel bir görevi olmadan beyin tarafından saęlanan elektriksel alanın sonucudur. İkincisi ise uyarılmıř potansiyellerdir, bu potansiyeller özel bir iřlem sonucu elde edilir. (ıřıęın flařı vb...). EEG'nin yüzey kayıtları, elektrotların yerlerine baęlıdır. Genel klinik uygulamalarda EEG kayıtları elektrotların belirli yerlere yerleřtirilmesiyle elde edilir. Bu yerler Ö(Ön), M(Merkez), T(Temporal), P(Parietal), O(Occipital) bölgeleridir. İki tane ortak elektrot kulak loblarına yerleřtirilir, 6 ile 32 kanal kullanılabilir. Genelde 8 veya 16 kanal kullanılır. Elektrotlar arasındaki potansiyel farklar kaydedilir. Kaydedilen EEG potansiyelleri 3 madde incelenir. Bu kayıtlar unipolar, ortalama referans ve bipolar olarak adlandırılır. Kafatası derisinden alınan EEG'nin frekans aralıęı DC ile 100 Hz arasında deęiřmektedir. Büyük güç daęılımları 0,5 Hz ile 60 Hz arasındadır. EEG güç spektral yoğunluęu fiziksel ve davranıřsal duruma göre deęiřir. Nörolojik teřhislerde uzun yıllar EEG sinyal analizi büyük bir iřlem kaynaęı olarak kullanılmıřtır. Epilepsi hastalıęının teřhisinde, bař yaralanmaları, psikolojik fonksiyonlar, uyku isteksizlięi ve birtakım dięer durumlarda bu yöntem kullanılmaktadır.

3.2. EEG'nin Tarihçesine Bakış

EEG beyin biyoelektrik aktivitesinin, uygun yazdırma sistemleri kullanılarak kağıt üzerine yazdırılma yöntemidir. 1902 yılında hayvan çalışmalarıyla işe başlayan Hans Berger, metodunu ilk kez 1924 yılında insana uygulamıştır. Bazı aktiviteleri tanımlayarak EEG'nin beyin hastalıklarında kullanılabileceğini düşünmüştür. Geçen süre içinde teknik gelişmeler ve konu ile ilgili bilgi birikimiyle birlikte yıllarca basta epilepsi olmak üzere çeşitli beyin hastalıklarında kullanılan önemli bir araştırma yöntemi olmuştur.

3.3. EEG'nin Kullanım Alanı

Yakın zamanda Computer Tomography (CT) ve Magnetic Resonance (MR) gibi ileri görüntüleme yöntemlerinin pratik kullanıma girmesiyle birlikte bir süre için EEG kullanım alanının çok daraldığı düşüncesi yaşanmıştır. Kısa dönemde ileri görüntüleme yöntemlerinin kullanım alanları ve sınırlarının belirlenmeye başlamasıyla birlikte CT ve MR gibi yapısal değişiklikleri belirleyebilen görüntüleme yöntemleri ile EEG, uyandırılmış potansiyeller gibi fonksiyonel özelliklerin saptanmasında önemli olan nörofizyolojik yöntemlerin birbirlerinin alternatifleri olmadığı, aksine tamamlayıcıları olduğu görülmeye başlanmıştır. Bugün EEG'nin sınırları, görüntüleme yöntemlerinin getirdiği ek bilgilerle daha açık olarak bilinmektedir. "Klinik değerlendirilmesi iyi yapılmış bir hastada EEG bulgularının teşhiste diğer laboratuvar yöntemlerinde olduğu gibi ancak yardımcı bir niteliğinin olduğu" kavramı açıkça görülmüştür. Günümüzde, EEG karotis endartektomisi sırasında cerrahi manipülasyonu yönlendirmeden demans ve multipil skleroz gibi hastalıkların değerlendirilmesine kadar geniş bir alanda kullanılmaktadır. EEG'nin pratikte sık olarak kullanıldığı durumları şöyle sıralayabiliriz.

- Beyin Bilgisayar Ara yüzü
- Epilepsiler
- Beyinle ilgili diğer paroksizmal hastalıklar
- Toksik-metabolik

- Ensefalitler
- Komalar
- Uyku hastalıkları

3.3.1. EEG sinyallerinin gözlenmesi

Beynin elektriksel etkinliğine bağlı EEG sinyalleri, osiloskop tipi bir gözlem aracı ile gözlenebilir veya kayıtçı tipi bir araçla kâğıda çizilebilir. Kafatası iyi bir iletken olmadığından, EEG aracı olarak kullanılacak bir gözlem aracı yüksek amplifikasyon kazancına sahip olmalıdır. Kaynak empedansın yüksek olması yüzünden ve genellikle küçük elektrotlar kullanılması gerektiğinden, EEG aracının giriş empedansı da yüksek olmalıdır. Ayrıca gerek vücuttan, gerek dışarıdan kaynaklanan birçok elektriksel gürültü kaynağı olabileceğinden, bu istenmedik etkileri azaltacak önlemlerin alınması gerekir. Elektrot materyali olarak Ag-AgCl tercih edilmektedir.

3.4. EEG Sinyal Özellikleri

EEG kayıtçılarının frekans sınırları (-3dB noktaları) standart olarak 0,53Hz-75Hz arasında seçilir. Araç içinde bulunan ve dışarıdan ayarlanabilen elektronik filtrelerle, gerektiğinde üst frekans sınırı daha aşağılara çekilebilir. Bazı EEG kayıtçıların, kayıt öncesinde elektrot empedansı ($10k\Omega$ 'dan küçük olması istenir) test eden alt sistemleri bulunur.

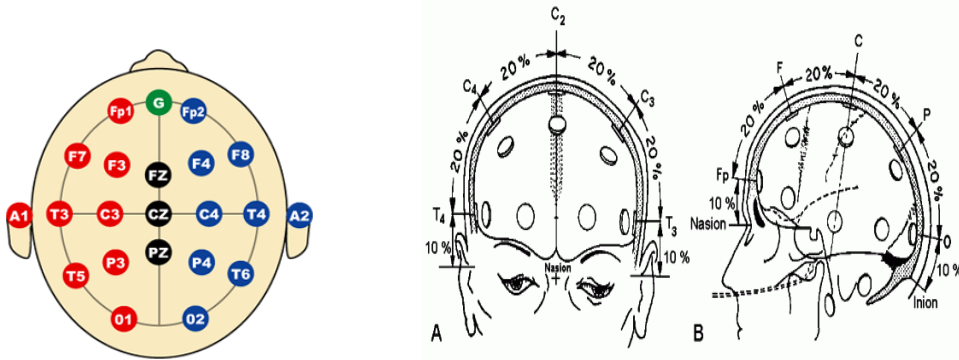
EEG aracında amplifikasyon kazancı (veya duyarlılık) düğmeleri bulunur. Standart ölçek duyarlılığı $100\mu V/cm$ dır. Başka bir duyarlılık seçilmiş ise kayıt kâğıdında belirtilmesi gerekir. EEG kayıtlarında kâğıt ilerleme hızı standardı ise 30mm/s dır. Çoğu EEG ataçlarında, gereğinde kullanmak üzere, 60mm/s ve 15mm/s seçenekleri de bulunmaktadır.

EEG, elektroensefalogram yorumlanması ve kayıt ile ilgili bir etki alanıdır. EEG beyin hücrelerinin kooperatif eylemi esnasında ürettiği elektrik sinyalinin bir kayıdır, daha doğrusu, eş zamanlı eylem tarafından hücre dışı alanda üretilen

potansiyellerinin bir zaman gidişatıdır. EEG Yunanca kelime, encephalo (beyin) ve graphein (yazmak)' den türemiştir. EEG kafa derisi üzerine yerleştirilir veya doğrudan korteks üzerinde elektrotlar vasıtasıyla ölçülebilir. İkinci durumda, bazen elektrokortikogram (ECoG) denilir. İntrakortikal şeklinde ölçülen elektrik alanlara yerel alan potansiyel adı verilmiştir. Bir dış uyaran yokluğunda kaydedilen EEG, doğal EEG olarak adlandırılır; dış veya iç uyarıcılara bir tepki olarak oluşan EEG, olaya ilişkin potansiyel olarak adlanır. Uyanık durumda kafa derisi üzerindeki elektrotlar ile kaydedilen normal bir EEG genlik 10-100 μ V arasındadır. Epilepsi durumunda, EEG genlikleri büyüklüğe bağlı olarak artırabilir, kortekste, genlikler 500-1500 μ V aralığında bulunmaktadır.

3.5. EEG de Elektrot Konumları

Gözlenen EEG desenleri kayıt bölgesi ve biçimine önemli ölçüde bağlıdır. Standart EEG kayıtlama sistemi, "10-20" sistemi olarak adlandırılan ve Şekil 3.1 de görülen, kafatası çevresindeki 21 elektrot bölgesini içerir. EEG araçları, beynin farklı yönlerinin aktivitelerini aynı anda kayıt edebilmek için, genellikle 8 veya 16 kanallı olarak yapılmaktadır.




Şekil 3.1. EEG' de elektrot konumları [11].

Elektrot bağlantı seçimi unipolar ve bipolar olarak adlandırılan iki farklı biçimde yapılabilmektedir. Unipolar kayıt biçiminde seçilen bir elektrot bölgesinin MSS den bağı olarak uzak bir referans noktasına göre potansiyel değişimleri kaydedilir. Gelenlikle referans noktası olarak Şekil 3.1 de A ile gösterilen sol kulak memesi seçilmektedir. Bir elektrot potansiyelinin, beyin içindeki bir kaynağa duyarlılığı,

kaynak-elektrot uzaklığı ile yaklaşık ters orantılıdır. Bu nedenle unipolar kayıt, elektrot altındaki yerel aktiviteye ek olarak zayıf da olsa uzak bölgelerin aktivitelerini de içerir [11]. Bipolar kayıt ile yakın iki yöre arasındaki potansiyel farkı gözlenir. Bipolar bağlantı duyarlılığı, kabaca, kaynak uzaklığının karesi ile ters orantılı bulunmaktadır ki bu nedenle yerel aktivite hakkında unipolar kayıttan daha iyi bilgi vermektedir.

3.6. Elektro-Kartiyografi (ECoG)

Beyin kabuğuna dokundurularak veya mikroelektrotlarla beyin derinliklerine girerek sinyalleri 3-4 kat büyük genliklerde kayıt etmek mümkündür. Bu şekilde kayıt biçimine elektro-kartiyografi (ECoG) adı verilir. Elektrot ve kayıt biçimine bağlı olarak beyinden ve beyin hücrelerinden kayıt edilebilecek farklı elektriksel sinyal türleri Resim 3.1 de özetlenmiştir.



Resim 3.1. Elektrot ve kayıt biçiminde bağlı olarak beyinden ve beyin hücrelerinden kayıt edilebilecek elektriksel sinyaller [16].

Beyinden tek hücre düzeyinde kayıtlarda solunum ve dolaşımın oluşturduğu sarsıntılardan kaynaklanan zorluklar vardır. Bu zorluklar, beyin dilimleri (slice)


şeklinde hazırlanan örneklerde ortadan kaldırılmaktadır. Uygun bir mikroskop altında oksijenli çözelti, dolaştırılan bir odacık içinde tutulan böyle bir dilimde, mikro-elektrot tekniği ile kayıtları yapılabilmekte, nöro-transmitterlerin etkileri ve protein kanallarının özellikleri incelenebilmektedir.

3.7. EEG Dalgaları

Normal bir EEG sinyali birçok frekansı içerse de, herhangi bir anda belirli bir frekans bölgesi başatır. Beyin aktivite düzeyi yükseldikçe EEG dalgaları frekansı da yükselmekte, genlikleri (amplitude) ise azalmaktadır. Egemen frekanslar yaşla yükselmektedir. Yeni doğanlarda 3-4 Hz frekanslar egemen iken, 2-3 yaş aralığında egemen frekanslar 6-7 Hz arasına, yetişkinlerde ise 8-12 Hz arasına yükselmektedir. EEG dalgalarının Elektrokardiyografi (EKG) de olduğu gibi özel biçimleri yoktur ve rastgele potansiyel değişimlerini andırırlar. EEG dalgalarını değerlendirilerek en önemli parametre frekans, ikinci derecede önemli bir diğer parametre ise genliktir. EEG spektrumu, dalgaların içerdikleri başat frekansa göre özel adlarla anılan bantlara ayrılmıştır.

3.7.1. Delta (δ) dalgaları


Frekansları 0,5-4 Hz, genlikleri 20-400 μ V aralığında olan bu dalgalarla derin uyku, genel anestezi durumu gibi beynin çok düşük aktivite gösterdiği durumlarda karşılaşılır.



Şekil 3.2. EEG birleşeninde Delta dalgası [11].

3.7.2. Teta (θ) dalgaları


Frekansları 4-8 Hz, genlikleri 5-100 μ V arasında olan bu dalgalarla normal bireylerde rüyalı uyku, orta derinlikte anestezi durum gibi beynin düşük aktivite durumlarında ve ayrıca birey bir stres altında iken karşılaşılmaktadır.



Şekil 3.3. EEG birleşeninde Teta dalgası.

3.7.3. Alfa (α) dalgaları


Frekansları 8-13 Hz, genlikleri 2-10 μ V arasında olan bu dalgaların biçimleri sinüzoidal biçime en yakındır. Uyanık bireylerin, fiziksel ve zihinsel olarak tam dinletimde bulunduğu, dış uyaranların olmadığı, gözlerin kapalı olduğu durumlarda görülürler. Occipital bölgeden alınan kayıtlardan belirgin biçimde gözlenirler.



Şekil 3.4. EEG birleşeninde Alfa dalgası.

3.7.4. Beta (β) dalgaları

Frekanslar 13 Hz den yüksek, genlikleri 1-5 μ V arasında olan bu dalgalara odaklanmış dikkat, zihinsel iş, duyuşsal enformasyon işleme ve uykunun hızlı göz hareketleri evrelerinde karşılaşılmaktadır. Bu dalgalarda beynin en yüksek aktivite düzeyine karşılıktır.



Şekil 3.5. EEG bileşeninde farklı dalga şekilleri, şekilde de görüldüğü gibi dalgalarda farklı frekanslara sahipler [11].

3.8. Beyin Elektriksel Aktivite Haritası

Bilgisayarlı tomografinin keşfedildiği 1960lı yılların sonlarından başlayarak beynin görüntülenmesi veya haritalanması amacıyla yönelik birçok yöntem geliştirilmiştir. Bu tekniklerden her biri ayrı fizikokimyasal ilkelere göre çalışmakta ve beynin yapısı veya işlevi hakkında farklı bilgiler vermektedir. Bu tekniklerin çoğunda beyin bir ışımaya maruz bırakılmakta, beyin dokusundan salınan ışın farklı doğrultulardan ölçülmekte, analiz edilmekte ve hesap sonuçlarına göre bilgisayar ekranında bir görüntü oluşturulmaktadır.

Diğer haritalama yöntemlerinde geliştirilen bilgisayar analiz ve hesaplama yöntemleri çoklu elektrot yöntemi ile kaydedilmiş EEG sinyallerine uygulanarak beynin elektriksel aktivite haritası çıkarılabilmektedir. Harita çıkarılmasına yönelik EEG kayıtları mono polar biçimde yapılmaktadır. Beynin belirli elektriksel etkinlik düzeyleri ekranda belirli renklerle kodlanmaktadır. Renk kodlaması, frekans analizlerine dayalı güç, uyum (coherence) veya faza göre yapılabilmektedir. Ancak

bilgisayarlı tomografide ekranda görülen her bir piksel (picture element) gerçek bir veri iken, EEG de çok sınırlı sayıda elektrot kullanılabildiğinden ekrandaki piksellerin çoğu geçek veri olmayıp ancak interpolasyonla belirlenebilmektedir [36]. Haritanın belirli zaman aralıklarındaki değişimleri de çizgi filimler de ki, ardışık resimler gibi ekrana getirilip oynatılabilmektedir. Genel eksele 19 kanaldan kayıt yerine 125 kanaldan yapılan kayıtlara dayalı, çözme gücü daha yüksek haritalama yöntemleri üzerinde çalışmalar sürdürülmektedir. Aynı analizlere dayalı olarak, beynin haritalanması yanında farklı bölgelerinin etkinliği arasında korelasyon hesapları da yapılabilmektedir.

3.9. Magnetoansafalografi (MEG)

Fizikten, elektriksel alan değişiminin manyetik bir alan değişimine olacağı bilinmektedir. Beyindeki elektriksel aktiviteye karşılık yerel akımların da değişken bir manyetik alan ortaya çıkaracağı açıktır. Beyindeki elektriksel aktiviteyi lokalize etmede kullanılan en önemli kavram akım dipolü (birimi, Ampermetre) kavramıdır. Akım dipolünün yeri, şiddeti ve doğrultusu önemlidir. Bir kürenin ancak yüzeyine teğet olan akım bileşenleri dışarıda manyetik alan oluşturabilmektedir [28].

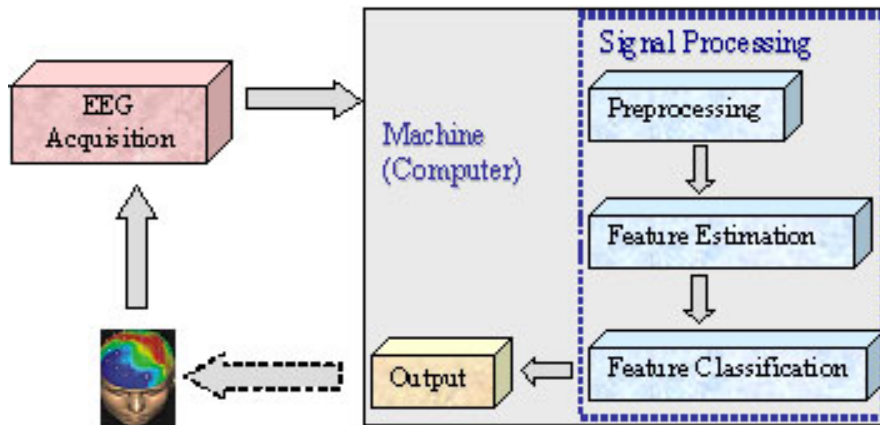
Beyindeki elektriksel akımların oluşturduğu manyetik alan değişimlerinin gözlenmesi yöntemine magnetoansafalografi (MEG) adı verilir. Ancak çok zayıf olan bu değişimlerin ayırt edilmesi oldukça zordur. Örneğin, duyuşsal bir uyarana yanıt olarak ortaya çıkan manyetik alan değişimleri 50-500 Femtotesla ($1\text{fT}=10^{-15}\text{ T}$) kadardır ve yerin manyetik alanının 10⁻⁸ katı kadar küçüktür. Bu kadar küçük alanlar, manyetik gürültüleri gidermek üzere sıkı önlemler alındıktan sonra, SQUID (Superconducting Quantum Interface Device) adı ile geliştirilmiş sensorlarla tespit edilebilmektedir. Şimdiye kadar 4-37 arasında sensor dizileri kullanan sistemler geliştirilmiştir. Bu sensor dizilerinden alanına veriler, bilgisayarlar aracılığı ile analiz edilerek, iki boyutlu harita şeklinde görüntülere dönüştürülebilmektedir.

3.9.1. MEG ve EEG'nin kıyaslaması

Zaman ölçeğinde çözünürlükleri bakımından MEG ve EEG'nin her ikisi de iyi sayılmaktadır. Uzaysal çözme gücü bakımında ise MEG daha üstün görülmektedir. Genel eksele EEG de dokundurulması ile ilgili sorunların MEG de bulunmaması da MEG için bir avantaj olarak kabul edilmektedir. Üstünlüklerine rağmen, henüz çok pahalı bir teknik olduğundan EEG kadar yaygınlaşmamaktadır. Beynin elektriksel aktivite haritası son yıllarda bulunan bazı voltaj bağımlı boyalar aracılığı ile de çıkarılabilmektedir. Bu boyalar zar potansiyelinden etkilenerek soğurma veya flüoresans özelliklerini değiştirmektedirler. Optik gözleme yönteminin beyin kabuğunun doğrudan görülmesini gerektirmesi, bu tekniğin uygulamaları şimdilik hayvan deneyleri ile sınırlamaktadır [8].

3.10. Biyolojik Geri bildirim (Biofeedback) ve EEG

Bir bireyin, istemli olarak kontrol almak amacı ile, iç organları veya iç ortam özellikleri hakkında doğrudan veya bir araç aracılığıyla bilgi edinmesi yoluna genel olarak biyolojik geri besleme adı verilmektedir. Bu yolla beyin aktivitesini kontrol altına almak mümkün olabilmektedir. Resim 3.2 EEG ile ilgili biyolojik geri bildirim konusunda detaylı bileşenleri göstermektedir.



Resim 3.2. EEG ile ilgili biyolojik geri bildirim [12].

Geri bildirim bir EEG analizleřici blok řeması Resim 3.2’de görölmektedir. Deneyimi yapan kiři, genellikle olduđu gibi, beynini dinlerimde, yani alfa ritminde EEG dalgaları ıkaracak durumda tutmak istesin. Geri bildirim yolu ile EEG analizleřici den gelen frekans bilgisi referans frekans aralıđı bilgisi ile uygunlukta ise karřılařtırıcıdan hata sinyali ıkmamakta, bu durumda osilatör-hoparlör sistemi řiddetli olmayan, müzikal bir ses üretmektedir. Uygunlukta deđilse bu ses kaybolmakta veya alarm sesi vermektedir. Böylece birey müzikal sesi sürekli elde etmeye alıřmakta, bunu bařardıka da beynini dinlenme durumunda tutabilmekte, problemlerinden uzaklařabilmektedir [24].

4. ELEKTROANSEFALOGRAFİ ve BEYİN BİLGİSAYAR ARA YÜZ (BBA) SİSTEMİ

4.1. BBA

BBA, kişilerin kas sistemlerini bir başka deyişle motor sinir sistemlerini kullanmadan sadece düşüncesi ile bir bilgisayarı, elektromekanik bir kolu ya da çeşitli nöroprotezleri kullanmalarını imkânlı hale getiren sistemlerdir. Özellikle bu sistemler felçli ve Amiyotrofik Lateral Sklerozis (ALS) hastalarının hayatlarına ışık tutabilmesi açısından oldukça önemli bir teknolojik gelişmedir.

Günümüzde BBA uygulamalarında EEG, tek hücre kayıtlamaları, fonksiyonel manyetik rezonans görüntüleme, yerel alan potansiyelleri, yakın kızılötesi spektroskopisi, elektrokortikografi, magnetoansefalografi gibi teknikler kullanılmaktadır. Bu teknikler içerisinde BBA sistemleri için genel olarak pratik olarak elde edilmesi ve uygulanmasının kolay olmasından dolayı EEG tercih edilmektedir. EEG işaretleri beyin yüzeyinden veya saç derisi üzerinden elektrotlarla ölçülen düşük genlikli (tepeden tepeye 1-400 μ V) biyoelektrik işaretlerdir (acı vermemesi bakımından genelde bu işaretler saç derisi üzerinden alınmaktadır). Yapılan araştırmalar bu işaretlerde çok miktarda nörolojik bilgi saklandığını ortaya çıkarmaktadır.


Son 15 yılda EEG işaretlerinin incelenmesi hız kazanmış, bu işaretlerle hem hasta tedavi yöntemleri geliştirilmekte hem de bu işaretler yardımı ile bir BBA oluşturularak elektronik cihazlarla haberleşme sağlanmaktadır.

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

4.2. EEG Tabanlı BBA

EEG tabanlı BBA sistemlerinde bilgisayar gibi elektronik cihazlarla iletişimi sağlayacak uygun komutların üretilmesi, farklı düşünel ve görsel durumlarda oluşan EEG işaretlerinin işlenmesine (öznitelik çıkarma) ve çıkarılan özniteliklere dayalı olarak sınıflandırılmalarına bağlıdır. Şekil 4.1’de EEG tabanlı bir BBA sisteminin temel işlem bileşenleri gösterilmiştir.

Beynin elektriksel aktivitesinin keşfedilmesinden yaklaşık 100 yıl sonra ilk BBA araştırmaları 1973 ile 1977 yılları arasında Jacques Vidal tarafından sunulmuştur [23, 24]. Vidal çalışmalarında beyin sinyallerinin bir zihinsel protezi geliştirmek için nasıl kullanılabileceğini göstermiştir. BBA teknolojisi özellikle 1999 yılında yapılan kortikal nöronların direk olarak robotik bir kolu kontrol edebildiğini gösterir ilk deneysel çalışmadan sonra büyük bir aşama kat etmiştir [25]. Bu çalışmadan sonra bu alanda muazzam araştırmalar yapılmaktadır [26].



Şekil 4.1. Beyin bilgisayar ara yüzü nün temel bileşenleri [16].

4.3. P300 Tabanlı BBA

BBA sistemleri genel olarak üç temel nörofizyolojik paradigmaya dayanmaktadır. Bunlardan biri olan P300 tabanlı BBA sistemlerinde amaç, görsel uyarılara odaklanma ve fark etme gibi görevler sonucu beyinde istemsiz olarak oluşan P300 sinyallerini algılamaktır. Bu sinyallerin algılanması sonucunda, kişinin odaklandığı uyarı ve bununla ilintili seçenekler dış dünyaya bir çıktı olarak verilir. Bunun en bilinen örneği olan ve Farwell ve Donchin (1988) tarafından öne sürülen P300 heceleme uygulamasında, kişiye bir bilgisayar ekranında karakterlerden oluşan bir matris gösterilir.

Kişiden bu matristeki karakterlerden birine odaklanması istenir ve bir süre sonra bu matrisin satır ve sütunları hızlı ve rastgele bir şekilde parlatılıp söndürülür. Bu süreçte kişinin odaklandığı karakter yanıp söndüğü zaman (eğer iyi bir şekilde odaklanmışsa ve odaklandığı karakterin yanıp söndüğünü o anda fark edebiliyorsa) kafa yüzeyinden alınan EEG sinyallerinden P300 sinyal bileşenlerini ayırt etmek mümkündür. Ancak beyinden EEG aracılığıyla alınan elektriksel sinyallerin şiddeti çok düşük olduğu için çok fazla elektriksel olgudan etkilenmektedir. Dolayısıyla P300 sinyallerinin varlığını hızlı bir şekilde algılamak ve kişinin odaklandığı karakterleri ekranda göstermek zor bir problemdir. Dünyada bu alanda çalışma yapan bilim insanlarının amacı bu sistemlerin hız ve doğruluk performansını iyileştirmektir.

4.4. Steady State Görsel Uyarılmış Potansiyel – SSVEP

Uyarı tabanlı bir diğer BBA sisteminde ise kişiye farklı frekanslarda yanıp sönen görsel uyarılar gösterilir. Kişi bu uyarılardan birine odaklandığı zaman beyin görüntü ile ilgili bölgelerinde odaklanılan uyarı ile aynı frekansta salınımlar gösteren örüntüler gözlemlenebilmektedir (Steady State Visual Evoked Potentials – SSVEP). Bu şekilde farklı frekanstaki uyarılar ayırt edildiği zaman, basit bir bilgisayar uygulaması ile elektronik sistemlerin kontrolü mümkün olmaktadır.

4.5. Beynin Duyu – Motor Değişimi

BBA sistemlerinde kullanılan bir diğer nörofizyolojik olgu da kişinin hareket etme istemi veya düşüncesi sonucunda beynin duyu - motor bölgelerinde birtakım elektriksel değişimlerin oluşmasıdır.

Bir örnek ile ifade edersek, sağ elinizi hareket ettirmek istediğinizde beynin sol bölgesi, sağ yarım küreye göre daha farklı bir elektriksel aktivite göstermektedir. Aynı şekilde dilinizi veya ayağınızı hareket ettirmek istediğinizde beynin orta bölgeleri, diğer bölgelere göre daha fazla elektriksel değişim göstermektedir. Bunlar gibi birtakım istemlerin ayrıştırılması sonucu kişi bir bilgisayar ekranındaki imleci veya bir tekerlekli sandalyeyi herhangi bir uyarana olmaksızın kontrol edebilmektedir.

4.6. EEG Eğrilerinin Değerlendirme Yöntemleri

EEG dalgalarının iki önemli parametresinden biri olan frekansı basitçe belirleyebilmek için, belirli bir zaman aralığında eğrilerdeki tepeler sayılır ve zamana oranlanarak ortalama bir frekans belirlenebilir.

Ortalama frekansı belirlemek için bir diğer yöntem sıfırdan geçen analizi olarak adlandırılır. Bunun için, örneğin, her bir 10s dönem içinde, eğrinin ardışık sıfırdan geçmeleri arasındaki süreler ölçülür. Bu ölçümlerden her biri yarım periyot kabul edilerek, ortalama alınarak, karşılığı olan periyot ve frekans ($F=1/T$) belirlenir. Bulunan bu frekansların genel eksel EEG bantlarından hangisi içine düştüğü saptanır. Frekans analizi daha ayrıntılı ve doğru olarak, bilgisayar teknikleri kullanılarak Fourier analizi yöntemi ile yapılır. Bu yöntemle EEG sinyali içinde hangi frekansların hangi paylarda bulunduğu, yani frekans spektrumu ayrıntılı olarak belirlenebilmektedir.

Ortalama genlikler de basitçe belirlenebilir. Örneğin, 10s'lik bir süre içinde, tüm tepeden tepeye (peak to peak) genlikler cetvelle veya milimetrik kâğıda çizili ise

bölmeler sayılarak ölçülür, ortamları alınır ve bu değer [$\mu\text{V}/\text{bölme}$] cinsinden ölçek duyarlılığı ile çarpılarak μV cinsinden ortalama genlik belirlenmiş olur.

Genlik analizinin otomatik yapılabildiği bir başka yöntem, alternatif akımların doğrultulması işlemine benzer. EEG sinyalleri doğrultma ve süzme işlemlerinden geçirilir. Elde edilen doğru gerilim EEG sinyallerinin genliği ile orantılıdır.

Bilgisayar tekniklerinin gelişmesi ve yaygınlaşması ile EEG verilerini analiz etme yeni yöntemler geliştirilmiştir. Önceleri yalnızca zaman ölçeğinde analizle sınırlı olan teknikler, daha sonraki paragraflarda açıklanacağı gibi, uzay ölçeğine genişletilmiştir.

4.7. Uyarılmış Potansiyeller

Uyarılmalı sinyal işleme konusu, sayısal hesaplama, sayısal sinyal işleme ve yüksek hızlı tümleşik devre teknolojisindeki çok hızlı ilerlemeler sonucu son 30 yıl içerisinde hızlı bir gelişme göstermiştir. Widrow ve Hoff 1959'lu yıllarda uygulamalı süzgeçleme algoritmasını LMS (Least Mean Square) olarak oluşturmuşlardır [71].

Uyarılmalı işaret işleme, esas olarak FIR süzgeç yapısıyla gerçekleştirilmekte ve bu gerçekleştirilmede LMS algoritması kullanılmaktadır. Uygulamalı sistem ile bilmeyen sistemin modellenebilmesi için giriş sinyalinin zengin spektral içeriğe sahip olması önemlidir. Böyle bir durum için en uygun giriş sinyali beyaz gürültüdür. Çünkü, eşit güç ile bütün frekansları içermektedir. Uyarılmalı gürültü yok etmede yaygın bir şekilde giriş işareti olarak beyaz gürültü kullanılır.

4.7.1. EEG verileri

Çalışmada kullanılan EEG verileri Technical University of Graz'dan alınmıştır. Alınan EEG verileri değişik yaşlardan kişilere aittir. Mevcut EEG verileri kişisel bilgisayar ortamında, Singview programı (Graz üniversitesinin geliştirdiği bir yazılım) aracılığıyla analiz edilmiştir. Bu amaçla veri toplama kartı (DAQ), işaret

düzenleyiciler ve kişisel bilgisayardan oluşan veri toplama sistemi ile gerçek EEG işareti bilgisayar ortamına aktarılmıştır. Bu çalışmada yukarıda belirtilen düzenek ve program paketi kullanılarak EEG işaretlerinde gürültünün bastırılması uyarlamalı süzgeçleme ile yapılmaktadır.

4.7.2. Beyin işlevlerinin lokalize edilmesi

Beyin işlevlerinin lokalize edilmesinde iki yöntemden çok yararlanmıştır. Beynin bir bölgesinin cerrahi olarak ayrılması (ablasyon) yöntemi ile beynin hangi işlevleri yitirdiği belirlenebilmektedir. Zararsız diğer yöntem ise, özgün bir duyuşal uyarılması sonrasında hangi bölgelerden kaydedilen EEG desenlerinde uyarılmış yanıtların ortaya çıktığı saptanır. Bu potansiyellere duyuşal uyarılmış potansiyeller (sensory evoked potential) veya birey böyle bir uyarının uygulanacağını önceden biliyor ise olaya ilişkin potansiyeller (event related potential) adı verilir [20]. Duyuşal uyarıların yokluğunda doğal fon (background) şeklindeki normal EEG aktivitesi üzerine, ışık veya ses gibi uyarıların etkisinde ortaya çıkan uyarılmış (evoked) aktivitelere eklenir. Uyarılma sonucu beyinde ilgili özel merkezlerin yanıtları bu uyarılmış aktivitelere, doğal fon aktivitesi yanında 50 kez kadar küçük olduklarından doğal fon içinde kaybolurlar. Uyarılmış aktiviteyi doğal fondan ayırabilmek için "sinyal ortalaması olan" teknikleri kullanılır.

Sinyal ortalamasını almak için, her bir kayıt uyarı kaynağına bağlı ve onun tetiklenmesi ile başlatılır (örneğin 50ms'lik stroboskopik ışık flaşları ile). Her bir kayıtle ilgili sayısal bilgiler bilgisayar belleğine kaydedilir. Bu şekilde alınmış her bir kayıt,

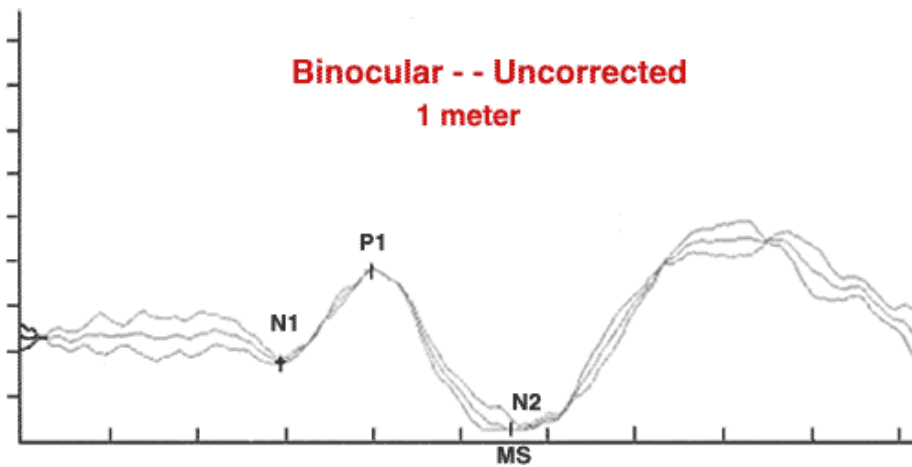
$$V^*i(t) = e(t) + Vi(t) \quad (4.1)$$

şeklinde yazılabilir. Bağlıdaki $Vi(t)$ terimi doğal fon aktivitesine, $e(t)$ uyarılmış aktiviteye, $V^*i(t)$ ise ikisinin toplamına karşılıktır.

İstatistik-olasılık teorilerine göre, burada doğal fon olarak tanımlandığımızı benzer, ortalama genliği A olan rastgele değişimli olaylarda, bu değişimlerden N tanesini aynı zaman ekseninde alt alta çizdirip her an için eğrilerdeki değerler okunup ortalamaları alınır, bu yolla bulunacak ortalama eğrinin genliği A/\sqrt{N} olarak bulunmaktadır. Rastgelelikten ötürü, her hangi bir t anına ait bazı kayıtlarda uzanım pozitifken bazılarında negatif olmakta, dolayısı ile N deney sayısı arttıkça, toplam $1/\sqrt{N}$ ile orantılı artarken ortalama uzanımı ve genlik A/\sqrt{N} şeklinde azalmaktadır. Diğer yandan, uyarılmış aktivite $e(t)$, uyarılmaya bağlı, özel bir biçime sahip ve rastgele olmayan bir değişim olmalıdır. Böyle bir değişim N kez tekrarlanıp ortalaması alınır yine kendisi, $e(t)$ elde edilmelidir. Böylece uyarılmış aktivite ile doğal fonu birlikte içeren $V^*i(t)$ eğrilerinden N tanesi çizilip,

$$V^*i(t) = e(t) + \frac{1}{N} \sum Vi(t) \quad (4.2)$$

şeklinde ortalamaları alınır, ilk terimin katkısı aynı kalırken ikinci terimin katkısı $1/\sqrt{N}$ ile azalacak ve böylece uyarılmış potansiyeller doğal fondan seçilmiş olacaktır. Bir duysal uyarılmış potansiyel, duysal yolda enformasyonun ardışık aşamalarda işlenmesi süreçleri ile ilgili birçok bileşen içerir. Şekil 4.2’de işleme yoluna ilişkin ve ortalama alınarak belirlenmiş bir uyarılmış potansiyel eğrimi görülmektedir.



Şekil 4.2. İşitsel uyarılmış potansiyeller [20].

4.8. EEG Tekniklerinin Uygulamaları

Normal ve uyarılmış EEG sinyallerinin analizi MSS işlevlerinin incelenmesinde önemli rol oynamış ve oynamaya devam etmektedir. Beyin kabuğunda duyuşal ve motor alanların saptanmasında EEG analizlerinin önemli payı olmuştur.

Klinikte, yaralanma ve tümör gibi nedenlerle ortaya çıkan beyin hasarlarının yerini belirlemede EEG den yararlanılmaktadır. Bu tür hasar görmüş bölgelerde ya sessiz, yani sinyal vermeyen alanlarla, ya da beklenmeyen tipte dalgalarla karşılaşmaktadır.

Epileptik tiplerin ve odaklarının belirlenmesinde de EEG den yararlanılmaktadır. Epilepsinin tipine göre, EEG sinyalleri içinde diken, dalga gibi adlarla anılan özel desenler ortaya çıkmaktadır.

Uykunun deęişik evrelerinde EEG dalga desenlerinin deęiştii saptanmıştır. Normal bireylerde görülen desenlerle karşılaştırılarak, uyku bozuklukları tespit edile bilmekte, nedenleri araştırılmaktadır. Uyarılmış EEG eğrilerinin incelenmesi ile, duyuşal merkezlerdeki muhtemel bozukluklar anlaşılabilir.

Özellikle organ nakilleri açısından önemli bir konuda, beyin ölümünün belirlenmesidir. Kayıt yapılan tüm kanalarda dalgalanmalar yok, kayıt edici hep sıfır çizgisinde kalıyor ve bu durum uzun süre devam ediyor ise beynin artık işlevini tamamen yitirdiđi sonucuna ulaşılmaktadır.

4.9. Niceleştirilmiş EEG

Normal EEG veya uyarılmış potansiyel sinyallerinin bilgisayarlar aracılığı ile derlenmesi, görüntülenmesi, depolanması ve analiz edilmesi işlemlerine niceleştirilmiş EEG (quantified EEG) adı verilmektedir.

Niceleştirilmiş EEG de, normal EEG de olduđu gibi, 10-20 sistemine görselleştirilmiş elektrotla alınan sinyaller, önce mikro-voltlar düzeyinden voltlar düzeyine amplifiye edilir ve filtrelendirir. Daha sonra bu sinyaller analog-dijital çevirici (A/D convertor) aracılığı ile sayısal verilere dönüştürülür. Sayısal veriler üzerinde Hızlı Fourier Dönüşümü (FFT) uygulanarak genlik spektrumu belirlenir.

Düşük (delta ve teta) ile yüksek (alfa ve beta) frekans bantlarına ait güç oranları beyinde kan akımı ve metabolizma hakkında bilgi vermektedir. Farklı iki elektrot bölgesi arasında güç spektrumları farklılığı genlik asimetrisi olarak adlandırılmakta ve beynin farklı bölgelerine ait işlevsel farklılaşma derecesi hakkında bilgi vermektedir.

Genlik ve frekans bileşenleri yanında faz bilgileri de değerlendirilerek, farklı bölgelerden alınan sinyaller arasında bir uyumluluk (coherence) ve eşzamanlılık (synchrony) olup olmadığı saptanabilmektedir.

5. BBA SİSTEMLERİNDE SİNYAL İŞLEME

5.1. BBA Sistemlerinde Elektroensefalografi'nin Kullanımı

Richard Caton (1842-1926) beyin potansiyelinin araştırılmasında ilk bilim adamı olarak kabul edilir. O kedi ve tavşan açık beyinleri üzerinde çalıştı ve galvanometre aracılığıyla elektrik akımları ölçtü. 1875 yılında sunulan sonuçlara dayanarak, elektrotlar kafatası üzerinde iki dış noktaya veya bir elektrot gri madde ve diğerine kafatası üzerine konulduğunda, değişken yönlerde zayıf akım geçiyor. Bu gözlem, EEG aktivitesi kâşifi olarak kabul edilebilir.

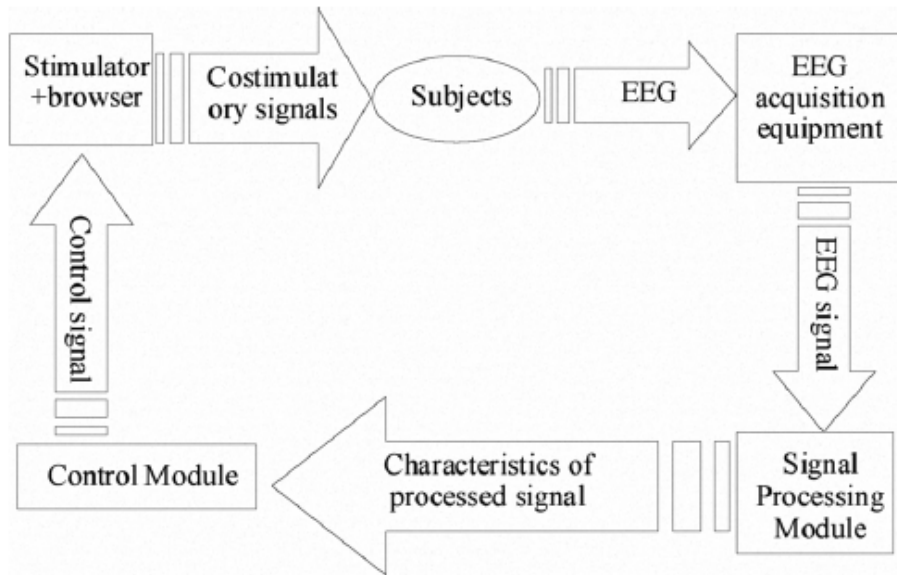
Adolf Beck (1863-1939) de tavşan ve köpek beyinlerinin doğal aktivitesini araştırmıştır. O (1890 yılında) beyin elektriksel aktivitesinin ritmik salınımlı olduğunu keşif etti. Ayrıca gözler ışık ile tahriş edildiğinde, bu salınımların ortadan kaybolması gözlendi, bu da “alpha blocking” adı verilen eylemin ilk keşfi olarak belirlenir. Daha sonra, onun yardımcısı, Napolyon Cybulski (1854 - 1919) bir fotoğraf aksesuarı ile bir galvanometre uygulayarak bir grafik biçiminde elektroensefalogram sundu. Bir elektrik stimülasyonu uygulayarak ortaya çıkarılan bir köpek epileptik EEG aktivitesi gözlenmesini ilk kişi olarak sağladı [4]. 1929 yılında ilk elektroensefalogram Hans Berger tarafından insan derisi yüzeyinden kaydedildi [5].

1935 yılı, günümüz klinik elektroensefalografisinin en önemli alanlarının ortaya çıkmasına tanıklık etti. F. Gibbs ve H. Davis, epileptik yokluluğunda, EEG ‘de 3/Sec diken-dalga komplekslerinin birleşmesini gösterdi. Ayrıca 1935 yılında, ilk elektroensefalografi (Grass Model I) çağdaş EEG kayıt dönemi başlatıldı. Elektroensefalografi tarihi hakkında daha fazla bilgi [12] ve [15] bulunmaktadır.

5.1.1. BBA sisteminin tanımı

Ele alınan işaretin hangi sınıfa ait olduğuna karar verebilmek için öncelikle eğitim verileri üzerinde incelemeler yapılarak farklı sınıflara ait EEG işaretlerinden

öznitelikler çıkarılmalıdır. Öznitelik çıkarma işlemi BBA uygulamalarının en temel ve en zor konusunu oluşturur. Çünkü kaydedilen EEG işaretleri düşümsel durumda oluşan nörolojik bilgileri içermesinin yanında gürültü olarak isimlendirebileceğimiz bozucu kaynakları da içerir. Birçok gürültü kaynağı içeren bir veri üzerinde matematiksel incelemeler yapmak oldukça zordur. Bu bakımdan bir ön işleme arabirimi ile EEG işaretlerine karışan gürültüler giderilmelidir. EEG işaretlerinin genlikleri çok düşük mertebelerde olduğundan bu hassas işaretlere çeşitli gürültüler kolayca karışabilmektedir. Ölçüm yaparken oda içerisindeki ışığın açık veya kapalı olması ve çevrede elektromanyetik dalga yayabilecek cihazların bulunması gibi dış etkenlerden etkilendiği gibi kişinin gözünü kırpması, kalp atışları, kolunu sağa-sola hareket ettirmesi gibi fiziksel aktivitelerden de çok kolay etkilenebilmektedir. Literatürde gürültüleri EEG işaretlerinden arındırmak için çeşitli yöntemler kullanılmaktadır. Şekil 5.1’de beyin bilgisayar ara yüzünde sinyal işleme şeması verilmektedir.



Şekil 5.1. Beyin bilgisayar ara yüzünde sinyal işleme şeması [27].

En yaygın olanları bağımsız bileşenler analizi [27, 28, 29] ve filtreleme (lineer ve lineer olmayan) [30, 31] teknikleridir. Dalgacık dönüşümü [32, 33] temel bileşenler

analizi [34], kaynak dipol analizleri [35] gibi yöntemler de nörolojik bilgiyi kaybetmeden gürültü arındırma yöntemi olarak kullanılmaktadır. Literatürdeki çalışmalarda en fazla giderilmeye çalışılan gürültü kaynağı göz kırpmasından ileri gelen gürültüdür. Bu gürültü özellikle göze yakın ve oksipital bölgelere konumlandırılmış elektrotlardaki işaretlere karışır. Gürültülerin yok edilmesinden başka bazı durumlarda başvuru alan ortalama alma, eşik değeri belirleme, işaret iyileştirme gibi işlemler de ön işlemeyi oluşturmaktadır.

Bu bölümde BBA sistemlerinde uygulanan çeşitli sinyal işleme yöntemleri incelenmiştir. Bu yöntemler aşağıdaki şekilde özetlenmiştir:

- Sinyal geliştirme için: Butterworth süzgeçleme yöntemi, Uygulamalı süzgeç, Least mean square (LSM) Algoritması
- Özellik çıkarmak için: TF- Tabanlı özellik çıkarma, Single Value Decomposition (SVD), TF- Tabanlı Single Values
- Sınıflandırma için: K En yakın komşuluk, Dinamik sinaps sinir ağları, Destek Vektör Makineleri (DVM)

5.2. Butterworth Süzgeçleme Yöntemi

İlgisiz frekansları ayırmak için veri, 1-20 Hz aralığını geçiren Butterworth bant geçiren süzgeç ile süzgeçlenir. BBA tabanlı SSVEP sinyallerinin sınıflandırma öncesi süzgeçlenmesi ile 50Hz'lik şehir şebeke gürültüsünden ve EEG ile ilgisi olmadığına inanılan yüksek frekanslı EEG bileşenlerinden arındırılmasıyla daha yüksek sınıflandırma başarısı sağlanacağı düşünülmektedir [13,14]. BBA tabanlı SSVEP in bellek ve dikkat süreçleri ile ilgili olduğu hipotezi de düşünüldüğünde yüksek frekanslı bileşenlerden kurtulmak mantıklı bir yaklaşım olarak görünmektedir. Bununla beraber süzgeçleme sırasında kaybettiğimiz bilginin yararlı olup olmadığı da başka bir sorudur.

5.3. Uygulamalı Süzgeç

Sinyal işlemede esas problem alınan bir gürültülü işaretten bizi ilgilendiren işaretin elde edilmesidir. Eğer sinyal bilinen bir işarete spektruma sahipse ve bu spektrum gürültü ile üst üste binmemişse işaret, geleneksel yani klasik yapıdaki süzgeçleme ile tekrar elde edilebilir. Ancak bu durum nadir olarak gerçekleşmemektedir [73].

Bu yüzden gürültülü bir rastgele işarete tahmin problemi ile çok karşılaşılır. Bu problem genellikle belli kriterlere göre hatanın minimuma indirilmesi şeklinde giderilir. Bu işlem uygulamalı süzgecin alanıdır. Bununda başara bilmek için bilinmeyen sistemin davranışlarının lineer bir sisteme benzetilmesi gerekmektedir. Biyolojik sinyaller çoğunlukla bant sınırlı spektruma sahiptir. Pratik sinyalin kaydedilmesinde, biyolojik ve çevreden kaynaklanan gürültü işarete karışır. EEG işaretleri, beyinde duyu organlarından ve insanın değişik faaliyetlerinden dolayı meydana gelen uyarılar vasıtasıyla cerebral dokudaki sinir hücreleri tarafından üretilen ve kafatası üzerinden elektrotlar ile algılanabilen aktiviteler toplamıdır [74].

EEG'nin çok karmaşık bir değişim şekli vardır ve yorumlanması zordur. EEG işaretinin frekans bileşenleri son derece önemlidir. Kafatası üzerinden alınan EEG işaretlerinin genliği tepeden tepeye $1\mu\text{V}$ ile $100\mu\text{V}$ arasında değişmektedir. Frekans bandı ise 0.5Hz ile 100Hz arasındadır.

EEG işaretlerinin ana frekansı ile beyin aktivitesi yakından ilişkilidir. Aktivite ile frekans birlikte yükselir. Beyin dalgalarının frekansları ve karakteristikleri beyin fonksiyonunu etkileyen hastalıklara ve fizyolojik duruma da bağlı olarak değişmektedir. Uyku anında, dinlenme sırasında veya çalışırken alınan beyin işaretlerinde farklılıklar olduğu görülmüştür.

EEG işaretleri genliği çok düşük olan biyoelektrik işaretlerdir. Bu nedenle pek çok iç ve dış kaynaklı gürültüye maruz kalmakta ve işarete karışan bu gürültü işaretleri hastalığın teşhisini mümkün kılmamaktadır. Bu amaçla beyinden alınan EEG işaretlerinin analizi yoluna gidilmektedir.

5.4. LMS Algoritması

Gürültü azaltma veya yok etme değişik kaynaklar için değişik stratejiler gerektirir. Yaklaşım parametresinin istenilen şekilde hızlı veya yavaş değişimleri izleyecek şekilde dikkatlice seçilmesi gerekir [71].

Genel uyarlamalı süzgeç yapısında; birinci giriş, $S(n)$ sinyali ile gürültü bileşeni $N_0(n)$ ' in toplamı şeklindedir.

Burada

$$d(n)=S(n)+N_0(n) \quad (5.1)$$

Hata sinyali

$$e(n)= d(n)-Y(n) \quad (5.2)$$

$$e(n)=S(n)+N_0(n)-Y(n) \quad (5.3)$$

Referans sinyal süzgeç girişindeki sinyaldir ve bu da gürültü bileşeni olarak $N_1(n)$ sinyalidir. Gürültü sinyalinden $N_0(n)$ ile işaretimiz $S(n)$ istatistiksel olarak ilişkisizdir. Ancak gürültü bileşenleri birbiriyle ilişkilidir.

$$E[|e(n)|^2]=E[|S(n)|^2]+E[|N_0(n) - Y(n)|^2] \quad (5.4)$$

$E[|e(n)|^2]$ ifadesi minimum yapılmaya çalışılır. İlk terim yalnızca $S(n)$ işaretine bağlı ve bunu ortalama karesel değeri, $S(n)$ ve $N_1(n)$ birbiriyle ilişkisiz olduğu sürece $E[|e(n)|^2]$ değerini etkilemez. $Y(n)$ süzgeç çıkış değişik algoritmalar yardımıyla hesaplanarak, hatanın değeri minimuma getirilir. Hatanın sıfır olduğu durumda gürültü tam olarak arındırılmış ve gürültüsüz işaret elde edilmiştir.

İstatistiksel ortalama karesel hata ifadesi;

$$J(n) = E[|e(n)|^2] \quad (5.5)$$

$e(n) = D(n) - Y(n)$ şeklindedir. Burada $D(n)$ istenen işaret, $Y(n)$ süzgeç çıkışıdır.

Bu çözüm Wiener çözümü olarak bilinir ve aşağıdaki gibi ifade edilir.

$$R_x = E[|X(n). X(N)|^T] \quad (5.6)$$

$$P = E[d(n).X(n)] \quad (5.7)$$

R_x : Giriş sinyalinin otokorelasyon matrisi,

P : Giriş sinyali ile istenen sinyalin çapraz korelasyonu

Ayrıca her iki durumda da oto korelasyon matrisinin öz değer dağılımı ve nümerik şartlandırılması uyarlamalı öğrenme işleminin yaklaşım oranında büyük ölçüde etkiye sahiptir [71].

$$R_x. W_{opt} = p$$

W_{opt} : optimal katsayıları içeren çözüm vektörü

Buna göre R_x oto korelasyon matrisi hem simetrik hem de Toeplitz'dır. Toeplitz matrisinin genel ifadesi aşağıdaki gibidir.

$$\begin{bmatrix} a_0 & a_1 & \dots & a_N \\ a_1 & a_0 & \dots & a_{N-1} \\ \cdot & \cdot & \dots & \cdot \\ \cdot & \cdot & \dots & \cdot \\ a_N & a_{N-1} & \dots & a_0 \end{bmatrix}$$

$$\begin{bmatrix} R_{XX}(0) & R_{XX}(1) & \dots & R_{XX}(0) \\ R_{XX}(1) & R_{XX}(0) & \dots & R_{XX}(n-1) \\ \cdot & \cdot & \dots & \cdot \\ \cdot & \cdot & \dots & \cdot \\ R_{XX}(n) & R_{XX}(n-1) & \dots & R_{XX}(0) \end{bmatrix} \begin{bmatrix} W(0) \\ W(1) \\ \cdot \\ \cdot \\ W(n) \end{bmatrix} = \begin{bmatrix} R_{xy}(0) \\ R_{xy}(1) \\ \cdot \\ \cdot \\ R_{xy}(n) \end{bmatrix}$$

Uyarlamalı süzgeç ile çalışmalarda, verilen uyarlamalı parametreler $Y(n)$ ile $d(n)$ 'in karşılaştırılmasıyla ayarlanabilen katsayılar, belli bir değerde sabitlenir ve bu şekilde hata değeri elde edilir.

$$E[e^2(n)] = E[d^2] - 2WT(n).p + WT(n).RX.W(n) \quad (5.8)$$

Buradaki $W(n)$ deęişen aęırlaştırıcı katsayı vektörüdür. Uyarlamalı süzgeç, hata yüzeyini ve $W(n)$ deęerlerini hata deęeri minimum olacak şekilde ayarlar. Genel olarak Uyarlamalı süzgeçleme probleminde hata deęerinin bulunmasında aşığıdaki iterasyon algoritması kullanılır.

$$W(n+1) = W(n) + \mu X(n)e(n) \quad (5.9)$$

yazılabilir.

μ adım boyu parametresi istenen oranda yaklaşım üretmek üzere ampirik olarak seçilir.

Uyarlamalı süzgeçlerde yaklaşımda, adım boyu parametresi (aęırlaştırma oranı) μ 'nün tespiti çok önemlidir. μ 'nün tespiti için pek çok yöntem olmakla birlikte henüz evrensel, kesin bir çözüm bulunamamıştır. Buna rağmen;

$0 \leq \mu \leq 1 / \lambda_{\max}$ şartını sağlamalıdır. λ_{\max} : Giriş oto korelasyon matrisinin öz deęerlerinin en büyük olanıdır.

5.5. Öznitelik Çıkarımı

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

Öznitelik çıkarma işleminde çok farklı yöntemler kullanılabildięi için EEG işaretini tanımlayan farklı öznitelikler elde edilebilmektedir. Çıkarılan her öznitelik vektörü işareti tanımlayabilir fakat sınıflandırma aşamasında hiç biri yüzde yüz doğruluk

vermeyebilir. Bundan dolayı, yüksek sınıflandırma başarımı elde etmek için farklı özniteliklerin birlikte kullanımı gerekli olmuştur. Bu şekilde çok sayıda öznitelik kullanan sınıflandırma işlemleri daha iyi sonuçlar vermektedir. Çoklu elektrot kullanılarak kaydedilen EEG verileri incelenirken, hangi elektrot öznitelik çıkarma için daha uygundur konusu da önemlidir. Beynin farklı bölgeleri farklı görevler için daha duyarlıdır. Örneğin dokunma duyuları beynin yan kafa lobunda beden duyumu bölgesi adı verilen bölgeyle algılanıp yorumlanır. Bunun gibi koklama, işitme, hayal kurma, matematiksel işlemler yapma gibi farklı görevler beynin farklı bölgelerinde daha fazla etki yaratır. Dolayısıyla, çoklu elektrotlu EEG verilerinde tüm elektrotlardan (kanallardan) elde edilen verileri kullanmak yerine, yapılan uygulamaya göre beyinsel aktivitenin yoğun olduğu bölgelerden alınan verileri kullanmak hem sınıflandırma için çıkartılacak en iyi özneliğin bulunmasını, hem de sınıflandırma aşamasında karar verme süresinin kısılmasını sağlar.

5.5.1. TF- tabanlı özellik çıkarımı

Zaman - Frekans dağılımı (TFD) durağan olmayan sinyallerde gizli olan desen özellikleri ayıklamak için güçlü araçlardan biridir [63]. Bir sinyalin TFD'si hem zaman hem de frekans ortaklığı bir gösterimidir. Belirli bir $x(t)$ sinyali için, kuadratik sınıfa ait TFD olarak aşağıdaki şekilde ifade edilmektedir [64]:

$$\rho_z(t, f) = \iiint_{-\infty}^{\infty} e^{j2\pi v(u-t)} g(v, t) z\left(u, \frac{\tau}{2}\right) z^* \times \left(u - \frac{\tau}{2}\right) e^{j2\pi v(u-t)} dv du d\tau \quad (5.10)$$

Burada $z(t)$, $X(t)$ ile ilgili analitik sinyal ve $g(v, \tau)$ TFD özelliklerini belirleyen bir 2 boyutlu çekirdektir.

Sinyal bir FM çok bileşenli veya doğrusal olmayan olduğunda, yukarıdaki denklemde bilinear operasyonu, TFD içinde sahte bileşenler, çapraz terimler üretebilir [16]. B-dağıtım gibi düşük girişim dağılımları (RID), bir sinyalin TFDsi üzerinde çapraz terimler etkisini azaltmak için getirilmiştir [65]. Farklı TF

çekirdekleri onların uygunluk uygulamaya bağlı olduğundan dolayı, belirli koşullar altında değerlidir. EEG sinyali düşük frekans faaliyetlerini analiz etmek için B-dağıtımının çözünürlük ve çapraz terimleri açısından çok uygun olduğu görülmüştür [58]. Yüksek çözünürlükte bir TFD sinyalleri ve çoklu özellikle de bileşenleri birbirine yakın sinyallerin analizi için daha iyi bir fikir verir.

5.5.2. Single value decomposition (SVD)

SVD yöntemi sinyal işleme ve istatistiksel veri analizinde değerli bir araç olmuştur. $M \times N$ matrisinin SVD'si, x sinyalinin TFD'sini temsil etmektedir;

$$X = U \Sigma V^T \quad (5.11)$$

Burada U ($M \times M$) ve V ($N \times N$) ortonormal matrisler ve Σ bir $M \times N$ diyagonal tekil değerler matrisidir. Ortonormal matrislerin U ve V sütunları sırasıyla sol ve sağ SVs adlandırılıyor. U ve V 'nin önemli bir özelliği karşılıklı dik olmasıdır [60]. Tekil değerler, matris kompozisyonu bireysel SVs' sinin önemini göstermektedir. Başka bir deyişle, büyük tekil değerler ile ilgili SVs'ler, matrisse gömülü olan desenler için daha detaylı bilgi vermektedir.

5.5.3. TF-tabanında SVs kullanımıyla sinyal karakterize etme

SVD kullanarak TF-tabanlı sinyallerin analizinde, TF dağıtım türü önemlidir. Gerçekten de, TFD'de hem daha az çapraz terimler ve yüksek çözünürlüğe sahip olması arzu edilir. Bu özellikleri karşılamak için, yeni doğan EEG sinyaller için iyi performans sergilediğinden dolayı B-dağıtımını kullanılmıştır [58].

Önceki araştırmalar çoğunlukla sinyallerin TFD' sinin sadece tekil değerler özellikleri üzerinde yoğunlaşmıştır [68,69].

Kendiliğinden, tekil değerler matrisi, gömülü desen davranışları hakkında önemli bilgiler taşımaz. Başka bir deyişle, bu sınıflandırma açısından uygun özellikler değildir [61, 70].

SVD tekniğiyle TF- tabanlı alanındaki bir sinyalin özelliklerini bulmak için, sağ ve sol SVs büyük tekil değerlerine karşılık gelen kullanım öneriliyor. Bunun nedeni sağ ve sol SVs de, sinyale ait sırasıyla zaman ve frekans bilgilerinin yer almasıdır [61]. Buna ek olarak, en büyük tekil değerler ile ilgili SVs, sinyalin yapısı hakkında daha fazla bilgi vermektedir. Dolayısıyla, yapısı daha farklı sınıflar olan sinyaller için uygun en büyük tekil değerler ile ilgili SVs kullanarak, sınıflandırma yapılmaktadır [71]. Ancak, farklı sınıfların yapısı birbirine benzediğinde, SVs ile ilgili düşük tekil değerler daha uygun olacaktır [72].

Sol ve sağ SVs' nin TF- tabanlı alanındaki bir sinyali karakterize etmek için ne kadar gerekli olduğunu göstermek için, aşağıda örnekler verilmiştir. $X_1(t)$ ve $x_2(t)$ beyaz gürültü $n(t)$ de iki doğrusal FM sinyalleri olduğunu varsayalım;

$$X_1(t) = \sin(4\pi t + 0.02t^2) \Pi\left(\frac{t-15}{18}\right) + n(t), \quad (5.12)$$

$$X_2(t) = \sin(12\pi t - 0.02t^2) \Pi\left(\frac{t-15}{18}\right) + n(t), \quad (5.13)$$

Burada $\Pi(\cdot)$ dikdörtgen fonksiyonudur. dikdörtgen fonksiyon olarak şu şekilde tanımlanmaktadır:

$$\Pi(\alpha) = \begin{cases} 1 & -\frac{1}{2} < \alpha < \frac{1}{2} \\ 0 & \text{otherwise} \end{cases} \quad (5.14)$$

Yukarıdaki iddiayı ispatlamak için, başka bir örnek aşağıda verilmiştir. Varsayalım:

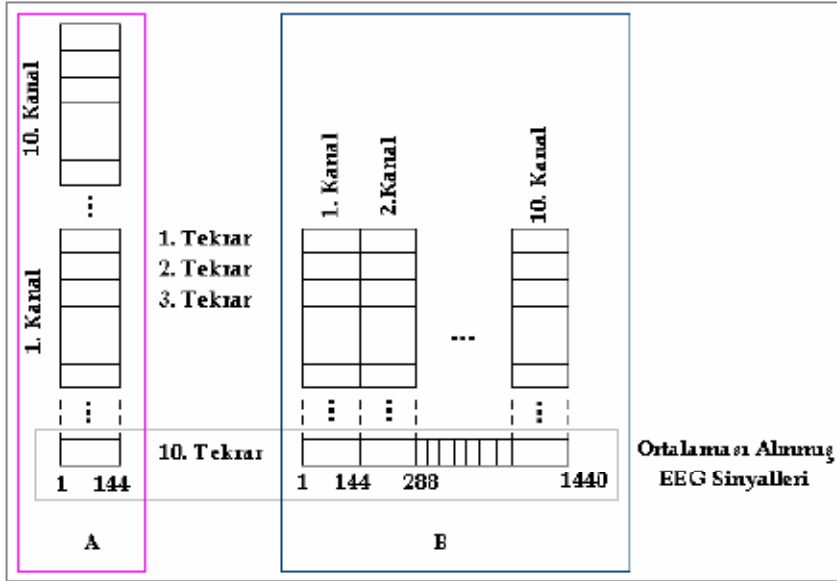
$$X_3(t) = \sin(4\pi t + 0.02t^2) \left(\Pi\left(\frac{t-9}{6}\right) + \Pi\left(\frac{t-21}{6}\right) \right) + n(t), \quad (5.15)$$

Yukarıdaki örnekler açıkça, TF-tabanlı alanında durağan olmayan sinyaller karakterize etmesi için, sol ve sağ SVs aynı anda kullanılmasının gerektiğini göstermektedir. Yukarıda belirtilen teknik durağan olmayan sinyallerin özellikleri ayıklamak için yararlıdır. Ancak, bu yöntemin üç dezavantajı vardır. İlk olarak, TF parsellerde gömülü desenleri karakterize etmek için sabit bir sayı özelliğini (dikdörtgenler) kullanmakta. İkincisi, eğer yoğunluk fonksiyonunda birden fazla localmaximum varsa, yoğunluk fonksiyonlarının birinci ve ikinci anlar konumu ve yerel maksimum genişliğini gösteremez. Üçüncüsü, TF deseni sağ ve sol SVs, ortonormal bazlar ayrılmıştır, sadece bir sağ ve sol SVS tarafından ele olmayabilir.

5.6. Ortalama

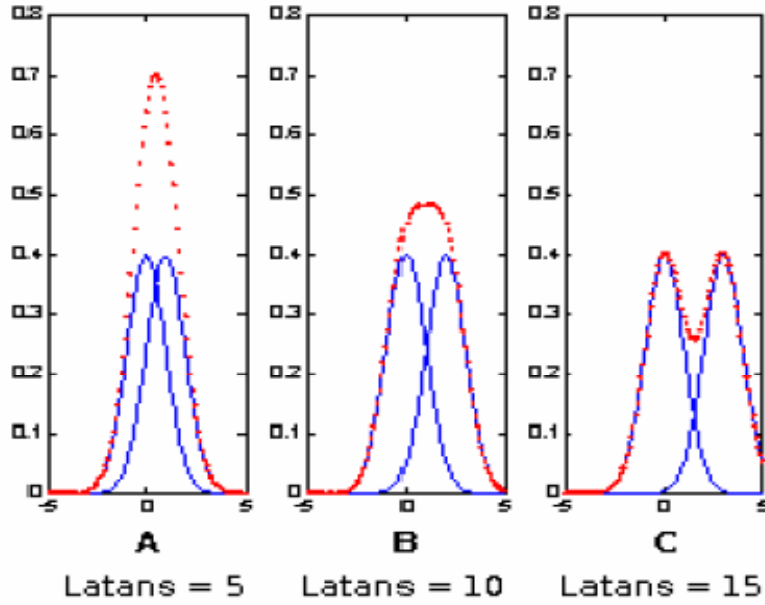
Birden fazla tekrar ile elde edilen sinyallerin ortalanması ile elde edilen SSVEP sinyalinin sınıflandırma başarımını pozitif yönde etkilediğinden bahsetmiştik. Sınıflandırma için kullanılacak EEG sinyalinin birden fazla kanaldan elde edilmesi durumunda farklı kanallardaki bilginin nasıl bir şekilde kullanılacağı sorusu akla gelmektedir. SSVEP tabanlı BBA sisteminde sınıflandırmayı konu alan benzer çalışmalarda [13,14,21,22] Şekil 5.2 B’de gösterilen yöntem kullanılmıştır. Bu yöntemde her bir kanal için elde edilen ortalanmış veriler ucuca eklenerek uzun bir öznitelik vektörü yaratılır.

Bu yöntem ile örneğin bu veri kümesinde, örnekleme frekansı 240 Hz olup 600 ms lik pencerelerde çalıştığımızdan dolayı elimizde 144 nokta uzunluğunda bir öznitelik vektörü olur. Bir kanal üzerinden bu 144 noktalı farklı zamanlardaki parçacıklar ortalandığında yine 144 noktalı bir öznitelik vektörüne ulaşılmaktadır. Analiz için eğer 10 kanal kullanırsak, öznitelik vektörümüzün uzunluğu $144 \times 10 = 1440$ nokta olacaktır. Yaratılan bu vektör sınıflandırıcıda kullanılır. Bizim burada gerçekleştirdiğimiz yeni yöntem Şekil 5.2A’da da görülen bütün kanalların önce kendi içlerinde sonrasında da ortaya çıkan ortalanmış vektörlerin birbirleri ile ortalamaları alınarak gerçekleşir.



Şekil 5.2. A) Kanalların önce kendi içlerinde tekrar sayısına göre, sonra da bütün kanallardaki ortalananmış tekrarların birbiriyle ortalananması (önerilen yöntem). B) Kanalların kendi içlerinde tekrar sayısına göre ortalandıktan sonra yan yana eklenerek uzun bir öznitelik vektörü oluşturulması (klasik yöntem) [23].

Bu durumda elimizdeki öznitelik vektörümüzün uzunluğu 144 nokta olacaktır. Farklı kanalların üst üste ortalananması sonucu oluşabilecek etkileri anlatan basit bir model Şekil 5.3'te gösterilmiştir. Kanallar arası latans farkı arttıkça sinyal zaman düzleminde kayacak ve kanallar üzerinden yapılan ortalamanın performansının düşmesine neden olacaktır.



Şekil 5.3. İki ayrı kanalın etkileşiminden oluşabilecek kanallardaki latans farklılıklarının toplam SSVEP sinyaline etkileri. Burada ortalama alınmamış, yalnızca toplamlar gösterilmiştir [23].

5.7. Sınıflandırma


Farklı düşünsel ve görsel durumlarda kaydedilen EEG işaretlerini elde edilen öznelik vektörlerine göre sınıflandırma BBA teknolojisinde önemli bir konudur. İşaretin hangi sınıfa ait olduğuna karar verme hem hızlı hem de doğru olmalıdır. Literatürde birçok sınıflandırma yöntemleri mevcuttur. Bunlardan en çok kullanılanları destek vektör makineleri (Support Vector Machines), K En yakın komşuluk (K nearest neighbor), doğrusal ayırteden analizi (linear discriminant analysis), sinir ağları (neural networks), bayes sınıflandırıcısı (bayesian classifier) 'dır. Aynı tür uygulamada değişik sınıflandırma algoritmaları farklı sonuçlar verebilmektedir [42]. Elde edilen öznelik vektörlerine en uygun sınıflandırıcıyı seçebilmek için sınıflandırma yöntemlerinin özelliklerinin iyi bilinmesi gerekmektedir. Aşağıda BBA alanında sıklıkla kullanılan K En yakın komşuluk ve destek vektör makineleri yöntemlerinin özellikleri, üstünlükleri, kritik noktaları üzerinde durulmuş, performans analizleri incelenmiştir.

5.7.1. K en yakın komşuluk

KNN algoritması sorgu vektörünün en yakın k komşuluktaki vektör ile sınıflandırılmasının bir sonucu olan denetlemeli, oldukça basit bir öğrenme algoritmasıdır [21]. Buna göre; tanıma yapılacak öznelik vektörüne en yakın k komşu bulunur. Daha sonra bu k komşu en fazla hangi sınıfa ait ise, o sınıf tanıma sonucu olarak atanır. K sayısını belirlemenin en pratik yolu k'yı toplam eğitim örnekleri sayısının karekökünden daha az olarak seçmektir [44]. BBA uygulamalarında bu en yakın k komşular genellikle bir metrik uzaklık kullanılarak elde edilir. En yaygın kullanılan Öklidyen uzaklığına dayalı metriktir [45, 46]. KNN algoritmaları büyük boyutlu öznelik vektörlerinde etkin olmamakla [45, 46, 47] birlikte düşük boyutlu öznelik vektörleri ile etkin olabilmektedirler [42, 49].

5.7.2. Dinamik sinaps sinir ağında dalgacık dönüşümü

Bu çalışmada, Liaw ve Berger çalışmalarına benzer şekilde, LIF nöronlardan oluşan iki katlı bir ağ kullanılmıştır [32].



Şekil 5.4. DSNN ve dalgacık önişlemci Mimarlığı.

Şekil 5.4'te görüldüğü gibi, iki kat arasında nöronlar tamamen birbirine bağlıdır. Girdi katmanı on altı nörondan oluşur, bu girişlerin her birisi dalgacık paketinden çıkan bir frekans alt bandını alır. Çıkış katmanlarından biri inhibitör interneuron olarak tüm sinapslara negatif geri bildirim gönderir. Diğer çıktı katmanları, SSVEP-EEG sinyallerinin tanınması için birer sınıf göstermektedirler.

Bu çalışmada, giriş nöronları bir dizi EEG sinyalleri almak, tanıma işlemini başlatmak için aksiyon potansiyellerini oluşturur. Giriş sinyallerinden daha önemli bilgiler elde etmek için Dalgacık dönüşüm paketi kullanılıyor.

Konuşma ve biyolojik sinyal kayıtları gibi karmaşık sinyaller, Zaman-Frekans yapıları farklı türleri olarak karşımıza çıkmaktadır. Bu zaman-frekans özelliklerine adapte olabilir tabanlı tasarımlara yol açabilir.

Dalgacık tabanlı etkili düz sinyallerin temsili temel bir belirli tekniktir. Diğer teknikler yüksek salınımlı dalga gibi sinyallerin farklı yaklaşımlarıyla sınırlı olmaktadır.

Dalgacık paket temelleri çeşitli boyutlarda ayrı aralıklarla frekans eksenini bölmek için eşlenik ayna filtreleri kullanmaktadır. Daha öncede anladığımız gibi, büyüklüğü N olan bir sinyal $2^{\frac{N}{2}}$ den fazla $O(N \log_2 N)$ operasyonlu hızlı bir filtre bankalı dalgacık paket tekniği algoritması gerekmektedir. Aslında dalgacık paket yöntemi sinyal analizi için olasılıkları zengin sunmaktadır ve buda dalgacık için bir genellemedir. Dalgacık analizi, bir sinyal bir yaklaşım ve bir detay ayırmaktır. Bu yaklaşım kendisi bir ikinci düzey yaklaşıma ve detaya ayrılmıştır, bu işlem tekrarlanır. N -seviyeli bir çözümleme için, orada ayırtırmak veya sinyal kodlamak için $n+1$ olası yol bulunmaktadır. Hiyerarşik dalgacık paket dönüşümü, iki alt grup halinde orijinal sinyal ayırtırmak için dalgacık fonksiyonları ve bunların ilişkili ölçekleme fonksiyonlarını bir küme halinde kullanmaktadır. Bir ortonormal dalgacık olarak seçilirse, bilgisayarlı katsayıları bağımsız olacaktır ve sonucu olarak özellik

vektörleri ayrı grupta yer alacaktır. Benzer şekilde, dalgacık paketleri aşağıdaki temel fonksiyonlar, toplama tarifliğiyle edilebilir:

$$W_{2n}(2^{\rho-1}x-1) = \sqrt{2^{1-\rho}} \sum_m h(m-2l) \sqrt{2^\rho} W_n(2^\rho x - m) \quad (5.16)$$

$$W_{2n+1}(2^{\rho-1}x-1) = \sqrt{2^{1-\rho}} \sum_m g(m-2l) \sqrt{2^\rho} W_n(2^\rho x - m) \quad (5.17)$$

P ölçekli indeksi, l çeviri indeksi, h low-pass filtre ve g high-pass filterler olarak kullanılmaktadır:

$$g(k) = (-1)^k h(1-k) \quad (5.18)$$

Şöyle ortonormal özelliğinden dolayı, farklı ölçeklerde ve ayrık sinyal pozisyonlarda dalgacık paket katsayılarının verimli hesaplanır:


$$C_{n,k}^\rho = \sqrt{2^\rho} \sum_{m=-\infty}^{+\infty} f(m) W_n(2^\rho \cdot m - k) \quad (5.19)$$

$$C_{2n,1}^{\rho-1} = \sum_m h(m-2l) C_{n,m}^\rho$$

$$C_{2n+1,l}^{\rho-1} = \sum_m g(m-2l) \cdot C_{n,m}^\rho$$

(5.20)

Bu tür bir ayrışmada, ön işleme aşaması olarak, dinamik bir sinaps sinir ağının önceden incelenmesinin çok faydalı olduğu düşünülmektedir.




Şekil 5.5. (a) Örnek bir EEG dalga (b) Dalgacık paket ayrıştırması.

Burada, dalgacık dönüşüm paket teorisi, on altı frekanslı alt bantlar için hesaplanan ham EEG sinyallerinin seviye ayrıştırma ağacı için kullanılmıştır. Ayrıştırma işlemini gerçekleştirmek için Symlet4 geçiştirilmiştir, çünkü EEG sinyallerinin işlenmesi için yapılan araştırmalar bu algoritmanın uygun olduğunu ispatlamıştır. Şekil 5.5'te, ilk denemeden gelen ham EEG sinyal için ayrılmış sinyal gösterilmektedir.

5.7.3. Destek vektör makineleri (DVM)

1960'ların sonlarında V. Vapnik tarafından bulunan istatistiksel bir algoritma olan DVM [28] özellikle EEG işaretlerinin sınıflandırılması aşamasında sıklıkla kullanılır ve geleneksel metotlardan çok daha iyi sonuçlar vermektedir. Yapısal risk

minimizasyonu prensibi etrafında formüle edilmiştir ve beklenen riskin üst sınırını küçükmeye çalışır. Şekil 5.6 da verilen iki ayrı kümeyi birbirinden ayırmak için sonsuz sayıda optimal olmayan hiperdüzlem çizilebilir. Ancak DVM bu iki kümeyi ayırmak için maksimum marjini (en yakın eğitim noktalarının uzaklığı) sağlayan optimal hiperdüzlemi arar.



Şekil 5.6. Maksimum marjinli hiperdüzlem.

Seçilen kernel fonksiyonuna göre doğrusal ve doğrusal olmayan sınıflandırma biçimleri vardır. BBA uygulamalarında çoğunlukla Eşitlik 5.21’de verildiği biçimde radyal tabanlı kernel (RTK) çekirdek fonksiyonu kullanılır. DVM’de σ değeri ve düzenleme parametresi en iyi sınıflandırma performansı elde edilecek şekilde elle ayarlanabilmektedir.

$$K(x,y) = \exp\left(\frac{-\|x-y\|^2}{2\sigma^2}\right) \quad (5.21)$$

DVM, uygulamasının hızlı olması ve özellikle yüksek boyutlu öznitelikler için çok iyi sonuçlar vermesinden dolayı BBA alanında sıkça başvurulan bir sınıflandırma yöntemidir. DVM de KNN gibi sınıflandırma işlemi sırasında öznitelik vektörlerin zamansal bilgilerini dikkate almaz bu bakımdan statiktirler. Diğer taraftan DVM sınıflandırıcısında eğitim kümesindeki küçük değişimler sınıflandırma performansını etkilemez bu bakımdan kararlılık özelliği vardır. Sınıflandırma işlemlerinde karşılaşılan bir zorlukta aşırı eğitim (overtraining) durumudur. Bu durumda eğitilen

ağ eğitim örneklerini mükemmel olarak uygunlaştırır fakat test setindeki örneklerde doğru sonuçlar vermeyebilir. DVM'de düzenleme parametresi ile aşırı eğitim engellenebilir ve çok iyi sonuçlar elde edilebilir.

Süreğen EEG içerisinde anlık uyarılara yanıt olarak üretilen SSVEP aktivitesinin var olup olmadığını anlamak ikili bir sınıflandırma problemidir. Uyarının verildiği andan itibaren EEG sinyalinin ilk birkaç yüz mili saniyelik bölümü bu tip sınıflandırma problemlerinde kullanılan standart bir seçimdir [12,13,14,15,16]. Bu çalışmada, seçilmiş EEG sinyal parçacıkları farklı öznitelik vektörleri oluşturacak şekilde düzenlenmiş ve bir DVM [19] kullanılarak sınıflandırılmışlardır. Bu yöntemin kullanılmış olmasının sebebi daha önce aynı veri kümesi üzerinde yapılan çalışmalarda yüksek başarımlar sağlamış olmasıdır [14]. İkili bir sınıflandırma yapmanın en basit bir yolu en iyi çoklu düzlem yaratmaktır. Örüntü analizi algoritmaları bir takım eniyileme ölçütüne göre sınıflar arasındaki birçoklu düzlem bulmaya çalışır. Bu düzlem bulunduğunda, daha sonra bir test verisi üzerinde öngörü yapmak mümkündür. Bu eniyileme işlemi birden fazla çoklu düzlem ile gerçekleştirilebilir. Mümkün olan en ayırt edici çoklu düzlemi bulmak için en yüksek sınır ölçütü, eniyileme içerisine eklenir. DVM'nin davranışı düzenleme parametresi C ve bant genişliği σ ile ilgilidir. İyi sonuçlar elde edilebilmesi için bu değişkenlerin doğru seçilmesi kritiktir. Bu çalışmada daha önceden en iyi sonuçları verdiği gösterilmiş değerler kullanılmıştır ($C = 20.007$, $\sigma = 27.359$) [14].

6. SONUÇ VE ÖNERİLER

EEG işaretleri yapısı gereği sürekli değişim gösteren oldukça karmaşık işaretler olduğundan sağlıklı yorumlanmaları matematiksel yöntemlerle analizlerine bağlıdır. Çok miktarda bilgi içerdikleri, gün geçtikçe yapılan çalışmalarla ortaya çıkmakta olan EEG işaretleri, özellikle tıpta teşhis ve uygulanan tedavilerin başarımlarının izlenmesinde kullanıldığı gibi, insanoğlunun hayatına farklı teknolojilerle de gireceği kesindir. EEG uygulamalı teknolojiye atılan adımlardan biri olan BBA sistemleri halen geliştirilme aşamasındaki sistemlerdir. BBA konusu ülkemizdeki üniversiteler de dahil olmak üzere dünyada bir çok üniversite tarafından çeşitli seviyelerde incelenen oldukça popüler bir araştırma konusudur. Araştırmalar sonucunda dünya nüfusunda göz ardı edilemeyecek kadar yüksek sayıdaki felçli ve ALS hastaları için hayatlarını daha kaliteli yaşayabilme olanağı sunulacaktır.

Özellikle güvenli, acı vermeyen ve kullanımının kolay olması gibi avantajlarının yanında sınıflandırma başarımındaki yetersizlik, veri bit hızının yavaş olması, etkin öznitelik vektörlerinin bulunmasının zaman alması bu alanda dikkat çeken olumsuzluklardır. İşaret gruplarını birbirinden ayırabilecek etkin bir öznitelik çıkarma yöntemi kullanarak bu grupları sınıflandırmada da önemli bir rol oynamaktadır. Etkin özniteliklerde de ancak bir ön işleme ara birimi ile nörolojik bilgiyi kaybetmeden gürültüden tamamen arındırılmış EEG işaretlerini kullanmak sureti ile elde edilebilir. EEG tabanlı BBA'larda sınıflandırma yöntemi olarak düşük boyutlu öznitelik vektörleri için kNN, büyük boyutlu öznitelik vektörleri için DVM algoritmaları sınıflandırmada başarılı sonuçlar vermektedir. Dolayısıyla uygun öznitelik vektörleri için uygun sınıflandırma algoritmasının seçimi çok önemlidir.


Yukarıda da değinildiği gibi farklı düşünsel ve görsel uygulamalarda kaydedilmiş EEG işaretlerinden öznitelik çıkarma işlemi çok önemlidir. Öznitelik çıkartımı için literatürde birçok matematiksel yöntem mevcuttur. Her yöntem her uygulamada iyi sonuç vermeyebilir. Yapılan uygulamaya has matematiksel analizlerle, o uygulamaya ait öznitelik(ler) aranmalıdır. Diğer taraftan farklı insanlardan aynı uygulamaya ait EEG işaretleri de insan fizyolojisi gereği aynı olmayacağından, bulunacak

öznitelik(ler) kişiden kişiye de farklı sonuçlar verecektir. Yapılacak çalışmalarda tüm bunların dikkate alınması çalışmanın sağlıklı temellere dayandırılması açısından önemlidir.


6.1. LMS Algoritması İçin Doğrulama Sonuçlar

Çalışmada National Instrument firmasının geliştirdiği grafiksel programlama olan LabVIEW grafik programlama dili kullanıldı. Lab VIEW yazılımı ile geliştirilen LMS algoritması, oluşturulan EEG veri toplama ünitesi ile elde edilen işaretlere ve simule işaretlere uygulanmıştır [73].

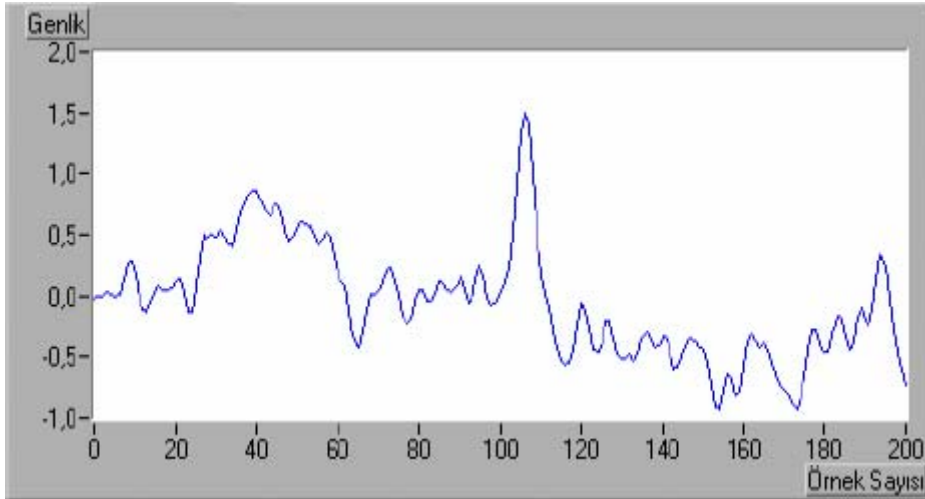
Şekil 6.1 de bir SSVEP işaretinin zamana göre değişimi görülmektedir. Şekil 6.1 deki EEG (SSVEP) işaretine beyaz gürültü işareti bindirdiğimizde, Şekil 6.2 deki gürültülü EEG işaretinin zamana göre değişimini elde etmekteyiz. İşareti gürültüden arındırmak için; Referans işaret olarak beyaz gürültü işareti ile gürültülü EEG işaretini süzgeç girişlerine uygularsak Şekil 6.3 deki gürültüsü bastırılmış süzgeç çıkışını elde ederiz.



Şekil 6.1. Bir SSVEP-EEG işaretinin zamana göre değişimi.



Şekil 6.2. Gürültülü SSVEP-EEG işareti.




Şekil 6.3. Gürültülü SSVEP-EEG işaretinin Uyarlamalı süzgeç çıkışı.

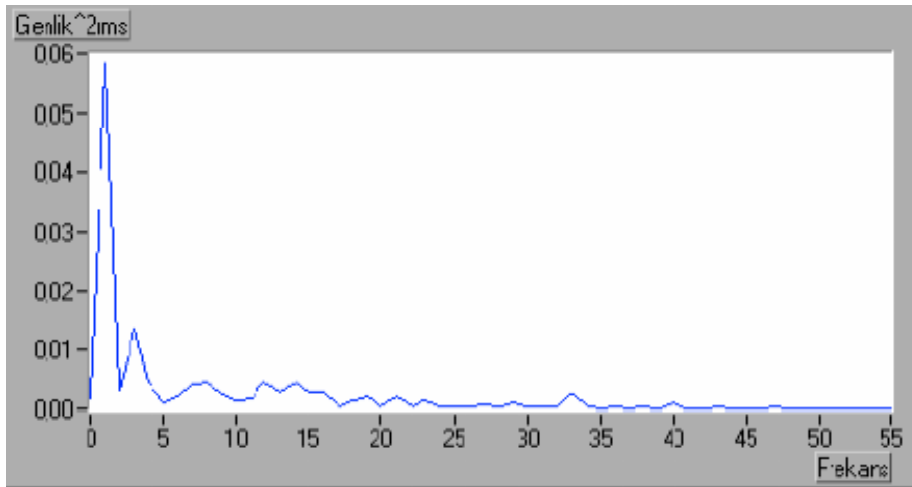
Şekil 6.4, beyaz gürültü eklenmiş olan, Şekil 6.3 deki gürültülü işaretin güç spektrumu, Şekil 6.5 ise gürültülü işaretin, gürültüsünün bastırılması işleminden sonraki uyarlamalı süzgeç çıkışından alınan işaretin güç spektrumları gösterilmektedir. Şekil 6.4 deki güç spektrumunda, işaretin frekans içerikleri tam olarak gözlenememekte, işaretin mevcut frekans bileşenlerinin yanında beyaz

gürültüden kaynaklanan frekans bileşenleri de görülmektedir, değişik frekans değerlerinde yanlıtıcı ani pikler de mevcuttur.

Şekil 6.5 deki güç spektrumunda, uyarlamalı süzgeç çıkışından alınan gürültüsü bastırılmış işaretin güç spektrumu verilmiştir. Burada güç spektrumunda, frekanslar 0-5 Hz arasında yüksek genlikli olarak görülmektedir. 5-10 Hz ve 10-17 Hz arasında da işaretin frekans içerikleri belirgin olarak tespit edilebilmektedir.



Şekil 6.4. Gürültülü SSVEP- EEG işaretinin güç spektrumu.




Şekil 6.5. Uyarlamalı süzgeç çıkışından alınan işaretin güç spektrumu.


Şekil 6.1 deki işaret SSVEP-EEG işaretiydi. SSVEP-EEG işaretleri özellikle 0-8 Hz arasında yoğun olarak görülmekte diğer frekans değerleri ise işarete bulunmamaktadır. Dolayısıyla Şekil 6.5 de elde edilen güç spektrumu Şekil 6.4 deki güç spektrumuna göre daha belirleyici olmaktadır. İstenmeyen frekans içerikleri bastırılmış ve buradaki pikler görülmemektedir.

Şekil 6.6 da 26 yaşında deneyden alınan normal EEG işaretinin zamana göre değişimi verilmektedir. Bu normal EEG işaretine, beyaz gürültü bindirirsek, gürültülü EEG işareti Şekil 6.7 deki gibi elde edilir.

Şekil 6.7 de verilen gürültülü normal EEG işareti, EEG işaretlerinin içerdiği Delta Dalgaları, (0.5 – 3.5 Hz), Teta Dalgaları (4-7 Hz), Alfa Dalgaları (8-12 Hz) ve Beta Dalgalarının (13-22 Hz) oluşturduğu dört ayrı frekans bandının yanında beyaz gürültüden kaynaklanan frekansları da içermektedir.




Şekil 6.6. 26 yaşındaki bir deneyden alınan normal EEG işareti.




Şekil 6.7. Gürültü bindirilmiş normal EEG işareti.

Normal EEG işaretinin süzgeç çıkışı Şekil 6.8 de verilmektedir. Şekil 6.9 da gürültülü güç spektrumu, Şekil 6.10 da ise, Şekil 6.8 de verilen süzgeç çıkışındaki,

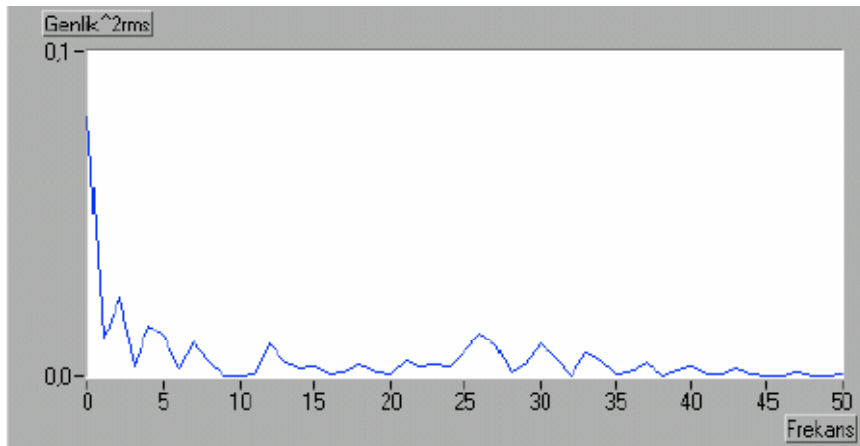


Şekil 6.8. Gürültülü normal EEG işaretinin süzgeç çıkışı.



Şekil 6.9. Gürültü bindirilmiş normal EEG işaretinin güç spektrumu.

gürültüsü bastırılmış EEG işaretinin güç spektrumu çizdirilmiştir. Burada, güç spektrumunda istenmeyen frekans bileşenlerinin yok edildiği görülmektedir. 0-9 Hz arasında ve 24-32 Hz arasında EEG işaretinin yüksek genlikli frekans bileşenleri görülebilmektedir. Yanıltıcı frekans bileşenleri süzgeç çıkışında bastırılmıştır. Bu şekilde Delta (0.5–3.5Hz) , Teta (4 - 7 Hz), Alfa (8 - 12 Hz), Beta Dalgaları (13 - 22 Hz) dalgalarının ayırt edilmesi teşhis ve tedavinin daha sağlıklı yapılması mümkün olabilmektedir [74].



Şekil 6.10. Gürültüden arındırılmış normal EEG işaretinin güç spektrumu.

6.2. SSVEP-Tabanlı BBA'de Dataset II Denemesi

Bu bölümde Graz Üniversitesi Araştırma Enstitüsü tarafından sağlanan veri kümesi üzerinde yapılan deneyler sunulmaktadır. Bu data set, dört farklı SSVEP tabanlı görevden oluşuyor.

- Parmakları açma
- Parmakları kapatma
- Sağa hareket
- Sola hareket

6.2.1. Deney açıklaması

14 kişinin üstünde yapılan deneyler sonucu aşağıda iki çizelgede açıklanmaktadır. Bu deney için kişiler çok uyumluluk gösterdiler, teknik açıdan hiçbir göz hareketi sonuçları etkilemedi ve kişilerin sarı ışığa karşı çok doğru sonuçları elde edildi. Çizelge 6.1de tek boyutlu özelliği kullanan (F1) tüm 14 kişi için sınıflandırma doğrulukları gösterilmektedir. Geribildirim olmadan, en yüksek doğruluk bu özelliği çıkarma yöntemi kullanarak "sarı" görev türüne ait oldu% 65.1. Tüm görev türleri için, ortalama doğrulukları elde edilen sonuçları ile karşılaştırıldığında önemli ölçüde azalması göz önüne geliyor. Çizelge 6.2 de iki boyutlu özelliği (F2) kullanan tüm 14 kişi için sınıflandırma doğruluklarını gösterir. Tüm görev türleri için ortalama doğrulukları marjinal özelliği, (F1) kullanılarak elde edilenlerden daha yüksektir. Görevin tamamlanmasını takiben kişilerin raporlarına dayanarak "sarı" görev türü "kolay" olarak kabul edilmesi belirtildi. "geri besleme", görev türü geribildirim değişkenliği nedeniyle "hayal kırıklığı" olarak kabul edildi.


Şekil 6-11 görülen konumlarda bulunan 22 elektrot kullanılarak EEG verileri kaydedildi. Örneklem hızı 250 Hz ve EEG sinyalleri 0,5-100 Hz'lik bir frekans aralığında band-pass şeklinde süzgeçlendi. Ayrıca 50 Hz notch süzgeç hat gürültüsünü bastırmak için kullanılmıştır [71].

Çizelge 6.1. Tek boyutlu özelliği (F1) kullanan deneyler için elde edilen değerler.

Deney	Standards	Sarı	Geribildirim	Geribildirim&Sarı
1	56.9	65.1	55.1	56.8
2	53.0	51.5	56.7	57.6
3	51.9	58.2	56.2	53.5
4	57.3	58.5	50.2	55.3
5	42.8	56.3	56.5	49.5
6	47.7	55.1	56.1	55.9
7	57.3	50.4	51.0	50.8
8	60.4	56.5	47.9	57.4
9	54.2	54.8	57.5	56.2
10	55.4	52.2	59.2	52.4
11	57.5	55.3	52.7	52.1
12	48.5	51.8	60.3	45.9
13	52.3	52.9	42.3	48.2
14	64.9	57.0	61.2	52.1
Ortalama	54.3	55.4	54.5	53.1

Çizelge 6.2. İki boyutlu özelliği (F2) kullanan deneyler için elde edilen değerler.

deney	Standards	Sarı	Geribildirim	Geribildirim&Sarı
1	59.6	65.6	54.1	58.2
2	56.1	51.4	59.3	55.6
3	55.1	57.4	60.5	55.4
4	56.0	57.2	55.3	63.6
5	53.2	59.9	54.4	49.1
6	54.5	54.8	56.8	53.3
7	63.5	57.0	50.4	55.0
8	71.2	54.5	53.6	58.7
9	66.0	58.1	61.8	59.7
10	52.2	50.4	56.1	57.7
11	54.4	57.4	58.3	50.7
12	49.1	54.2	61.2	55.2
13	52.9	59.5	49.3	53.7
14	67.9	56.4	60.1	52.7
Ortalama	58.0	56.7	56.5	55.6



Şekil6.11. Deneyde kullanılan elektrot yapılandırması [75].

Sınıflandırma için veri önceden hesaplanmış özellik vektörleri verilmiştir.

6.2.2. Özelliklerin açıklaması

Ön hesaplanan özellikleri sinyal geliştirme ve özellik çıkarma aşamalarında dikkate almadan EEG sinyal işleme sorunun sınıflandırma aşamasına odaklanma açısından yararlıdır. Bu çıkarılan özellikler zaten temelde SSVEP-EEG verilerinin ilgili frekans içeriğini özetliyor. Bu özellikleri çıkarmada önce Butterworth süzgeci kullanılmıştır []. Daha sonra Single Value Decomposition (SVD) yöntemi filtrelenmiş EEG dataları, 8-30Hz frekans aralığında hesaplanmıştır. Frekans çözünürlüğü 2 Hz ve LMS hesaplamada kullanılan elektrot sayısı 8 (C3, Cz, C4, CP1, CP2, P3, Pz, P4) olarak düşünülmüştür. Sonuç olarak, 96 boyutlu özellik vektörleri (8 kanal, 12 frekans bileşenleri) elde edilmiştir.

6.2.3. Ön hesaplanmış özelliklerin sonuçları

Bu bölümde sınıflandırma teknikleri kullanılarak elde edilen sonuçlar sunulacaktır. Sınıflandırma adımında, sinaptik sinir ağları ve Destek Vektör Makinesi (DVM) incelenmektedir. Metodolojilerin çıkan performans sonuçları test verileri üzerinde

değerlendirilmektedir. Bu strateji, aynı dataset üzerinde diğer yöntemler ile elde edilen sonuçların kıyaslamasını sağlar.

Değerlendirme aşamasında, ilk olarak, saniyede 16 kez hesaplanan her öznitelik vektör girişi için bir sınıflandırma çıktısı oluşturulur. Daha sonra 8 ardışık çıkışın ortalaması hesaplanarak her 0.5 saniyede bir yanıt üretilir. Son olarak, sınıflandırma doğruluğu hesaplanır.

6.2.4. SVM Sınıflandırma için doğrulama sonuçları

DVM sınıflandırma yönteminde, sınıflandırma performansı açısından en iyi sonuçları sağlamak için Radial Basis Function (RBF) kernel tercih edilmektedir [68]. Principal Component Analysis (PCA) tabanlı RBF kernel, DVM sınıflandırmasında, optimize edilmesi için üç parametre vardır. Birincisi RBF kernelin γ katsayısı, ikincisi C düzenleme parametresi, ve üçüncü bir PCA-Katsayısıdır. Bu parametrelerin optimum değerlerinin bulunmasında doğrudan analitik bir yol olmadığı için, doğrulama ayarı, eğitim verileri üzerinde farklı γ , C ve PCA-Katsayıları kombinasyonu için hesaplanır. Bu kombinasyondan oluşan maksimum doğrulama ayarı, son sınıflandırma modeli oluşturmak için kullanılır. Bu çalışmada γ ve C değerleri arama alanını genişletmek için exponential şekilde büyümekte. C 2^{-1} ve 2^7 arasında değiştiği ise γ 2^{-31} ve 2^5 arasında değişmektedir. Örnek bir doğrulama ayar tablosu Çizelge 6.3 'te verilmiştir.

Çizelge 6.3'te farklı γ , C ve PCA katsayıları kombinasyonları için doğrulama ayarı verilmektedir. Çizelge'den de görüldüğü gibi γ & C kombinasyonun optimize değerleri kesinlikle PCA katsayısına bağlıdır. Bunun nedeni de, geniş bir aralıkta optimum γ & C kombinasyonu aramasıdır. Çizelge 6.3'te gözlenen bir başka özellik, işaretlenmiş maksimum ayarların doğruluklarının genel artış eğilimidir. Bu bizim için beklenen bir durumdur, çünkü özellik vektör boyutu ve özellik vektöründen oluşan bilgi yüzdesi, PCA katsayısının artmasıyla artıyor. Ancak, maximum doğrulama ayarı PCA-Katsayı 99'da elde edilir. Bir kısım bilgilerin PCA da kayıp olma nedeni gürültü olarak belirlenmiştir. Bu sınıflandırma problemlerinde PCA kullanmanın en önemli avantajlarından biridir. Küçük PCA Katsayıları için, kayıp bilgi oranında gürültü etkisi oldukça azalır. Bu nedenle doğrulama ayarı bir azalma görülmektedir. Ancak, PCA hala yüksek boyutlu hızlı yanıt oluşturma açısından, tercih edilmektedir.

6.3. Sinaptik Sinir Ağları Sınıflandırma İçin Doğrulama Sonuçları

Sinaptik sinir ağları sınıflandırma yöntemi için optimize edilmesi gereken iki parametre vardır. Birincisi, üç katmanlı ileri beslemeli ağ için, gizli katman düğüm sayısıdır ve ikinci PCA-Katsayısı'dır. Bu amaçla, doğrulama ayarı, farklı nHidden ve PCA-katsayı, kombinasyonları için eğitim verileri üzerinde hesaplanmıştır. Bu kombinasyon maksimum doğrulama ayarını kullanarak, son sınıflandırma modeli oluşturur. Çizelge 6.4'te, bir deney için doğruluk ayarı, farklı düğüm sayısı ve PCA-katsayıları kombinasyonu için verilmekte.

Çizelge 6.4: Deney Üzerinde farklı düğüm sayısı ve PCA-katsayı, kombinasyonları için eğitim verileri üzerinde hesaplamalar.

PCA-katsayısı:	97	97.5	98	98.5	99	99.5
Düğüm						
5	54,27	54,12	54,15	55,58	61,54	63,85
9	54,65	54,77	54,58	59,00	62,65	64,08
13	54,73	54,08	54,38	57,96	62,04	63,15
17	54,77	54,27	55,38	57,58	62,27	63,73
21	54,65	54,15	55,12	58,54	62,65	63,81
25	54,42	54,38	55,54	58,35	62,73	64,31
29	55,00	54,69	55,42	58,73	62,00	64,73
33	54,92	54,46	55,69	58,38	62,58	64,46

Çizelge 6.4'te görüldüğü gibi düğüm sayısı ve PCA-katsayı değerleri artıka doğru doğrulama değerleri genel bir eğilim ile artmakta. Ancak, düğüm sayısı 20'nin üzerine çıktığında, doğrulama ayarı değişmemektedir. 21 gizli düğüm, sınıflandırma işlemi gerçekleştirmek için yeterli gibi görünüyor.

Bu çalışmada, dalgacık dönüşüm paketini kullanarak geçici bir desen olarak, EEG sinyalleri analiz edilmiştir. Mevcut yöntemlerin aksine, dalgacık paket dönüşümünü sinyallerin faz bilgileri ihmal değildi, çünkü ayrıştırma ana sinyalinin faz bilgilerini korur. Bu yüzden teklif sınıflandırıcının başarısı bazı bu konuda bağlı olduğunu söyleyebiliriz. Sınıflandırmayla ilgili sonuçlar Çizelge 6.5 ve 6.6 da gösterilmektedir.

Çizelge 6.5: DSSA Sınıflandırmasıyla ilgili sonuçlar.

Deneme No	İterasyon sayısı	Yapılan test sayısı	Test setinde önerilen yöntemin performansı	Örenme setinde önerilen yöntemin performansı
1	100	140	51.04%	92%
2	100	140	53.28%	90.6%

Çizelge 6.6: SSA ve DVM sınıflandırma yöntemlerinin karşılaştırılması.

Deneme No	Özellik Tipi	Seviye	Performans (SSA)	Performans (DVM)
1	Sym4	2	64.3%	52%
2	Sym4	3	84.47%	65%
3	Sym4	4	87.3%	71.3%

Görüldüğü gibi, EEG işleminde çok iyi bir sonuç yani % 90.6 ile tanıma doğruluğunu göstermiştir. Kullanılan SSA ve DVM sınıflandırma yöntemlerinin doğruluğunu, SSVEP işaretleri için Çizelge 6.6 da sunulmuştur.

Çizelge 6.5, 6.6 da' da görüldüğü gibi SSA sınıflandırma yöntemini kullanarak daha az öğrenme ile daha iyi sonuçlar elde edilmiştir.

KAYNAKLAR

1. Niedermayer, E., Lopes. F. H. da Silva., “Electroencephalography, Basic Principles, Clinical Applications, and Related Fields, 3rd ed.”, **Lippincott Williams & Wilkins**, Baltimore, MD, 157-204 (2005).
2. Lopes, F. H. da Silva, “The generation of electric and magnetic signals of the brain by local networks. In: R. Greger and U. Windhorst, eds., *Comprehensive Human Physiology*.”, **Springer-Verlag**, Heidelberg, Germany, 69-154 (1996).
3. Freeman, W. J., “ The physiology of perception.”, **Scientif. Amer**, 26:78–85 (1991).
4. Brazier, M. A. B., “A History of the Electrical Activity of the Brain.” **The First Half-Century**, London: Pitman, (1961).
5. Gloor, P., “Hans Berger on the Electroencephalogram of Man.”, **Elsevier** Amsterdam, (1969).
6. Nunez, P. L., “ Electric Fields of the Brain.”, **Oxford University Press**, New York, (1981).
7. Jahnsen, H., Linas, R., “ Electrophysiological properties of guinea-pig thalamic Neurons”, **An in vitro study. J. Physiol.**, 349:205–226 (1984).
8. Jasper, H., “Report of the Committee on Methods of Clinical Examination in Electroencephalography”, **Electroenceph. Clin. Neurophysiol**, 10:370–375 (1958).
9. Pivik, R. T., Broughton, R. J., Coppola, R., Davidson, R. J., Fox, N., Nuwer, M. R., “ Committee Report: Guidelines for the recording and quantitative analysis of electroencephalographic activity in research context”, **Psychophysiology**, 30:547–558 (1993).
10. Pehlivan, F., “Biyofizik”, **Hacettepe-Taş**, Ankara , 1997.
11. Farwell, L. A., Donchin, E. “Talking off the top of your head: toward a mental prosthesis utilizing event-related brain potentials”, **Electroencephalogr. Clin. Neurophysiol**, 70(6):510-523 (1988).
12. Hoffmann, U., Garcia, G., Vesin, J.M., Diserens, K., Ebrahimi, T., “A Boosting Approach to P300 Detection with Application to Brain-Computer Interfaces”, **Proceedings of the IEEE EMBS Conference on Neural Engineering**, (2005).

13. Donchin, E., Spencer, K.M., Wijensinghe, R., “The mental prosthesis: Assessing the speed of a P300-based braincomputer interface”, *IEEE Trans. Rehab. Eng.*, 8:174-179 (2000).
14. Blankertz, B., Müller, K.R., Curio, G., Vaughan, T. M., Schalk, G., Wolpaw, J. R., Schlögl, A., Neuper, C., Pfurtscheller, G., Hinterberger, T., Schröder, M., Birbaumer, N., “The BCI Competition 2003: Progress and Perspectives in Detection and Discrimination of EEG Single Trials”, *IEEE Trans. Biomed. Eng.* 51(6), (2004).
15. Hoffman, L.D., Polich, J., “P300, handedness, and corpus callosal size: gender, modality, and task”, *Int. J. Psyc. Physio.*, 163-174 (1999).
16. Wolpaw, J. R., Birbaumer, N., McFarland, D. J., Pfurtscheller, G., Vaughan, T. M., “Brain-computer interfaces for communication and control”, *Clin. Neurophysiol.*, 113: 767–791 (2002).
17. Chang, C., Lin. C. J. LIBSVM: A Library for Support Vector Machines [Online]. Available: <http://www.csie.ntu.edu.tw/libsvm> , (2001).
18. Luck, S.J., “An Introduction to Event Related Potential Technique”, *MIT Press*, (2005).
19. Pfurtscheller, G., Neuper, C., “EEG-Based brain computer interfaces”, “Niedermeyer E. and Da Silva F. L. Electroencephalography, basic principles”, *Clinical applications and related fields*. 5th ed”, 1265-1271 (2005).
20. Sellers. E.W., ”A P300 Based Brain Computer Interface: Testing an Alternative Method of Communication”, Ph.D. Thesis, *Department of Psychology, University of South Florida* (2004).
21. Vidal, J. J., “Direct brain–computer communication”, *Ann. Rev. Biophys. Bioengng*, 157–158 (1973).
22. Vidal, J. J., “Real-time detection of brain events in EEG”, *IEEE Proc.*, 65, 633–664 (1977).
23. Chapin, J. K., Moxon, K. A., Markowitz, R. S., ve Nicolelis, M. A., “Real-time control of a robot arm using simultaneous recorded neurons in the motor cortex”, *Nature Neurosci.*, 2:664–670 (1999).
24. Lebedev, M. A., ve Nicolelis, M. A. L., “Brain–machine interfaces: past, present and future”, *Trends in Neurosci.*, 29(9) (2006).
25. Xue, Z., Li, J. ve Li, S., “Using ICA to Remove Eye Blink and Power Line Artifacts in EEG”, *Proceedings of the First International Conference on Innovative Computing, Information and Control*, 3: 107-110 (2006).

26. Nezhadarya, E. ve Shamsollahi, M. B., “EOG artifact removal from EEG using ICA and ARMAX modeling”, *ICBME 2005*, Singapore, (2005).
27. Barbati G., Porcaro C., Zappasodi F., Rossini, P.M., Tecchio F., “Optimization of an independent component analysis approach for artifact identification and removal in magnetoencephalographic signals”, *Clinical Neurophysiology*, 115, 1220-1232 (2004).
28. He, P., Wilson, G. ve Russell, C., “Removal of ocular artifacts from electroencephalogram by adaptive filtering”, *Medical and Biological Engineering and Computing*, 42: 407-412 (2004).
29. Shooshtari, P., Mohamadi, G., Ardekani, B. M. ve Shamsollahi, M. B., “Removing Ocular Artifacts from EEG Signals using Adaptive Filtering and ARMAX Modeling”, *Proceedings Of World Academy Of Science, Engineering And Technology*, 11: 277-280 (2006).
30. Kumar, P. S., Arumuganathan, R., Sivakumar, K. ve Vimal, C., “A Wavelet based Statistical Method for De-Noising of Ocular Artifacts in EEG Signals”, *IJCSNS International Journal of Computer Science and Network Security*, 8(9): 87-92 (2008).
31. Browne, M., ve Cutmore, T. R., “Lowprobability event-detection and separation via statistical wavelet thresholding: an application to psychophysiological denoising”, *Clin. Neurophysiol.*, 113(9): 1403- 1411 (2002).
32. Lagerlund, T. D., Sharbrough, F. W., ve Busacker, N. E., “Spatial filtering of multichannel electroencephalographic recordings through principal component analysis by singular value decomposition”, *J. Clin. Neurophysiol.*, 14(1): 73-82 (1997).
33. Berg, P., ve Scherg, M., “A multiple source approach to the correction of eye artifacts”, *Electroencephalogr. Clin. Neurophysiol.*, 90(3): 229-241(1994).
34. Wolpaw, J. R., McFarland, D. J., Neat, G. W. ve Forneris, C. A., “An EEG-Based Brain- Computer Interface for Cursor Control”, *Electroencephalogr. Clin. Neurophysiol.*, 78: 252–259 (1991).
35. Guger, C., Ramoser, H. ve Pfurtscheller, G., “Real-Time EEG Analysis with Subject- Specific Spatial Patterns for a Brain-Computer Interface (BCI)”, *IEEE Trans. Rehab. Eng.*,8: 447–456 (2000).
36. Chiappa, S. ve Bengio, S., “HMM and IOHMM Modeling of EEG Rhythms for Asynchronous BCI Systems”, *European Symposium on Artificial Neural Networks (ESANN)*, 199-204 (2004).

37. Millan, J. R. ve Mourino, J., “Asynchronous BCI and Local Neural Classifiers: An Over View of the Adaptive Brain Interface Project”, *IEEE Trans. Neural Syst. Rehabil. Eng.*, 11:159–61(2003).
38. Penny, W. D., Roberts, S. J., Curran, E. A. ve Stokes, M. J., “EEG-Based Communication: a Pattern Recognition Approach”, *IEEE Trans. Rehabil. Eng.*, 8: 214–5(2000).
39. Pfurtscheller, G., Neuper, C., Schlogl, A. ve Lugger, K., “Separability of EEG Signals Recorded During Right and Left Motor Imagery Using Adaptive Autoregressive Parameters”, *IEEE Trans. Rehabil. Eng.* 6: 316–25 (1998).
40. Lotte, F., Congedo, M., Lecuyer, A., Lamarche, F. ve Arnaldi, B., “A Review of Classification Algorithms for EEG-Based Brain– Computer Interfaces”, *Journal Of Neural Engineering*, R1-R13, (2007).
41. Rosa, J. L. A. ve Ebecken N. F. F., “Data Mining for Data Classification Based on the KNN Fuzzy Method Supported by Genetic Algorithm”, *Lecture Notes In Computer Science, issue: 2565*: 126-136 (2003).
42. Blankertz, B., Curio, G. ve Muller, K. R., “Classifying single trial EEG: towards brain computer interfacing”, *Adv. Neural Inf. Process. Syst. (NIPS 01)*, 14 :157–64 (2002).
43. Lan, T., Erdogmus, D., Adami, A. Mathan, S., ve Pavel M., “Channel Selection and Feature Projection for Cognitive Load Estimation Using Ambulatory EEG”, *Computational Intelligence and Neuroscience*, Article ID 74895 (2007).
44. Muller, K. R., Krauledat, M., Dornhege, G., Curio, G., ve Blankertz, B., “Machine learning techniques for brain–computer interfaces”, *Biomed. Technol.* 49, 11–22 (2004).
45. Schlogl, A., Lee, F., Bischof, H. Ve Pfurtscheller, G., “Characterization of four-class motor imagery EEG data for the BCI-competition 2005”, *J. Neural Eng.* 2: L14–22 (2005).
46. Borisoff, J. F., Mason, S. G., Bashashati, A., ve Birch, G. E., “Brain–computer interface design for asynchronous control applications: improvements to the If-asd asynchronous brain switch”, *IEEE Trans. Biomed. Eng.* 51: 985–92 (2004).
47. Vapnik, V., “Statistical Learning Theory”, *Wiley*, (1998).
48. Mizrahi, E. M., Kellaway, P., “Neonatal electrocephalography in Diagnosis and Management of Neonatal Seizures”, *Lippincott-Raven*, Philadelphia, Pa, USA, 99–143 (1998).

49. Paige, P. L., Carney, P. R., “Neurologic disorders”, Handbook of Neonatal Intensive Care, chapter 25, 644–678, *Mosby, St. Louis*, Mo, USA (2002).
50. Mizrahi, E.M., Plouin, P., Kellaway, P., “Neonatal seizures in Epilepsy: A Comprehensive Textbook, J. Engel and T. A. Pedley, Eds., vol. 1, chapter 57, 647–663, *Lippincott–Raven*, Philadelphia, Pa, USA (1997).
51. Celka, P., Colditz, P., “Nonlinear nonstationary wiener model of infant EEG seizures,” *IEEE Transactions on Biomedical Engineering*, 49(6): 556–564 (2002).
52. Boashash, B., Carson, H., Mesbah, M., “Detection of seizures in newborns using time-frequency analysis of EEG signal” , *10th IEEE Workshop on Statistical Signal and Array Processing*, 564–568 (2000).
53. Celka, P., Colditz, P., “A computer-aided detection of EEG seizures in infants: a singular-spectrum approach and performance comparison,” *IEEE Transactions on Biomedical Engineering.*, 49(5): 455–462 (2002).
54. Boashash, B., Mesbah, M., “A time-frequency approach for newborn seizure detection,” *IEEE of EMBS Magazine*, 5: 54–64 (2001).
55. Hassanpour, H., Williams, W. J., Mesbah, M., Boashash, B., “Time-frequency extraction of EEG spike events for seizure detection in neonate”, *6th International Symposium on Signal Processing and Its Application (ISSPA '01)*, 246–249 (2001).
56. Nakos, G., Joyner, D., “Linear Algebra with Applications”, Brooks/Cole Publishing Company, *Pacific Grove*, Calif, USA (1998).
57. Groutage, D., Bennink, D., “A new matrix decomposition based on optimum transformation of the singular value decomposition basis sets yields principal features of timefrequency distributions” , *10th IEEE Workshop on Statistical Signal and Array Processing*, 598–602 (2000).
58. Cohen, L., “The need for time-freacuity analysis”, in Time-Frequency Analysis, Prentice Hall Signal Processing Series, chapter 5, 70–81, *Prentice-Hall*, Englewood Cliffs, NJ, USA (1995).
59. Abeysekera, S. S., Boashash, B., “Methods of signal classification using the images produced by the Wigner-Ville distribution”, *Pattern Recognition Letters*, 11: 717– 729 (1991).
60. Boashash, B., “Part I: Introduction to the concepts of TFSAP”, in Time-Frequency Signal Analysis and Processing: A Comprehensive Reference, pp. 1–81, *Elsevier*, Oxford, UK (2003).

61. Boashash, B., Barkat, B., "Introduction to time-frequency signal analysis", in *Wavelet Transforms and Time-Frequency Signal Analysis*, L. Debnath, Ed., 321–380, **Birkhäuser**, Boston, Mass, USA, (2000).
62. Williams, W. J., "Reduced interference time-frequency distributions," in *Time-Frequency Signal Analysis and Processing: A Comprehensive Reference*, B. Boashash, Ed., chapter 5, 168–177, **Elsevier**, Oxford, UK (2003).
63. Barkat. B., Boashash, B., "A high-resolution quadratic timefrequency distribution for multicomponent signals analysis", *IEEE Trans. Signal Processing*, 10: 2232–2239 (2001).
64. Marinovic, N. M., Eichmann, G., "Feature extraction and pattern classification in space-spatial frequency domain", *SPIE Intelligent Robots and Computer Vision*, 19–25 (1985).
65. Gu, S., Ni, J., Yuan, J., "Non-stationary signal analysis and transient machining process condition monitoring," *International Journal of Machine Tools and Manufacture*, 1: 41–51 (2002).
66. Groutage, D., Bennink, D., "Feature sets for nonstationary signals derived from moments of the singular value decomposition of Cohen-Posch (positive time-frequency) distributions", *IEEE Trans. Signal Processing*, 5: 1498–1554 (2001).
67. Jenkins, W., Kenneth , Strait , Jeffrey C., Schnaufer, B.A., Andrew, W. Hull, Li, X., "Advanced Concepts in Adaptive Signal Processing", **Kluwer Academic Publishers**, USA (2005).
68. Michael J.Werter, "FSK Demodulation Using an Adaptive Recursive Digital Filtre", *IEEE Transactions on Signal Processing*, 7: 1822-1833 (1996).
69. Laguna, P., Thakor, Nitish V.,Caminal,P., Jane,R., "Low-Pass Differentiators for Biological Signals with Known Spectra: Application ECG Signal Processing", *IEEE Transactions on Biomedical Engineering*, 4: 420-425 (1990).
70. Yazgan, E., Korürek, M., "Tıp Elektroniği", **İTÜ Elektrik -Elektronik Fakültesi Ofset Baskı Atölyesi**, İstanbul (1996).
71. Widrow, b., Stearns, S.D., "Adaptive Signal Processing", Englewood Cliffs, **Prentice Hall** , New Jersey (1985).
72. Thakor, N.V., Zhu, Y. S., "Applications of Adaptive Filtering to ECG Analysis :Noise Cancellation and Arrhythmia Detection", *IEEE Transactions on Biomedical Engineering*, 8: 785-793 (1991).
73. Dölek, F., "Adaptif Filtrelerin EEG (Elektroencefalogram) İşaretlerine Uygulanması", Y.Lisans Tezi, **KSÜ Fen B.E.**, Kahramanmaraş, Haziran (1999).

74. BCI Competition IV, <http://www.bbc.de/competition/iv/>, son izleme, 18/05/2011.
75. BCI Competition IV, <http://www.bbc.de/competition/iii/>, son izleme, 18/05/2011.

ÖZGEÇMİŞ

Kişisel Bilgiler

Soyadı, adı :ALIPOUR,Akbar
Uyruğu :Iran
Doğum tarihi ve yeri :24/06/1983 Iran (Urmia)
Medeni hali :Bekar
Telefon :05072848360
e-mail :akbar.alipour@gmail.com

Eğitim

Derece	Eğitim Birimi	Mezuniyet tarihi
Lisans	Elektrik & Elektronik Mühendisliği	2007
Lise	Urmu	2002

İş Deneyimi

Yıl	Yer	Görev
2009-2010	TYI Hastanesi	Biyomedikal kalibratör

Yabancı Dil

İngilizce
Arapça

Hobiler

Spor, Müzik, Seyahat