

**KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANA BİLİM DALI

**DÜŞÜNSEL ELEKTROKORTİKOĞRAFI (EC_oG) İŞARETLERİNİN BEYİN
BİLGİSAYAR ARAYÜZÜ UYGULAMALARINDA VERİMLİ
SINIFLANDIRILMASI**

YÜKSEK LİSANS TEZİ

Elektrik-Elektronik Mühendisi Ramazan KOÇOĞLU

AĞUSTOS 2009

TRABZON

**KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANA BİLİM DALI

**DÜŞÜNSEL ELEKTROKORTİKOĞRAFI (ECoG) İŞARETLERİNİN BEYİN
BİLGİSAYAR ARAYÜZÜ UYGULAMALARINDA VERİMLİ
SINIFLANDIRILMASI**

Elektrik-Elektronik Mühendisi Ramazan KOÇOĞLU

**Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsünde
“Elektronik Yüksek Mühendisi”
Unvanı Verilmesi İçin Kabul Edilen Tezdir.**

**Tezin Enstitüye Verildiği Tarih: 14.07.2009
Tezin Savunma Tarihi : 10.08.2009**

Tez Danışmanı: Doç. Dr. Temel KAYIKÇIOĞLU

Jüri Üyesi : Doç. Dr. Ali GANGAL

Jüri Üyesi : Yrd. Doç. Dr. Cemal KÖSE

Enstitü Müdürü: Prof. Dr. Salih TERZİOĞLU

Trabzon 2009

ÖNSÖZ

Bu tez, Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim Dalı, Elektronik Mühendisliği Anabilim Dalı Yüksek Lisans Programı'nda hazırlanmıştır. Çalışmamda beyin bilgisayar arayüzü uygulamalarına yönelik farklı düşünsel ve görsel uygulamalarda kayıt edilmiş ECoG işaretlerinin çıkartılan özniteliklere dayalı sınıflandırılması konusu işlenmiştir. Tez çalışmam süresince bilimsel desteği ve değerli düşünceleriyle bana her aşamada yardımcı olan tez danışmanım Doç. Dr. Temel KAYIKÇIOĞLU'na teşekkür ederim. Ayrıca çalışmam sırasında yardımlarından dolayı Araş. Gör. Önder Aydemir'e ve Araş.Gör. Mehmet Öztürk'e teşekkür ederim.

Desteklerini benden hiçbir zaman esirgemeyen aileme teşekkür ederim. Bu tezin, bundan sonraki çalışmalara katkı sağlamasını temenni ederim.

Ramazan KOÇOĞLU
Trabzon 2009

İÇİNDEKİLER

	<u>Sayfa No</u>
ÖNSÖZ.....	II
İÇİNDEKİLER.....	III
ÖZET.....	VI
SUMMARY.....	VII
ŞEKİLLER DİZİNİ.....	VIII
TABLolar DİZİNİ.....	X
SEMBOLLER DİZİNİ.....	XI
1. GENEL BİLGİLER.....	1
1.1. Giriş.....	1
1.1.1. İnsan Beyninin Fizyolojik Yapısı.....	1
1.1.1.1. Nöronlar ve Elektriksel Aktiviteleri.....	1
1.1.1.2. Serabral Korteksin Fonksiyonel Yapısı.....	4
1.1.2. Kayıt Teknikleri.....	5
1.1.2.1. EEG.....	5
1.1.2.2. ECOG.....	6
1.1.2.2.1. ECoG Dalga Tipleri.....	8
1.1.2.2.2. ECoG Çeşitleri.....	9
1.1.2.2.3. Cerrahi Müdahalenin Yapılması.....	9
1.1.2.3. Tek Hücre Kayıtları (Mikroelektrotlar).....	10
1.1.2.4. Kayıt Tekniklerinin Karşılaştırılması.....	11
1.2. Beyin Bilgisayar Arayüzü.....	12
1.2.1. Giriş.....	12
1.2.2. ECoG ile Beyin Bilgisayar Arayüzü Arasındaki İlişki.....	13
1.2.3. Beyin Bilgisayar Arayüzü Çeşitleri.....	14
1.2.3.1. Bağımlı Beyin Bilgisayar Arayüzü.....	14
1.2.3.2. Bağımsız Beyin Bilgisayar Arayüzü.....	15
1.2.4. Beyin Bilgisayar Arayüzü Sisteminin Temel Bileşenleri.....	15
1.2.4.1. Sinyal Elde Etme.....	16

	<u>Sayfa No</u>
1.2.4.2. Öznitelik Çıkarma.....	17
1.2.4.3. Sınıflandırma Algoritması	17
1.2.4.4. Cihaz Komutları	18
1.2.4.5. İşletim Protokolü	18
1.2.5. Modern Beyin Bilgisayar Arayüzü Örnekleri	18
1.2.5.1. Görsel Olarak Tetiklenen Potansiyeller.....	19
1.2.5.2. Yavaş Kortikal Potansiyeller	19
1.2.5.3. P300 Tetiklenen Potansiyeller	19
1.2.5.4. Düşünsel Hareket.....	20
1.3. Literatür Araştırması.....	21
2. YAPILAN ÇALIŞMALAR VE BULGULAR.....	26
2.1. Tezin Özeti	26
2.2. Materyal.....	27
2.2.1. Literatürde Aynı Veri Kümesini Kullanarak Yapılan Çalışmalar	28
2.3. Yöntem	31
2.3.1. Fourier Dönüşümü.....	31
2.3.1.1. Sürekli Fourier Dönüşümü	31
2.3.1.2. Ayrık Fourier Dönüşümü.....	31
2.3.1.3. Hızlı Fourier Dönüşümü (FFT)	32
2.3.2. Dalgacık Dönüşümü	33
2.3.2.1. Sürekli Dalgacık Dönüşümü (Continuous Wavelet Transform – CWT).....	37
2.3.2.2. Ayrık Dalgacık Dönüşümü (Discrete Wavelet Transform - DWT)	38
2.3.2.3. Çoklu Çözünürlük Analizi (Multiresolution Analysis)	38
2.3.2.5. Morlet Dalgacığı.....	39
2.3.3. Filtreler	40
2.3.4. Sınıflandırma	41
2.3.4.1. Eğitimsiz (Unsupervised) Sınıflandırma	42
2.3.4.2. Eğitilmiş (Supervised) Sınıflandırma.....	42
2.3.4.3. Doğrusal Ayırma Analizi.....	42
2.3.4.4. Destek Vektör Makineleri	45

	<u>Sayfa No</u>
2.3.4.4.1. Doğrusal Olarak Ayrılabilen Veriler	46
2.3.4.4.2. Doğrusal Olarak Ayrılamayan Veriler.....	48
2.3.4.4.3. Doğrusal Olmayan Destek Vektör Makineleri	50
2.3.4.5. k- En Yakın Komşuluk Yöntemi	51
2.3.5. Bilgi Transfer Hızı.....	53
2.4. Öznitelik Çıkarma Çalışmaları ve Sınıflandırma	54
2.4.1. Görsel Olarak Kanal Seçimi	56
2.4.2. Frekans Bandı Seçimi	58
2.4.3. Dalgacık Dönüşümü İşlemi ile Öznitelik Çıkarma.....	61
2.4.4. Sınıflandırma	68
3. SONUÇLAR.....	69
4. TARTIŞMA.....	71
5. ÖNERİLER	72
6. KAYNAKLAR.....	73

ÖZGEÇMİŞ

ÖZET

Beyin Bilgisayar Arayüzü (BBA) sistemleri çevresel sinir sistemi ve kaslara bağlı olmayan bir iletişim sistemidir. BBA sistemi biyoelektrik beyin işaretlerini analiz ederek düşünsel istekleri kontrol komutlarını dönüştürmektedir. Bu sistem ALS hastaları gibi kas ve sinir sistemi rahatsızlığı bulunan kişiler için dış ortamla bir iletişim arayüzü olabilmektedir. Böylece bu tip hastaların yaşam kalitesinin artırılması sağlanmış olacaktır.

Son yıllarda BBA teknolojisi hızla gelişmektedir. BBA uygulamalarında sınıflandırma doğruluğu ve bilgi transfer hızı önemli iki konudur. BBA araştırmalarında amaç mevcut yöntemlerden daha yüksek sınıflandırma doğruluğu ve daha yüksek veri transfer hızına sahip yöntem geliştirmektir. BBA sistemlerinin giriş işaretlerinin kalitesi artırılarak sınıflandırma doğruluğu artırılabilir. Elektrokortikografi (ECoG) işaretleri korteks üzerinden kayıt edildiklerinden daha yüksek işaret gürültü oranı ve daha iyi uzamsal çözünürlük sağlayabilmektedir. Bundan dolayı ECoG işaretleri BBA sistemleri için işaret kaynağı olarak kullanılabilir.

Bu tez çalışmasında, literatürde kullanılan farklı düşünsel ve görsel uygulamalarda elde edilmiş ECoG veri kümesi üzerinde çalışılmıştır. Bu veri kümesinde farklı oturum durumlarında işaretlerin sınıflandırılmasına yönelik katkı sağlayabilecek algoritmaların oluşturulması istenmektedir. Öznitelik çıkarma işlemi BBA uygulamalarının en temel ve en zor konusunu oluşturur. Bu çalışmada farklı sınıflara ait ECoG işaretlerinden dalgacık dönüşümü katsayıları yardımıyla öznitelikler çıkartılmıştır. Bulunan özniteliklere göre K-En Yakın Komşuluk (KNN), Destek Vektör Makineleri (DVM) ve Doğrusal Ayırma Analizi (DAA) kullanılarak sınıflandırma yapılmıştır. Tüm bu çalışmalar daha yüksek sınıflandırma oranı ve yüksek beyin bilgisayar arayüzleşmesi veri hızı elde edebilmek amacı gözetilerek gerçekleştirilmiştir.

Anahtar Kelimeler: ECoG, BBA, Öznitelik Çıkarma, Sınıflandırma

SUMMARY

Efficient Classification Of Imagery Electroencephalography (EEG) Signals In Brain Computer Interface Applications

A brain computer interface (BCI) is a communication system that does not depend on the normal output pathways consisting of periphery nerves and muscles. BCI transforms mental intentions into control commands by analyzing the biomedical brain activity. The technique can be an interface to patients who totally losing volitional motor ability like amyotrophic lateral sclerosis (ALS). Thus, life quality of these type patients will be increased.

In the past decade BCI technology has developed rapidly. In BCI applications classification accuracy and information transfer rate are two important issues. The goal in area of BCI research is to develop a method which has higher classification rate and brain computer interfacing data rate than existing methods. One method to boost classification accuracy is to improve the quality of input signal of a BCI system. Electroencephalographic (EEG) recordings, derived from surface of the cortex, have the advantages of higher signal-to-noise ratio and better spatial resolution, and thus may be used as a feasible alternative of BCI signal source.

In this thesis, it was studied on EEG dataset which was obtained under different mental and visual tasks used in literature. In this data set, creating algorithms for contributing the classification of signals in different session situations is required. Feature extraction process is the main and also most difficult issue in BCI applications. In this work features are extracted from EEG signals which have two different classes by means of wavelet transform. According to discovered features classification was done by using k-nearest neighbor (KNN), support vector machines (SVM) and linear discriminant analyses (LDA) classifier. All these studies actualized by considering the goal of to obtain higher classification rate and high brain computer interfacing data rate.

Key Words: EEG, BCI, Feature Extraction, Classification

ŞEKİLLER DİZİNİ

	<u>Sayfa No</u>
Şekil 1.1.	Nöron yapısı..... 2
Şekil 1.2.	Aksiyon potansiyeli 3
Şekil 1.3.	Korteks alanları..... 4
Şekil 1.4.	İlk EEG işaretinin grafiği..... 6
Şekil 1.5.	Şekil 1.5. Üç saniye süreyle kayıt edilen bir ECoG işareti..... 7
Şekil 1.6.	Diğer görüntüleme tekniklerinden faydalanılarak ilgili bölgenin belirlenmesi..... 9
Şekil 1.7.	Serebral korteksin açılması ve subdural ECoG için elektrot yerleştirilmesi..... 10
Şekil 1.8.	Farklı beyin görüntüleme tekniklerinin karşılaştırılması. Zamansal çözünürlük x- ekseninde logaritmik olarak gösterilmekte, müdahale derecesi y ekseninde ve renkler uzamsal çözünürlüğü göstermektedir 11
Şekil 1.9.	Elektriksel sinyalin elektrota ulaşması..... 14
Şekil 1.10.	BBA sisteminin temel bileşenleri 16
Şekil 2.1.	Denemeler için bilgisayar ekranında gösterilen işaretler..... 27
Şekil 2.2.	Sinyal analiz yöntemleri arasındaki ilişki 35
Şekil 2.3.	Sonsuz sayıda olabilecek dalgacıklardan bazıları ,(a) Meyer dalgacığı ve (b)Meksika şapkası dalgacığı..... 36
Şekil 2.4.	Morlet dalgacığı..... 40
Şekil 2.5.	Bazı sayısal filtre karakteristikleri 41
Şekil 2.6.	Destek Vektör Makineleri giriş uzayını yüksek boyutlu bir öznitelik uzayına eşleştirmektedir..... 46
Şekil 2.7.	Kuramsal hiper düzlemler ve en büyük marjinin gösterimi..... 47
Şekil 2.8.	Öznitelik uzayında doğrusal ayırma 48
Şekil 2.9.	DVM sınıflandırma modelleri (a) doğrusal (dot) kernel,Eq (60);(b) 2.dereceden polinomial kernel,Eq(61)..... 50
Şekil 2.10.	Eğitim ve Test veri kümesine ait tüm denemelerinin ortalama genlikik Spektrumları (38. kanal). 54
Şekil 2.11.	ECoG verilerinin sınıflandırılmasında kullanılan akış diyagramı 55
Şekil 2.12.	Eğitim verilerine ait bazı kanalların DDH ve DPH ait tüm denemelerin zaman domeni ortalamaları (a) 1. Kanal, (b) 2. Kanal, (c) 12. Kanal, (d) 38. Kanal 57
Şekil 2.13.	Eğitim kümesine ait bazı kanalların genlik spektrumları 59

Şekil 2.14.	Kanal 38 için DPH ait bir denemenin Butterworth filtre ile 7-13 Hz frekans bölgesinin filtrelenmesi.....	60
Şekil 2.15.	Kanal 38 için DDH ait bir denemenin Butterworth filtre ile 7-13 Hz frekans bölgesinin filtrelenmesi.....	60
Şekil 2.16.	Bir denemeye ait işaret ve bunun Morlet dalgacığı ile dalgacık dönüşümü işleminin yapılması	62
Şekil 2.17.	DDH ait bir ECoG işareti ve bu işaretin dalgacık katsayı grafikleri	63
Şekil 2.18.	DPH ait bir ECoG işareti ve bu işaretin dalgacık katsayı grafikleri	63
Şekil 2.19.	Kanal 12 için ,(a) DDH denemelerinin ortalaması,(b) DPH denemelerinin ortalamaları	64
Şekil 2.20.	Kanal 38 için,(a) DDH denemelerinin ortalaması,(b) DPH denemelerinin ortalamaları	64
Şekil 2.21.	Kanal 38'e ait (a) eğitim ,(b) test verileri	66
Şekil 2.22.	(a)Eğitim verilerine ait kanal 12 ve kanal 38 kullanılarak oluşturulan öznitelik uzayı, (b) test verilerine ait kanal 12 ve kanal 38 kullanılarak oluşturulan öznitelik uzayı	67
Şekil 2.23.	DVM sınıflandırıcısı ile eğitim ve test verilerinin sınıflandırma sonuçları.Kırmızı renkli + işareti DPH ait eğitim verilerini ve mor + işareti DPH ait test verilerini göstermektedir. Buna karşın yeşil * işareti DDH ait eğitim verilerini ve mavi * işareti DDH ait test verilerini göstermektedir ...	70
Şekil 2.24.	(a) deneme uzunluğu ile sınıflandırma doğruluğu arasındaki ilişki,(b) deneme uzunluğu ile bit transfer hız (bit/dk) arasındaki ilişki	71

TABLULAR DİZİNİ

Sayfa No

Tablo 1.	Farklı BBA çeşitleri için eğitim süreleri.....	21
Tablo 2.	BCI Competition III Data Set I yarışmasına katılan çalışma gruplarının sonuçları ..	30
Tablo 3.	ECoG verilerine yönelik dalgacık katsayılarının ortalamaları kullanılarak yapılan sınıflandırma sonuçları ..	70
Tablo 4.	Farklı deneme uzunlukları için sınıflandırma doğrulukları ve bilgi transfer hızı ..	71

SEMBOLLER DİZİNİ

ALS	:	Amiyotrofik Lateral Sklerozis
AP	:	Aksiyon Potansiyeli
AR	:	Autoregresive
BBA	:	Beyin Bilgisayar Arayüzü
BCI	:	Brain Computer İnterface
BİUP	:	Beyinsapı İşitsel Uyarılmış Potansiyeller
C	:	Kovaryans Matris
CSP	:	Common Spatial Pattern
DAA	:	Doğrusal Ayırma Analizi
DD	:	Dalgacık Dönüşümü
DDH	:	Düşünsel Dil Hareketi
Det	:	Determinant
DMR	:	Duyu Motor Ritimleri
DPH	:	Düşünsel Parmak Hareketi
DV	:	Destek Vektörü
DVM	:	Destek Vektör Makineleri
ECoG	:	Elektrokortikografi
EEG	:	Elektroensefalogram
ERD	:	Olay İlişkili Desenkronizasyon
FD	:	Fourier Dönüşümü
fMRI	:	Functional Magnetic Resonance İmaging
GA	:	Genetik Algoritma
GTP	:	Görsel Tetiklenen Potansiyel
GUP	:	Görsel Uyarılmış Potansiyeller
Hz	:	Hertz
ITR	:	Information Transfer Rate
I	:	Birim matris
ICA	:	Independent Component Analysis
KNN	:	k-en yakın komşuluk
KZFD	:	Kısa Zamanlı Fourier Dönüşümü

LDA	:	Linear Discriminant Analysis
LFP	:	Local Field Potential
MEG	:	Magnetoencefalography
MLP	:	Multi-layer Perceptron Neural Network
MRP	:	Movement Related Potentials
P300	:	Beynin yaklaşık 300 ms sonra ürettiği pozitif potansiyeldir
PCA	:	Principal Component Analysis
PFD	:	Pencerelenmiş Fourier Dönüşümü
RP	:	Resting Potential
SCP	:	Slow Cortical Potentials
SCR	:	Single Cell Recordings
SDD	:	Sürekli Dalgacık Dönüşümü
Sign	:	Karar Fonksiyonu
SSVEP:		Steady State Visual Evoked Potentials
SUP	:	Somatosensoryel Uyarılmış Potansiyeller
SVM	:	Support Vector Machines
YKP	:	Yavaş Kortikal Potansiyel
YSA	:	Yapay Sinir Ağları
Σ	:	Köşegen matris
ε	:	Hata oranı
Φ	:	Özvektör
Λ	:	Özdeğer
σ	:	Sigma
μ	:	Mü ritmi
α	:	Alfa dalgası
β	:	Beta dalgası
θ	:	Teta dalgası
δ	:	Delta dalgası

1. GENEL BİLGİLER

1.1. Giriş

1.1.1. İnsan Beyninin Fizyolojik Yapısı

Bu bölüm beyin işaretlerinin oluşum yapısını açıklamaktadır. İlk olarak nöronlar ve onların elektriksel aktiviteleri daha sonra kortikal düzeyde daha büyük nöron gruplarının açıklaması yapılacaktır.

1.1.1.1. Nöronlar ve Elektriksel Aktiviteleri

Nöron ya da sinir hücresi sinir sisteminin temel fonksiyonel birimidir. Basit ya da karmaşık her türlü davranış, beynin değişik bölgelerinde yer alan bir grup nöronun etkinliği ile gerçekleşir. Beynin çalışabilmesi için nöronlar arasında iletişim zorunludur. Nöronlar sinirsel uyarıları elektriksel ve kimyasal yolla iletir.

Bir nöron soma, dendrid ve akson denilen üç ana kısımdan oluşur. Soma, çekirdek (nukleus) ve çekirdekçisi (nukleolus) ihtiva eden esas hücre kısmıdır. Dendrid, görevi diğer nöronlardan gelen uyarıları alıp, nöron gövdesine iletmektir. Akson, sinir hücresinden gelen işaretleri çevreye taşımakla görevlidir.


Nöronlar işlevlerine göre 3 sınıfta incelenirler.

1-Duyusal nöronlar; duyuların alınmasını sağlar.

2-Motor nöronlar; doku, organ ya da organ sistemlerinin işleyişinde değişiklik oluştururlar.

3-İnternöronlar; duyu ve motor nöronlar arasında yer alırlar.

Nöronların birbirleriyle bağlandığı alana sinaps adı verilmektedir. Bir nöronun aksonu birkaç ya da binlerce sinapsta sona ermektedir. Bir insan beyinde yaklaşık 10^{10} nöron ve buna bağlı olarak yaklaşık 10^{14} sinaptik birleşme noktası bulunmaktadır. Şekil 1.1' de bir nöronun yapısı gösterilmektedir.



Şekil 1.1. Nöron yapısı

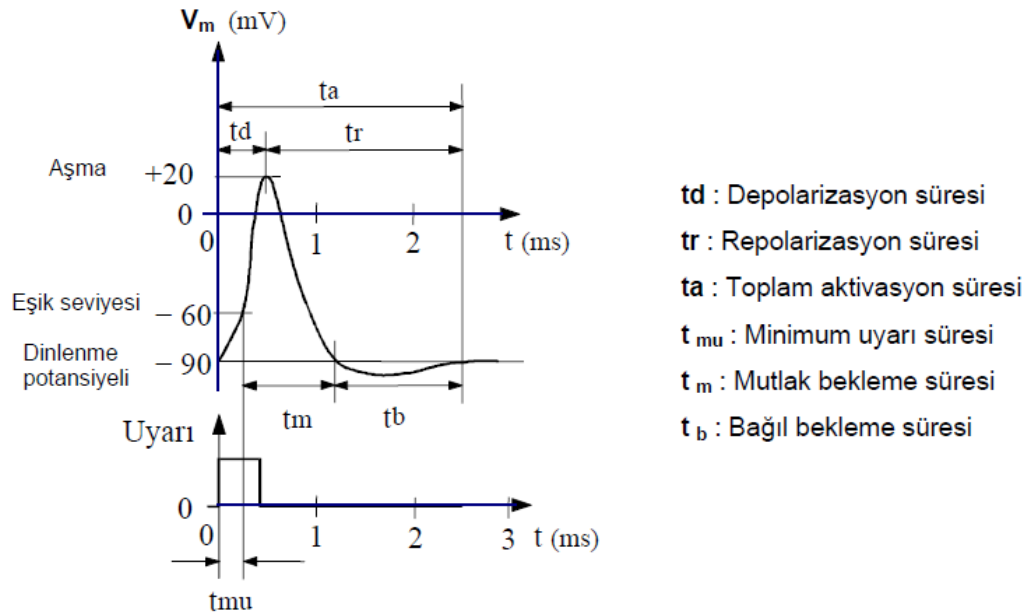
Yoğun nöronlar grubuna nükleli denmektedir. Beyin herhangi bir işlev yaparken o görevle alakalı nükleli aktive olur, bilgiyi işler ve gönderir [1]. Bu aktivite durağan olmayan işaret olarak gözlenir ve bu birçok nöronun, aynı anda gösterdiği potansiyellere beyin biyoelektrik işaretleri denir. Biyolojik işaretlerin temelini, hücrelerdeki elektrokimyasal olayların sonucunda oluşan aksiyon potansiyeli oluşturur. Bu potansiyel, gerçekte, hücre zarının iç ve dış taraflarındaki potansiyel farkıdır. Hücrelerde elektriksel işaretler, hücrenin uyarılabilme özelliği nedeniyle oluşur. Hücre membranları, eşik seviyesi olarak isimlendirilen bir değerin üzerindeki bir işaret ile uyarılacak olurlarsa bu uyarma bütün hücreye yayılır. Uyarma şekli elektriksel, kimyasal, optik, termal veya mekanik olabilir. Sinir ve kas hücreleri gibi hücreler ise uyarılabilme özelliğine sahiptir. Bu hücreler membranları boyunca darbe şeklinde değişen elektrokimyasal değişimleri iletebilmektedir. Vücut öz sıvısındaki en önemli iyonlar; sodyum (Na^+), potasyum (K^+) ve klor (Cl^-) iyonlarıdır. Hücrenin elektriksel aktivitesi açısından bakıldığında hücrenin dışında ve içinde yer alan sıvı bileşimleri arasında temel fark; hücre dışında Na^+ ve Cl^- iyonları sayısının hücre içine nazaran fazla, K^+ iyonları sayısının ise az olmasıdır. Uyarılabilen hücrelerin membranları K^+ ve Cl^- iyonlarının hücre içine geçmesine izin vermesine rağmen Na^+ iyonlarının geçişine engel olur.

Hücre uyarılmadığında sükûnette olup sükûnet potansiyeli -90 mV kadardır. Bu potansiyeli dengelemek üzere, hücre zarının da kendilerini kolay geçirir olması nedeniyle, K^+ iyonları hücre içini doldurmuştur; oysa hücre zarının Na^+ iyonlarına olan geçirgenliği yüksek olmadığından Na^+ iyonları hücre içine girememektedir. Sükûnette, hücre dışında, içine göre, Na^+ ve Cl^- iyon konsantrasyonu daha fazladır; K^+ iyonu ise hücre içinde daha konsantredir. Hücre uyarıldığında zarının Na^+ iyonlarına olan geçirgenliği artar; hücre

içine Na^+ iyonları hücumu olur ve hücre içi potansiyeli +20 mV değerine kadar yükselir. Bu olaya depolarizasyon denir.

Gerilim değerinden etkilenen hücre zarının geçirgenliği tekrar sükûnetteki durumuna döner. Bu durumda, aktif transport etkili olur. Enerji harcayarak çalışan Na-K aktif pompaları Na^+ iyonlarını hücre dışına (K^+ iyonlarını da hücre içine) pompalamak suretiyle sükuneteki konsantrasyon dengelerini kurmaya ve bu dengeleri korumaya çalışır. Bu olaya da repolarizasyon denir.


Repolarizasyonda, zar potansiyeli eski seviyesine gelir. Bu değişime, aksiyon potansiyeli adı verilir. Aksiyon potansiyellerinin değişimi çeşitli hücrelerde farklılıklar gösterir [2]. Hücre uyarıldığında, zar potansiyeli (hücre dışı referans olmak üzere) pozitif doğru artar. Belli bir eşik gerilimini (-60 mV) geçer geçmez, uyarı kesilse bile zar potansiyeli +20 mV repolarizasyon değerine kadar yükselmeye devam eder. Eşik değerini geçemeyen zar potansiyelleri uyarı kesildiğinde denge değerine dönerler. Demek ki, hücre, zar potansiyelini eşik değerinin üzerine çıkaran uyarılar için uyarılmış olmakta; yoksa uyarılmamış kalmaktadır. Buna ‘ya hep ya hiç yasası’ denir. Hücre uyarıldıktan sonra, tekrar uyarılabilmesi için bir süre gerekir. Buna, bekleme süresi denir. Şekil 1.2.’ de aksiyon potansiyeline ait grafik gösterilmektedir.



Şekil 1.2. Aksiyon potansiyeli

1.1.1.2. Serabral Korteksin Fonksiyonel Yapısı

Serebral korteks, beynin bütün yüzeyini örten 2-5 mm kalınlıkta, yaklaşık 2 mm² lik yüzey alanına sahip koyu renkli örtüdür. Beyin korteksi birkaç nörondan birkaç milyon nörona kadar değişen nöron gruplarından oluşmaktadır. Aynı kümeye ait olan nöronlar benzer veya eş-zamanlı elektriksel aktivite göstermektedir. Serebral korteksin fonksiyonu motor ve duyu fonksiyonlardaki özelleşmiş alanlara ilave olarak dil, görsel, duyu algılama, hafıza, şuur, planlama, muhakeme ve bunun gibi çeşitli diğer kavramsal görevlerdir [3].



Şekil 1.3. Korteks alanları


Şekil 1.3. incelendiğinde görme merkezinin occipital kortekste, işitme alanlarının temporal kortekste, dokunma, basınç, ağrı, sıcak, soğuk, tad ve proprioseptif duyu alanının da, iskelet kaslarının motor aktivitesi ile ilgili alanın motor alan da yerleşmiş olduğu görülmektedir. Beyin iki yarım küreden oluşmaktadır. Bir hemisferdeki (yarım küre) somatik duyu alanı ile primer motor alan vücudun zıt tarafı ile bağlantıdadır. Örneğin: Sol bacağın ağrı duyusu, sağ hemisferin somatik duyu alanında algılanırken, sol bacak kaslarına kasılma emri, sağ hemisferin primer motor alanından çıkmaktadır [4].

1.1.2. Kayıt Teknikleri

Bir nöron uyarıldığı zaman bir magnetik alan oluşmaktadır. Normalde elektrik alanı olarak ortaya çıkmaktadır. Tek bir nöronun alanı çok zayıf olduğundan dolayı ancak hücrenin içerisine giren sensörler vasıtasıyla tespit edilebilirler. Harici kayıt teknikleri tek bir nöronun elektriksel faaliyetini algılayamazlar, bu teknikler büyük nöron gruplarının elektriksel aktivitelerini ölçebilirler. Kafatasının içerisine yerleştirilen elektrokortikografi (ECoG) sensörleri ya da kafatasının dışına yerleştirilen elektroensefalografi (EEG) ve magnetoensefalografi (MEG) sensörleri vasıtasıyla sinir dokusunun elektrik ve magnetik alanları kayıt edebilirler [5]. Beyine ait bilgilerin elde edilmesi fonksiyonel manyetik rezonans görüntülemesi (fMRI), pozitron emisyon tomografisi (PET), magnetoensefalografi (MEG), elektroensefalografi (EEG) ve tekil nöron kayıtları gibi pek çok yöntemle mümkündür. Elimizdeki uygulanabilir fonksiyonel kayıt teknikleri zamansal ve uzamsal çözünürlük bakımından çeşitlilik gösterir. Beyin işaretleri klinik nöropsikoloji, farmakoloji (ilaç bilimi) ve diğer ilgili bilim dalları için elzem hale gelmiştir. Hastanın durumuna göre merkezi sinir sistemi aktivitelerinin değerlendirilmesi için farklı teknikler uygulanır. Bu tekniklerden kısaca bahsedelim.

1.1.2.1. EEG

Bilim adamları beyin hakkında detaylı bilgi edinebilmek amacıyla, geçmişten bugüne, çok ilkel yöntemlerden gelişmiş yöntemlere kadar pek çok metot geliştirmişlerdir. Beyin dalgalarının elektro-kimyasal olaylarla açıklanabilir ve beynin elektriksel potansiyelinin ölçülüp işlenebilir olması da bu yöntemlerle mümkün olmaktadır. İlk defa insan beyninin elektriksel aktivitesinin varlığı Jena’ da 1924 yılında Alman psikiyatristi Hans Berger tarafından ortaya koyuldu. O buna elektroensefologram (EEG) ismini verdi. EEG işaretlerinin varlığının ortaya çıkmasından sonra EEG işaretlerinin uyku ve uyanıklılık gibi canlıların fiziksel durumlarını yansıttığı anlaşıldı. Hans Berger tarafından ilk kaydedilen EEG örneği Şekil 1.4.’ de gösterilmiştir.



Şekil 1.4. İlk EEG işaretinin grafiği

EEG işaretleri, beyin yüzeyinden elektrotlarla algılanan harici bir yöntemdir. Bundan dolayı klinik uygulamalarda yaygın olarak kullanılmaktadır. EEG işaretleri düşük genlikli biyoelektrik işaretler olduğundan bilgilere ulaşılmasını zorlaştırmaktadır. Dolayısıyla iyi bir EEG çekimi yapmak için, vücuttan veya dışarıdan kaynaklanan, gürültü veya istenmedik etkileri azaltacak önlemler alınmalıdır. EEG işaretleri, ölçüm yaparken oda içerisindeki ışığın açık veya kapalı olması ve çevrede elektromanyetik dalga yayabilecek cihazların bulunması gibi dış etkenlerden ve yine ölçüm yaparken kişinin gözünü kırpması, kalp atışları, kolunu sağa-sola hareket ettirmesi gibi fiziksel aktivitelerden etkilenir. EEG işareti geniş bir frekans bandına sahip olmakla birlikte, klinik ve fizyolojik uygulamalarda 0-40 Hz frekans aralığı kullanılmaktadır. Birçok analiz tekniği yaklaşık 40 Hz üzeri frekansları algılayamamaktadır. Çünkü işaret gürültü oranı yüksek frekanslar için hızlı bir şekilde düşmektedir. EEG gibi harici kayıt teknikleri ile iyi bir işaret-gürültü oranı gerçekleştirmek; yalnızca sensörlerin işaret kaynağına yakın yerleştirilmesi ve işaret kaynağının güçlü olması ile gerçekleştirilebilir.


1.1.2.2. ECoG

ECoG yeni bir metoddur [6,7]. Kafatasının altına yerleştirilen elektrotlarla serebral korteksteki elektriksel aktivitenin ölçülmesinde kullanılan özel bir yöntemdir. EEG kayıt yöntemiyle temelde benzerlik göstermektedir. Tıpkı EEG gibi elektrotlar vasıtasıyla lokal elektrik alanındaki değişimleri algılar. EEG ve ECoG elektrotları sinirsel dokunun üzerindeki aksiyon potansiyelleri tarafından harekete geçirilen iyonların akışından kaynaklanan çok fazla sayıdaki elektrik alan salınımlarının toplamlarını algılamaktadır. ECoG elektrotlarının yerleştirilmesi cerrahi müdahale gerektirdiği için dâhili bir kayıt yöntemidir. Bu işlemin yapılması için kişinin ileri derecede epilepsi hastası olması ve hastanın epileptik yerinin tespitinde MRI ve EEG gibi yöntemlerinin sonuç vermemesi durumunda uygulanır. Böylece hastanın epileptik alanının tespit edilmesi sağlanır. Korteks

herhangi bir zarar görmediği için cerrahi müdahalenin derecesi beyin içine yerleştirilen mikroelektrotlara göre çok daha azdır [8,9]. Yine de ECoG için gerekli olan elektrot yerleştirme işlemi enfeksiyon riski taşıdığı için daha profesyonel bir gözetim altında yapılması gerekir. Bundan dolayı belli başlı laboratuvarlarda bu cerrahi müdahale yapılmaktadır.

Çok sık nöbet geçiren ve epilepsi tedavisine cevap vermeyen hastaların tedavisi için uygulanan yollardan birisi de fokus diye adlandırılan ve epilepsi nöbetlerinin kaynağı olan dokunun cerrahi müdahale ile yok edilmesidir. Bu tedavi genellikle epilepsi nöbetlerinin yoğunluğunu ve sayısını azaltır. Fokusu yok etme işlemi, beyin elektriksel aktivitelerinin görüntülenmesiyle ve fokusun yerinin tam olarak saptanmasıyla başlar. Bu amaçla hastalara ECoG elektrot gridleri yerleştirilir. Bazı durumlarda bu subdural elektrotlar 4 yıl gibi bir süre vücut içerisinde durmaktadır.

Kafatası ve zar altına yerleştirilen elektrotlar ya paslanmaz çelikten ya da platinden imal edildikleri için sinyal kaynakları ile elektrotlar arasındaki doku daha az nemlenir. ECoG için standart bir elektrot yerleştirme sistemi henüz bulunmamaktadır. Elektrotlar genelde bir boyutlu levha şeklinde (8 elektrot) veya 2 boyutlu grid (8×8 elektrot) şeklinde yerleştirilmektedir. Deneyler sırasında elektriksel ve magnetik değişimler her elektrotta kayıt edilmektedir. Örnekleme frekansı duruma göre seçilmektedir ve genellikle 1000 Hz olarak seçilmektedir.



Şekil 1.5. Üç saniye süreyle kayıt edilen bir ECoG işareti

Şekil 1.5.' de yüksek çözünürlüğe sahip bir kanaldan alınmış ECoG kayıtlarını göstermektedir. ECoG işaretlerinin genlikleri $-100 \mu\text{V}$ ile $+100 \mu\text{V}$ arasında değişir. Bu ölçümler EEG ile ölçülen değerlerden 5-10 kat daha fazladır.

1.1.2.2.1. ECoG Dalga Tipleri

ECoG işaretleri frekans domeninde analiz edilirler. ECoG işaretleri yorumlanırken çoğu zaman dalgaların frekansına, kimi zaman da dalga tipine bakılarak değerlendirilir. ECoG verilerinin özellikleri (bazen buna kortikal EEG de denir) genellikle EEG (Scalp EEG de denir) ile benzer olsa da ECoG verileri daha yüksek frekansları içermektedir. Bu frekans aralığı çeşitli frekans bandlarına ayrılmıştır. Bunlar:

Delta (δ) Dalgaları: Delta dalgaları değişken bir genliğe ve 0,5-4 Hz arasındaki frekansa sahiptirler. Bu dalgalar derin uykuyla ilişkilendirilmiştir, uyanık durumda gözlenmesi halinde beyinde fiziksel kusurlar olduğu düşünülür. Fakat bir yaşına kadar olan yeni doğmuş bebeklerde 3. ve 4. derece uykuda görülmesi oldukça normaldir.

Teta (θ) Dalgaları: Teta dalgalarının frekansı 4- 7 Hz arasındadır ve $20 \mu\text{V}$ ' un üzerindeki genliğe sahiptirler. Teta dalgaları çoğunlukla hüsrana ve hayal kırıklıkları gibi duygusal stres sonucunda ortaya çıkar. Uyanık durumdaki yetişkinlerde görülmesi normal değildir fakat 13 yaşına kadar uyku esnasında çocuklarda gözlenmesi doğaldır. Bilinç dışı, yoga ve derin düşünme halleriyle ilişkilendirilebilir. Teta dalgalarının gözlendiği en geniş tepe noktası 7 Hz civarındadır.

Alfa (α) Dalgaları: Alfa dalgaları frekansları 7,5-13 Hz arasında ve $30-50 \mu\text{V}$ genlik değerli dalgalarlardır. Gözler kapalı ve vücut rahat pozisyondayken ortaya çıkar, gözlerin açılması veya herhangi bir tetikleyici unsurla (düşünme, hesap yapma) yok olur. Normal rahat yetişkinlerde görülen esas ritimdir.

Mü (μ) Dalgaları: Mü dalgaları (μ) kendiliğinden olan ve motor aktivitelerle ilişkilendirilen 7,5-13 Hz frekanslı EEG ve ECoG dalgalarıdır. Motor korteks üzerinden kaydedilirler. Hareketle veya hareket etmeye çalışınca azalır. Mü dalgaları ve alfa dalgaları aynı frekans bandına sahiptirler fakat alfa dalgaları oksipital korteksten gözlenir.

Beta (β) Dalgaları: Beta aktivitesi “hızlı” aktivite olarak adlandırılır. 13-30 Hz arası frekanslara ve $5-30 \mu\text{V}$ arası bir genliğe sahiptir. Beta dalgaları özellikle aktif düşünürken,

dikkat kesilmişken, dış dünyadaki olaylara kafa yorarken veya somut problemler çözerken ortaya çıkar.


Gama (λ) Dalgaları: Gama dalgaları 30 Hz ve üzerindeki frekanslarda gözlenir. Bu bandın bilinç mekanizmasını yansıttığı düşünülmektedir. EEG yöntemiyle yapılan ölçümlerde ihmal edilen yüksek frekans işaretleri denilen gama dalgaları oldukça fazla bilgi içermektedir [10].

1.1.2.2.2. ECoG Çeşitleri

1. Intra Operative: Epileptojenik alanla sağlıklı kısmı ayırt etmek için uygulanan cerrahi yöntemdir.
2. Extra Operative: Epileptojenik alanın araştırılması için dışarıdan cerrahi müdahalenin yapılması [11].
3. Epidural: Elektrotlar dura materin üzerine yerleştirilir.
4. Subdural: Elektrotlar dura materin altına yerleştirilir.


1.1.2.2.3. Cerrahi Müdahalenin Yapılması

Cerrahi müdahale diğer görüntüleme tekniklerinden faydalanılarak ilgilenilen bölgenin belirlenmesi ve kranyotomi (kafatasının açılması için yapılan cerrahi müdahale) gerçekleştirme işlemleri ile başlar. Şekil 1.6.' da gösterilen MRI görüntüsü ve EEG ile belirlenen bölgeye elektrot gridleri yerleştirilir.



Şekil 1.6. Diğer görüntüleme tekniklerinden faydalanılarak ilgili bölgenin belirlenmesi

Cerrahi müdahale sırasında lokal anastesi uygulanır ve iyi bir sonuç için hastanın bilinci yerinde olması sağlanır.



Şekil 1.7. Serebral korteksin açılması ve subdural ECoG için elektrot yerleştirilmesi

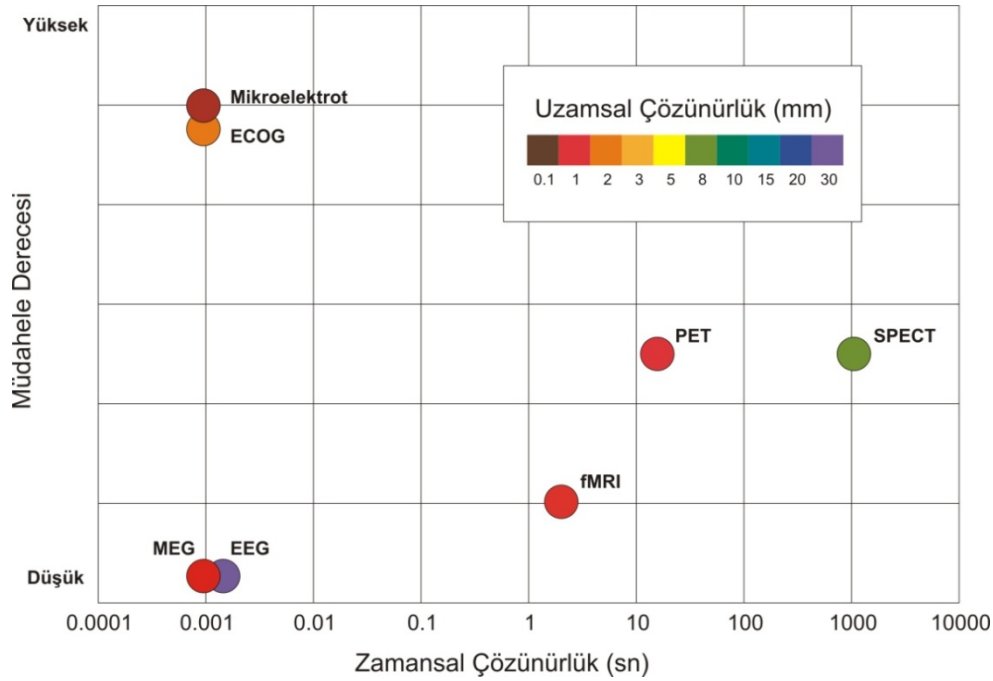
Elektrot gridleri esnek ve jel bir tabakadır. Yaklaşık 0,4 mm çapında disk şeklindeki elektrotlar 2 boyutlu dize veya düzlemsel bir şekilde jel tabakasında yerleştirilir. 2 elektrot merkezi arasında mesafe 10 mm dir. Tipik grid yerleştirme şekilleri 8x8 dir. Elektrot ile korteks dokusu arasındaki mesafe 1 mm kadardır.

1.1.2.3. Tek Hücre Kayıtları (Mikroelektrotlar)

Tek bir sinir hücrelerinin aksiyon potansiyellerini kayıt etmek için kullanılan bir yöntemdir. Kullanılan elektrotlar 3-10 μ m boyutlarında olduğundan mikroelektrot yöntemi de denmektedir. Tek hücre kayıtları olağanüstü uzamsal ve zamansal çözünürlük vermesine rağmen elektrotlar beyin içerisine yerleştirildiği için dokulara zarar vermektedir. Bu nedenlerden dolayı insanlarda klinik uygulamaları yasaklanmıştır. Uygulamalar hayvanlar üzerinde olmaktadır. Elektrotların canlı bir hayvanın beyni içerisine yerleştirilmesi ile kayıtlar gerçekleştirilir [12,13].

1.1.2.4. Kayıt Tekniklerinin Karşılaştırılması

Kayıt tekniklerini karşılaştırırken cerrahi müdahalenin derecesi, sistemin taşınabilirliği, işaret gürültü oranı ve uzamsal ve zamansal çözünürlük gibi parametreler göz önüne alınmaktadır.



Şekil 1.8. Farklı beyin görüntüleme tekniklerinin karşılaştırılması. Zamansal çözünürlük x- ekseninde logaritmik olarak gösterilmekte, müdahale derecesi y ekseninde ve renkler uzamsal çözünürlüğü göstermektedir

Müdahale derecesine göre en acısız yöntem EEG' dir. Fakat EEG'nin dezavantajları sınırlı bir işaret gürültü oranına sahip olmasından dolayı yavaş bir iletişim hızına sahiptir. Dakikada 1 ila 5 harf arasında. Diğer nedeni uzun eğitim süresidir. Şekil 1.8.' de görüldüğü üzere EEG işaretleri iyi bir uzamsal çözünürlüğe sahip değildir. EEG'deki işaret gürültü oranını arttırmak için uzamsal veya spektral filtreleme yapılır.

Tek hücre kayıtları olağanüstü uzamsal ve zamansal çözünürlük vermesine rağmen elektrotlar beynin içerisine yerleştirildiği için dokulara zarar vermektedir. Bundan dolayı insanlarda bu yöntem kullanılmamaktadır.

ECoG, subdural elektrot gridleri ile kayıt yapıldığı için elektrotların korteks içerisine girmesi gerekmiyor. Böylece daha az klinik risk içermektedir. ECoG yöntemi ile tek hücre

kayıtlarına bir alternatif sağlanır. ECOG tek hücre kaydından daha uzun süreli kararlılık sağlamaktadır. ECoG, EEG'den daha iyi bir uzamsal çözünürlüğe sahiptir (mm karşı cm) [14] ve daha yüksek genliğe (50-100 μ V karşı 10-20 μ V) ve EMG gibi bozucu etkenlere karşı daha az hassastır [15].

1.2. Beyin Bilgisayar Arayüzü

1.2.1. Giriş

Dünya genelinde milyonlarca insan nöromüsküler (sinir ve kasa ait) rahatsızlıktan ızdırap duymaktadır. Bu rahatsızlıklar ALS, Serebral Palsi (çocuklarda bedensel sakatlık yaratan en yaygın hastalık) ve omurilik hasarıdır. Bu hastaların çoğu göz hareketleri ve nefes alıp verme hariç tüm istemli kas hareketlerini kaybetmektedirler ve çevreyle hiçbir şekilde iletişimde bulunamamaktadırlar. Alışlagelmiş yardımcı aletler bir kısım istemli kas hareketi gerektirmektedir. Ama yukarıda sözünü ettiğimiz hastalar için bunlar uygun değildir. EEG ve ECoG gibi beyin işaretleri iletişim ve kontrol için alternatif bir yol sağlayabilir. Bu hastalar beyin bilgisayar arayüzleri ile beyin işaretlerini kullanarak doğrudan bir aygıtı kontrol edebilirler. Beyin Bilgisayar Arayüzü (BBA) bir tür iletişim sistemidir. Bu iletişim sisteminde, bireyin dış dünyaya gönderdiği iletiler ve komutlar beynin normal çıktı yolları olan çevre sinirlerden ve kaslardan geçmez [16]. "Beyin bilgisayar arayüzü" terimini ilk kullanmış olanlardan biri Jacques J. Vidal' dir [17,18]. Vidal, 1973 yılındaki çalışmasında EEG sinyallerini algılayıp, çözümleyip belli örüntüleri bulup bunları önceden tanımlanmış hareket komutları olarak yorumlayan karmaşık bir bilgisayar sistemi geliştirmiştir. "Bağımlı BBA" olarak tanımlanan bu sistem ki bu sistem aşağıda daha detaylı incelenecektir, kullanıcının göz hareketlerini kontrol etme kabiliyetine dayanıyordu. Özetle BBA' nı mümkün kılan, beynin ürettiği sinyalleri kaydedip bunları örüntü çözümlenme ve sınıflandırmasına tabi tutabilme yeteneğidir denebilir. BBA araştırmalarının başlangıcında ki ana katkı fizyolojistler olmasına karşın bu araştırma alanı elektrik mühendisleri, fizyolojistler ve diğer bilimler arasında önemli bir konudur.

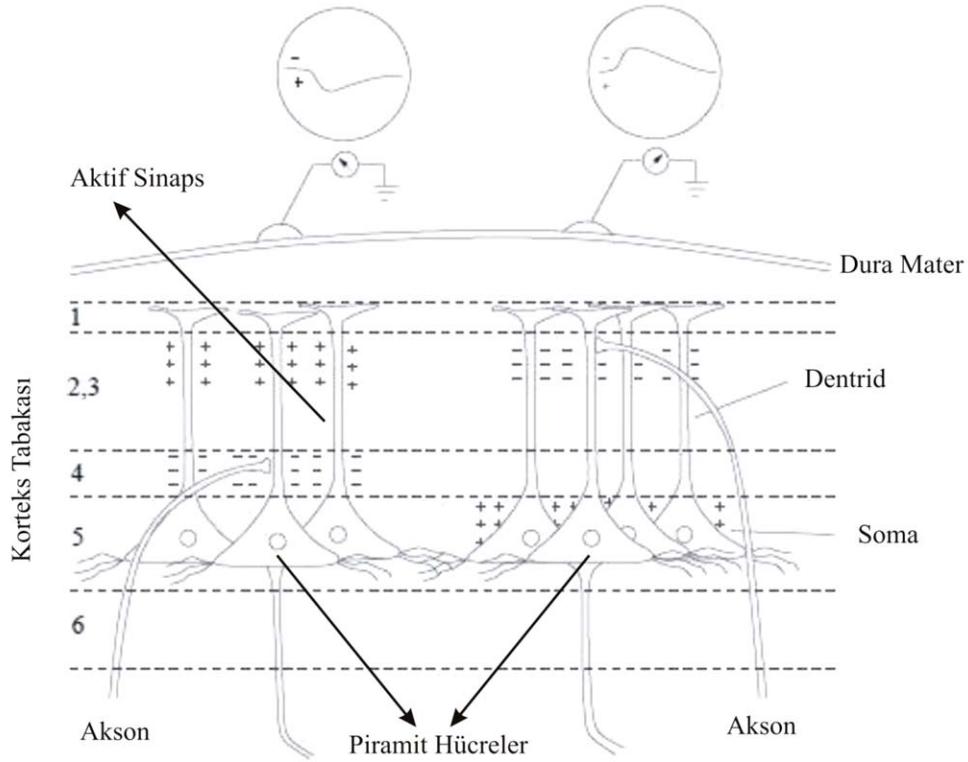
Günümüzde BBA uygulamaları için EEG, tek hücre kayıtlamaları (SCR), fonksiyonel manyetik rezonans görüntüleme (fMRI), bölgesel alan potansiyelleri (LFP), yakın infrared spektroskopisi (NIRS), elektrokortigografi (ECoG), magnetoensefalografi (MEG) gibi teknikler kullanılmaktadır. EEG bu teknikler içerisinde en çok kullanılan

yöntem olmasına rağmen sınırlı işaret gürültü oranından dolayı son zamanlarda daha yüksek işaret gürültü oranına sahip ECoG tabanlı BBA uygulamaları da denenmektedir.

1.2.2. ECoG ile Beyin Bilgisayar Arayüzü Arasındaki İlişki

Daha öncede belirtildiği üzere elektroensefalografi terimi ilk kez Berger tarafından kullanılmıştır [18]. Berger, insan kafatası yüzeyinden beyin dalgalarının tespit edilebileceğini ve okunabileceğini göstermiştir. Vidal' e göre kafatası yüzeyi elektriksel potansiyellerinin ana kaynağı kafatasının hemen altındaki beynin dış kabuğunu meydana getiren serebral korteksteki elektriksel etkinliktir. Serebral korteks, sinir hücreleri içeren gri maddeden oluşan ince bir tabakadır. Bu hücrelerin bir kısmı (piramit hücreleri) apik dendritlere sahiptir. Yani beyin yüzeyine doğru uzanır ve yanlamasına genişlerler. Bunun sonucunda ince bir beyaz madde yüzeyi oluşur ve burada da yoğun şekilde iç içe geçmiş ince dendrit uzantıları diğer komşu dendritlerle bağlantı kurarlar. Dendritler elektrik alanı nöron merkezine ileten elektrolitik bağlantı araçlarıdır. Hücre merkezine ulaşan elektrik sinyali hücre zarını depolarize ederek hücre akımını tetikler ve böylece sinyal yeniden diğer bir tür hücrelerarası bağlantı elemanı olan akson üzerinden ilerler. Gözlemlenen yüzey potansiyelleri piramitsel hücrelerin tepedeki dendritlerinde ve hücre merkezinde üretilir. Bu potansiyeller hücre içindeki polarizasyon ve depolarizasyona karşılık gelir.

Hücreler arası alanda dikey olarak ilerleyen elektrik akımlarının aynı zamanda dendritler ile derinlerdeki hücreler arasında bir tür geri besleme bağlantısı sağladıkları da düşünülmektedir. Yüzeydeki pozitif olarak kaydedilen bir değişim derin bölgelerdeki bir depolarizasyona (daha yüksek uyarılabilirlik) karşılık gelir ve bunun terside doğrudur. Şekil 1.9.' da piramitsel hücrelerin beyin üst kısmında nasıl yerleştikleri ve ECoG işaretlerinin kaydedilmesi için elektrotların yerleşimleri şematik olarak gösterilmektedir.



Şekil 1.9. Elektriksel sinyalin elektrotla ulaşması

1.2.3. Beyin Bilgisayar Arayüzü Çeşitleri

BBA çeşitleri, bağımlı BBA ve bağımsız BBA olmak üzere iki adettir [19]. Bu ayrım, beynin çıktı yollarına olan bağımlılık ile ilgilidir.

1.2.3.1. Bağımlı Beyin Bilgisayar Arayüzü

Bağımlı bir BBA sistemi beynin normal çıktı kanallarını kullanır. Bu yüzden de bu tür bir BBA öyle ya da böyle tam olarak işlevsel bir sinir sistemi gerektirir. Yaygın bir BBA örneği vermek gerekirse, bedeninin büyük kısmı felçli olan bir hastaya ekranda tek tek harfler gösterilir. Hasta seçmek istediği harf ekranda görününce konsantre olup o harfe bakar. Bu durum, görsel olarak tetiklenen bir potansiyele (GTP) yol açar ve EEG cihazı ile tespit edilebilir. Bunun mümkün olmasının sebebi hastanın konsantre olup belli bir süre baktığı harfin diğer harflere bakma durumuna kıyasla daha yüksek bir GTP oluşturmasıdır.

Her ne kadar bu tür BBA sistemleri bazı durumlarda, mesela kullanım kolaylığı ve düzgün öğrenme eğrisi gibi konularda faydalı olsa da, sistem çok hasar görmemiş bir sinir sisteminin varlığına dayanır. EEG kullanılıyor olsa da sinyal üretilmesini sağlayan şey göz kasları ve bunları kontrol eden kraniyal sinir hücreleridir.

1.2.3.2. Bağımsız Beyin Bilgisayar Arayüzü

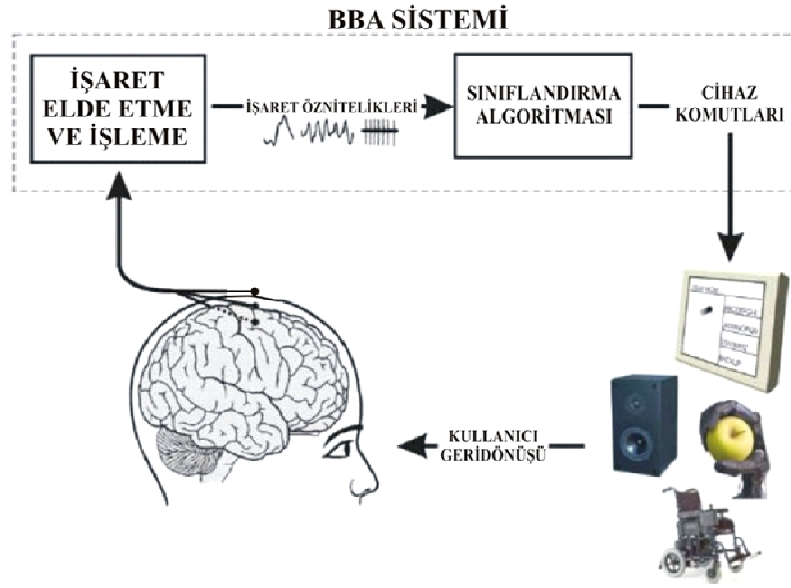
Bağımsız bir BBA sistemi sağlam bir çevresel sinir sistemi gerektirmez. Böyle bir BBA sadece kullanıcının eğilimlerine dayanır. Yine yukarıdaki harf seçme örneğini göz önüne alacak olursak, eğer bağımsız BBA kullanılırsa kullanıcının tek yapması gereken istediği harfi düşünmektir. Bu mekanizmada gözün hareketi ya da kontrolü ile ilgili hiçbir şey söz konusu değildir. Bu durumda EEG tarafından tespit edilen P300 potansiyelidir. P300 potansiyeli aşağıda açıklanacaktır.

1.2.4. Beyin Bilgisayar Arayüzü Sisteminin Temel Bileşenleri

Modern bir BBA sistemi beş alt sisteme bölünebilir:

1. Sinyal elde etme ve ön işleme
2. Öznitelik çıkarma
3. Sınıflandırma algoritması
4. Cihaz komutları
5. İşletme protokolü

Bu sistemlerin işleyişi Şekil 1.10.' da gösterilmiştir.



Şekil 1.10. BBA sisteminin temel bileşenleri [20]

1.2.4.1. Sinyal Elde Etme

Sinyal elde etme bir BBA sürecindeki ilk adımdır. Beyinde gelen sinyalleri tespit edip kaydetmek için en yaygın kullanılan yöntem EEG olmasına rağmen sınırlı işaret-gürültü oranı nedeniyle son yıllarda ECoG tabanlı BBA uygulamaları da son yıllarda denenmektedir. EEG harici bir yöntem olduğu için üzerine yapılan çalışmalar daha fazladır. Fakat ECoG gibi dâhili yöntemlerde daha iyi uzamsal ve zamansal çözünürlük sağlamaktadır. Ayrıca kas hareketlerinin bozucu etkileri EEG' ye göre önemli ölçüde azalmaktadır. EEG' nin dezavantajlarından biride çok fazla deneme gerektiriyor olmasıdır. EEG tabanlı beyin bilgisayar arayüzleri çoğunlukla μ ve β dalgaları üzerine yoğunlaşmıştır. Çünkü gama dalgaları kafatası üzerinde dikkate alınmazlar. Bunun aksine ECoG' da γ dalgaları μ ve β dalgaları kadar önemlidir. ECoG, EEG' den daha iyi işaret-gürültü oranı vermektedir. ECoG cerrahi müdahalesi ile işaret elde etme işlemi belli başlı laboratuarlarda yapılmaktadır. ECoG verilerinin elde edilmesi için hastalardan BBA deneylerine katılması istenir. Hastalara elektrot ızgaralarının yerleşim pozisyonunu BBA deneyleri için değil, tamamen epileptik alanın tespiti için olduğu söylenir. Hasta ile gerçek zamanlı etkileşim vardır.

1.2.4.2. Öznitelik Çıkarma

Elektrik sinyalleri ECoG yöntemi kullanılarak kaydedildikten sonra bunlardaki özniteliklerin tespit edilmesi, çıkarılması gerekir. Bu süreç, örüntü tanıma ve sınıflandırma öncesindeki bir önışleme olarak düşünülebilir. Bu süreçte ham sayısal sinyal verisi alınır ve bazı bakımlardan özetlenir. Uzamsal süzme, spektral çözümleme ve voltaj şiddeti ölçümleri öznitelik çıkarmada kullanılan tekniklerden bazılarıdır. Ayrıca aksiyon potansiyelleri, PCA, ICA, dalgacık dönüşümü, filtreleme yöntemleri ve istatistikî yöntemler de öznitelik çıkarmada kullanılabilir.

1.2.4.3. Sınıflandırma Algoritması

Sayısal beyin işaretine ait bazı öznitelikler çıkarıldıktan sonra bu bilginin içindeki örüntülerin taranması ve tanınması gerekmektedir. BBA sistemi ancak bu şekilde hangi komutların gerçekleştirilmesi gerektiğini anlayabilir. Toplanan verideki özellikleri çözümlemek için çeşitli algoritmalar kullanılır. Bu algoritmalar esnek yani yeniden uyarlanabilir ve hatalara karşı dayanıklı olmalıdır. Çünkü BBA kullanıcısı her seferinde aynı şeyi düşünüyor olsa da beyin sinyallerinde çeşitli sapmalar, ufak tefek dalgalanmalar mutlaka olacaktır. Algoritmanın esnekliği öğrenme açısından da önemlidir. Bu olay bir konuşma veya görüntü işleme uygulaması gibi de düşünebilir. Bu uygulamalar işleyecekleri veri için eğitilirler ve genellikle işleyecekleri verinin karakteristikleri de bazı bakımlardan o kullanıcıya özgü olur. Bunların ötesinde algoritmanın esnekliğinin ve öğrenme yeteneğinin önem arz ettiği bir başka durum da vardır: İnsan süreç içinde aynı kalmaz. Ufak tefek metabolizma değişiklikleri, hastalıklar, mevsimsel değişimler ve hatta günün hangi saatinde olduğu kişinin vücudunu ve dolayısı ile beyninin işleyişini bazı bakımlardan değiştirir.

Üçüncü seviye uyarlanabilirlik ise oldukça detaylı bilgi işleme algoritmalarını gerektirmektedir. Bu aşamadaki uyarlama BBA sisteminin, beynin o sisteme uyum sağladığını fark etmesini gerektirir. Diğer bir ifadeyle kullanıcı beyni BBA sistemini nasıl kullanacağını öğrenirken değişmektedir ve BBA kendisine adapte olmaya çalışan beyin ile uyum içinde çalışıp beyne düzgün şekilde geri besleme verir, kullanıcıyı doğru bir zamanlama ile ödüllendirirse, makine ile kullanıcı arasında güçlü bir bağlantı oluşur. Bu da makinenin çok daha iyi bir başarımla çalışması anlamına gelir.

Beyin Bilgisayar Arayüzü uygulamasında yaygın olarak kullanılan bazı sınıflandırma algoritmaları şunlardır; Destek Vektör Makineleri (DVM), K-En Yakın Komşuluk (KNN), Yapay Sinir Ağları (YSA), Bulanık mantık ve Doğrusal Ayırma Analizi (DAA).

1.2.4.4. Cihaz Komutları

Modern bir BBA sisteminin çıktısı herhangi bir cihaz olabilir ama genellikle bu cihazlar bilgisayarlar ya da bilgisayar kontrollü robotlardır. Araştırmalarda ve deneylerde kullanıcıya geri besleme sağlamak için genellikle bir bilgisayar monitörü ve bunun üzerindeki imleçler, ikonlar ve harf seçimleri kullanılır.

1.2.4.5. İşletim Protokolü

İşletim protokolü sistemin genel olarak davranışını ve kullanımını belirleyen kurallar bütünüdür. Protokol sistemin ne tür bir iletişim kullanacağını, ne tür beyin sinyallerinin analiz edileceğini ve sistem ile kullanıcı arasındaki etkileşim şekillerini belirler. Uzman araştırmacıların ve BBA teknisyenlerinin hazır bulunup kullanıcıya ya da hastaya yardımcı oldukları bir laboratuvar ortamında bu protokol çok detaylı ya da önemli olmayabilir ama eğer BBA sistemi bir hasta tarafından tek başına kullanılacaksa ve hasta kendisi cihazı açıp kapatmak, komut vermek zorunda ise protokol detayları had safhada önem arz eder.

1.2.5. Modern Beyin Bilgisayar Arayüzü Örnekleri

Pek çok BBA sistemi kullandığı beyin sinyali türüne göre sınıflandırılabilir. Bu sınıflar şunlardır:

1. Görsel olarak tetiklenen potansiyeller
2. Yavaş kortikal potansiyeller
3. P300 tetiklenen potansiyeller
4. Düşünsel hareket

1.2.5.1. Görsel Olarak Tetiklenen Potansiyeller

GTP, hastanın oksipital korteksinin uyarılması sonucunda oluşur. Yanıp sönen harfleri ya da benzeri görsel uyarıları gösteren bir bilgisayar monitörü beyinde bu tür elektrik potansiyel farklılıklarına yol açar.

Daha önce belirtildiği gibi 1970'lerde Vidal tarafından BBA araştırmalarında kullanılan ilk sinyal türü GTP idi. Ancak bu BBA sistemi bağımlı BBA olup hastanın az da olsa gözünü bir yere odaklayabilmesini gerektiriyordu. Burada önemli olan nokta dikkat seviyesi ve bakışın yöneldiği yer ile bilginin tamamen EEG ile toplanıyor olmasıdır yani hiçbir şekilde gözün kendisi üzerinden bir ölçüm yapılmamaktadır. GTP kullanan modern bir BBA sistemine örnek olarak Middendor gösterilebilir. Kullanıcı ekrandaki düğmelerden birini bakışlarını oraya odaklayarak seçebilir.

1.2.5.2. Yavaş Kortikal Potansiyeller

Yavaş kortikal potansiyel (YKP) biyoelektriksel beyin sinyalindeki potansiyel kaymadır [21]. Negatif YKP' ler genellikle kortikal etkinliğe yol açan hareket ve benzeri işlevlerle bağlantılı iken pozitif YKP' ler de seviyesi düşen kortikal etkinlikle ilgilidir. Negatif kaymalar genellikle beynin primer görsel korteksinin görsel uyarana karşı verdiği elektriksel tepkidir.

Bu tür sinyaller EEG ve ECoG verisindeki çok yavaş voltaj değişimleri olarak algılanır. Bu değişiklikler 0,5 ile 10 saniye arasında gerçekleşir. Yavaş kortikal potansiyellerle ilgili en önemli nokta, insanların bunları kullanmak üzere biyogeribesleme aracılığı ile eğitilebilmeleridir. Dolayısı ile YKP' ler BBA operasyonunun temelini oluşturur. YKP' leri kullanan en meşhur BBA' lardan biri Düşünce Tercüme Cihazıdır.

1.2.5.3. P300 Tetiklenen Potansiyeller

P300 tetiklenen potansiyeli alakasız bir uyarın dizisi içine gömülmüş dikkat çekici bir uyarın ile karşılaşan beynin yaklaşık 300 ms sonra ürettiği pozitif potansiyeldir [22]. Tipik bir P300 dalga formu Gauss dağılımını andırır, yarı genişliği 150 ms olup şiddeti 100 mikrovolta kadar çıkar. Genellikle temiz bir P300 dalgası elde edebilmek için pek çok

denemenin ortalamasını almak gerekmektedir ve bunun sebebi de sinyalin, gürültü başına düşen sinyal oranının düşük olmasıdır.

P300 potansiyellerini kullanan BBA sistemlerinin kullanımları daha çok yenidir. Yapılan bir çalışmada sistemin kullanıcıları bilgisayar monitöründe yanıp sönen harflere bakarak istedikleri harfi seçebilmektedir. Sistemin performansı dakikada yaklaşık bir kelime kadardır. P300 tabanlı BBA sistemlerinin avantajlarından biri kullanıcının eğitilmesine pek gerek duyulmamasıdır yani sistem çok kısa sürede kullanılır hale gelmektedir. Bu tür çalışmalar çok yeni olduğundan P300 BBA uygulamalarında kullanıcı beyninin sisteme alışmasından kötü etkilenip etkilenmeyeceği henüz bilinmemektedir.

1.2.5.4. Düşünel Hareket

Normalde insanlar uyanıkken ve belli bir şey yapmıyorken beyinde α dalgaları baskındır. Bu dalgalar 7,5-12 Hz frekans aralığındadır. μ ritimleri aynı aralıkta olup α dalgalarındaki ufak tefek değişiklikler şeklinde kendilerini gösterirler. Buradaki önemli nokta şudur: μ ritimleri, kişi hafifçe motor korteksini uyaracak şekilde bir şeye konsantre olduğunda ortaya çıkan α dalgalarıdır. β ritimleri ise 13-30 Hz aralığındadır ve bunlarda istemli hareket ve etkin odaklanma ile bağlantılıdır.

Yapılan çalışmalarda insanların 7,5-12 Hz aralığındaki μ ritimlerini ve 18-25 Hz aralığındaki β ritimlerini kontrol edebildikleri ve böylece ekrandaki bir imleci istedikleri gibi hareket ettirebildikleri görülmüştür [23]. Gerçek ve hayal edilen hareketleri kıyaslayarak ve temel bileşen analizi kullanarak bu ritimler çözümlenmiş ve hem gerçek hareketlerin hem de düşünel hareketlerin μ ve β ritim desenkronizasyonları ile bağlantılı olduğu tespit edilmiştir. μ ve β ritimlerinden faydalanan örnek bir çalışma Wolpaw tarafından yapılmıştır. Bu sistemde kullanıcı ekrandaki imleci iki boyutlu olarak kontrol edip sadece düşünerek ve bedeninin başka hiçbir yerindeki hareketlere dair bir şey gerçekleştirmeksizin bir bilgisayar oyununu oynayabilmektedir.

Özetleyecek olursak; Hastalar, BBA sistemlerini kullanarak çok basit kelime işlem uygulamalarını çalıştırabilmekte, etraflarındaki cihazları açıp kapatabilmekte, cihazları belli bir ölçüye kadar ayarlayabilmektedirler. BBA sistemlerinin gelişimi uyarlanabilir dönüştürme algoritmalarının geliştirilmesine ve beynin işleyişi hakkındaki bilgilerimizin artmasına bağlıdır. Bilgi işleme teknikleri gelişirken bir yandan da fiziksel boyutları düşen bilgisayarlar BBA açısından önemli bir avantajdır çünkü bu sayede sistemleri daha

taşınabilir yapmak ve böylece BBA kullanan hastaların hareket özgürlüklerini artırmak mümkün olmaktadır. BBA sistemleri daha taşınabilir hale gelip ucuzladıkça ALS gibi ağır hastalıklarla mücadele eden hastalara yardım etmek kolaylaşacaktır. BBA araştırmalarının bir başka önemli noktası da kas uyarıcıları ve harekete geçiricilerinin intrakortikal elektrotlara bağlama deneyleridir. Böylece normalde kaslarına hükmedemeyen hasta bu yapay sistemler sayesinde de olsa bazı kaslarını hareket ettirebilir hale gelecektir.

Tablo 1. Farklı BBA çeşitleri için eğitim süreleri [24]

BBA Tipi	Kullanıcı Eğitim Süresi	Kontrol Oranı
EEG-mu ve beta dalgası	2-3 hafta (2-3 40 dakika oturum/hafta)	Kayda değer bir oran
ECoG- mu ve gama dalgası	3-8 gün (1-8 3 dakika)	74-100% doğruluk
P300 potansiyelleri	Birkaç aydan birkaç yıla kadar (3-4 saat için 2-3/hafta)	
Yavaş Kortikal Potansiyeller	Haftalık 1-2 saatlik oturum ile birkaç hafta veya ay	>75% doğruluk

1.3. Literatür Araştırması

Son yıllarda BBA' ne olan ilgi artmıştır. Şu an bu alanda birçok çalışma yapılmaktadır. BBA araştırmalarının birçoğu EEG' ye dayalı olarak yapılmasına karşın son yıllarda ECoG işaretlerine dayalı BBA araştırmalarına olan ilgi artmaktadır. BBA araştırmalarını yürüten başlıca laboratuvarlar ve bu konu ile ilgili araştırmacıların yaptığı çalışmalar aşağıda özetlenmiştir.

N. Jeremy Hill, Thomas Navin Lal ve diğerleri hızlı BBA için kullanıcıyı eğitmeden EEG ve ECoG işaretlerini sınıflandırmaya çalışmışlardır. Her bir kişiden tek bir kayıt süresince EEG ve ECoG işaretlerini kullanarak düşünsel motor hareketi tabanlı BBA geliştirmeyi hedefleyerek bununla ilgili bir dizi çalışma yapmışlardır. Aynı deneyleri ve analitik metotları 11 tane sağlam kişiye (8 tanesi EEG, 3 tanesi ECoG) olmak üzere uygulamışlardır. Ve bu deneyleri ve analitik metotları 5 felçli hastaya (4 EEG, 1 ECoG)

uygulamışlardır. Bu felçli hastalar çevreleriyle iletişim kuramayan kişilerden oluşmuştur. Sağlam kişilerden alınan kayıtların çoğu için işaretleri sınıflandırmak kolay olmasına karşın aynı metotları kullanarak felçli hastalardan elde edilen beyin işaretlerini sınıflandırmanın imkânsız olduğu kanıtlanmıştır. Bu gerçek bazı BBA modellerinin sağlıklı insanlarla oldukça başarılı sonuçlar verdiğini ancak bu çalışmaların asıl amaç grubuna yönelik (hastalar) oldukça başarılı sonuçlar vermediğini görmüşlerdir. N. Jeremy Hill ve arkadaşları bunun muhtemel nedenlerini bu çalışmalarında özetlemişlerdir [25].

Yine Almanya' dan N. Jeremy Hill ve arkadaşları 3 farklı düşünsel motor hareketi tabanlı BBA deneyleri ile ilgili çalışmalar yapmışlardır. Beyin işaretleri EEG, ECoG ve MEG yöntemleriyle kaydedilmiştir. Kısa sürede muhtemel en iyi sınıflandırma yöntemlerini elde etmeye çalışmışlardır. İki ana konu üzerinde yoğunlaşmışlardır. Birincisi deneme sayılarının etkileri, ne kadar uzunlukta bir kayıt süresi gerekli? Bunun sonucu olarak ortalama EEG işaretleri için 200 deneme MEG için 75-100 deneme ve ECoG için 25-50 denemenin yeterli olduğunu bulmuşlardır. İkinci konu ise uzamsal filtrelemenin etkilerinin ne olduğu ile ilgilidir. Her 3 kayıt tipi için ortak uzamsal örüntü algoritması (Common Spatial Pattern Algoritması) ve bağımsız bileşen analizinin çıktılarını ile orijinal işaretlerinin performanslarını karşılaştırdılar. Sonuç olarak uzamsal filtreleme MEG kayıtlarında herhangi bir performans artışı sağlamıyor, ECoG da küçük bir iyileşme sağlıyor. Buna karşılık EEG işaretlerinde oldukça iyi bir performans gösteriyor. EEG işaretleri uzamsal olarak bulanık oldukları için uzamsal filtreleme EEG işaretleri için çok kritik bir öneme sahiptir. Bunun için sınıflandırma doğruluğunu arttırmak için muhtemelen ya 1. dereceden bağımsız bileşen analizi ya da ortak uzamsal örüntü algoritması (Common Spatial Pattern Algoritması) kullanılır. Bu iki yaklaşımın da performansı yaklaşık olarak eşittir. ECoG' da kanallar arası cross-talk daha az meydana geldiğinden uzamsal filtreleme daha az önemlidir [26].

Washington Üniversitesi Bilgisayar Bilimi ve Mühendisliği Bölümünden Prodeep Shenoy, Kai J. Miller ve arkadaşları ECoG tabanlı BBA için parmak hareketlerinin sınıflandırılması üzerine çalışmalar yapmışlardır. Prodeep Shenoy ve arkadaşları önceki çalışmalarında dil ve el hareketlerinin sınıflandırılması üzerinde çalışmalarında ECoG işaretlerinin yüksek uzamsal çözünürlük ve yüksek kestirim doğruluğuna sahip olduğunu görmüşlerdir. Bu çalışmalarında daha önceki öngörülerini genişleterek ECoG işaretleriyle 5 farklı sınıflandırma yoluna gitmişlerdir. 10 dakikadan daha az bir eğitim verisi kullanarak 6 denekten alınan 5 farklı sınıftan veriyi ortalama %23'lük bir hata ile

sınıflandırmışlardır. Çalışmalarında vücudun diğer farklı yerlerini kullanan (örneğin: el, dil, ayak) gibi çok sınıflı BBA yerine sadece el parmaklara odaklanmışlardır. Amaçları elin fonksiyonlarını yerine getiren sezgisel protezlerin gelişmesine yardımcı olmaktır. Yaptıkları çalışmada, ECoG işaretlerinin motor aktiviteleri için yüksek frekans bandını oldukça bilgi içerdiğini ve 5 farklı sınıf veri için iyi bir sınıflandırma performansı gösterdiğini fark etmişlerdir. Çalışmaları parmakların gerçek hareketleri üzerine odaklanmıştır. Çalışmalarında 6 denek bir bilgisayar ekranı karşısına oturtulmuş ve ekrandaki işaretlere göre parmaklarını hareket ettirmeleri istenmiş her bir parmak 30 kez hareket ettirilmiş, 5 farklı sınıf hareket için toplam 150 kez denenmiştir. Önceki çalışmalarında [27] motor kortikal alanları için 11-40 Hz ve 71-100 Hz arası frekans bantlarının oldukça efektif olduğunu ve bununla birlikte başka bir çalışmalarında [28] 101-150 Hz arası frekans bandının oldukça fazla bilgi içerdiğini bulmuşlardır. Bu çalışmalarında bu 3 frekans bandını kullanmışlardır. Destek vektör makineleri ve doğrusal planlama makineleri (Lineer Programming Machine) olmak üzere 2 farklı sınıflandırma metodu kullanmışlardır. Doğrusal planlama makineleri yönteminde 6 denekten alınan verilerden ortalama %23 hata ile sınıflandırma işlemi gerçekleştirilmiştir. Çalışmalarında doğrusal planlama makineleri yönteminin DVM yöntemi sınıflandırıcıya göre daha iyi bir performans gösterdiği görülmüştür [29].

Washington Üniversitesi Biyomedikal Mühendisliği Bölümünden Eric C.Leuthardt ve diğerleri ECoG işaretlerini kullanarak yaptıkları çalışmalarında bilgisayar imlecini bir boyutlu olarak hızlı ve doğru bir şekilde kontrol edilebilmesini sağlamışlardır. 4 Hastanın katıldığı deneylerde 3 ile 24 dakikalık bir eğitim süresinden sonra bu işaretlerle % 74 ile %100 oranında bir başarı elde etmişlerdir ve ayrıca çalışmalarında joystick hareketlerini iki boyutta kontrol edilmesi deneyini yapmışlar ve ECoG işaretlerinin 180 Hz' e kadar olan frekanslar için önemli bilgiler taşıdıklarını fark etmişlerdir. Araştırma sonuçlarına göre ciddi şekilde motor sinir sistemi rahatsızlığı olan kişiler ve felçli hastalar için ECoG tabanlı BBA' nin EEG tabanlı BBA' ne göre kontrol açısından daha iyi performans veren bir yöntem olduğu ve aynı zamanda beyin içerisine elektrotların yerleştirilmesi esasına dayalı BBA' ne göre daha kararlı olduğu ve daha az travmatik olduğu sonucuna varmışlardır. Deneylerinde hastaların sol ön parietal-temporal korteksi üzerine yerleştirilen 32 elektrotla ECoG kayıtları gerçekleştirilmiş olup hastalardan 3 motor olayı (sağ veya sol eli açıp kapama, dili dışarı çıkarma ve İngilizce 'move' kelimesini söyleme işlemi) ve diğer 3 görev bu işlemlerin düşünsel olarak yapılması olup bu 6 görevden birini yapmaları

istenmiştir. Her elektrot için autoregresive spektral analizi ile 0-200 Hz arası her bir görevin gerilim spektrumlarını bulmuşlardır. Her bir görevi beynin aktif olmayan durumuna göre karşılaştırmışlardır. Bekledikleri gibi her bir hastada her bir görev için μ ve β ritimlerinin genliklerinde bir azalma ve γ ritmi genliklerinde bir artış olduğunu görmüşlerdir. Her bir hasta için bir veya iki elektrot ve μ, β ve/veya γ frekans bandlarını seçerek bu 3 motor olayı veya bunların düşünsel olarak gerçekleştirilmesi görevlerinden biriyle en yüksek korelasyonu (ilişki) gösterdiler [30].

Almanya' dan Thilo Hinterberger ve diğerleri Bonn Üniversitesi Epileptoloji Bölümünde yaptıkları çalışmalarda yaşları 21 ile 46 arasında olan 5 epilepsi hastasından 5-14 gün arsında ECoG işaretleri elektrot gridleri yardımıyla kaydedilmiştir. Deneyler eğitim fazı ve iletişim fazı olmak üzere iki aşamadan oluşmuştur. Hastalarda el ve dil hareketinin düşünülmesi gibi iki farklı istekte bulunulmuş ve bunlar kaydedilmiştir. Eğitim denemelerinde kaydedilen veriler kullanılarak Autoregresive (AR) bir modelleme, kanal seçimi ve sınıflandırma işlemleri yapılmış ve bunlar kullanılarak deneyin ikinci aşaması için bu ECoG işaretlerini sınıflandırma yoluna gidilmiştir. Her bir denemenin sınıflandırma sonuçları bir heceleme uygulaması için kontrol işareti olarak kullanılmıştır. Sınıflandırma algoritması olarak Destek Vektör Makinesi algoritmasını kullanmışlardır. Çünkü DVM büyük ölçekli sınıflandırma problemlerinde iyi bir performans gösterdikleri bilinmektedir. Öznitelik çıkarma işleminde AR model kullanmışlar ve en düşük offline çapraz-doğrulama hatasını $M=3$ için bulmuşlardır. Çalışmalarında ilgili kanalların otomatik seçimi BBA sistemlerinde sınıflandırma performansını artırdığı gözlenmiştir [31].

B.Grainmann ve diğerleri ECoG kanalında harekete bağlı örüntüleri (movement-related pattern) ayırmak için dalgacık paket analizi ve genetik bir algoritma kullanmışlardır ve %90' dan fazla doğruluk elde etmişlerdir [32].

JF Fen ve diğerleri çalışmalarında çok katmanlı sinir ağları (Multilayer Perceptron Neural Network (MLPNN)) ve Genetik Algoritma (GA) dan oluşan bir yöntem kullanmışlardır. Genetik Algoritma yöntemi sınıflandırma performansını artırırken kanal sayılarını azalttığından dolayı ECoG kanal seçimini optimize etmek için kullanmışlardır. Error back-propagation algoritması MLPNN' nin öğrenme mekanizması olarak kullanılmıştır. Doğrusal olmayan (non-linear) dinamik özellikleri (mesela permutasyon entropisi- PE ve Hurst exponent- HE) kanal seçimi ve sınıflandırma için seçilmiştir. Çünkü 2 doğrusal olmayan parametre yüksek hesaplama performansı ve büyük ayırt etme yeteneği verdiler. Çalışma sonucu olarak tüm 64 kanalı kullanarak yapılan sınıflandırma

%79 olmasına karşın sadece seçilen 15 kanalı kullanarak %87 oranında bir sınıflandırma başarısı göstermiştir [33].

R.Murat Demirer ve diğerleri bu tez çalışmasında kullanılan verilerle yaptıkları çalışmalarında ECoG işaretlerini sınıflandırma yoluna gitmişlerdir. Çalışmalarında ilk olarak Hilbert domeninde Tsallis entropisine dayalı kanal seçimi işlemi yapmışlar ve SVM yöntemi ile 2 düşünsel olayın doğrusal olmayan sınıflandırmasını yapmışlardır. Eğitim verileri için %95 oranında ve test verileri için %73 oranında bir sınıflandırma doğruluğu bulmuşlardır [34].

M.Zaky Rasmy ve diğerleri BCI Competition III yarışmasındaki Data Set 1 verilerini kullanarak ECoG işaretlerini sınıflandırmaya çalışmışlardır. İlk olarak işaretlere Spektral Gürültü Çıkarma (Spectral Subtraction Denoising) uygulayarak işarettaki bozulmaları kaldırmaya çalışmışlar. T-test kuramı ve PCA yöntemlerini kullanarak 64 elektrot kanalından işaretlerin özelliklerini taşıyan 9 elektrot kanalını bularak öznelik çıkarma işlemi yapmışlardır. Son olarak bu özneliklerden işaretleri 4 farklı yöntemle sınıflandırma yoluna gitmişlerdir. Bu 4 farklı sınıflandırma yöntemi ve sonuçları şöyledir. Bayes minimum hata sınıflandırıcı %50 sınıflandırma doğruluğu; k-en yakın komşuluk algoritması %54 doğruluk, minimum mesafe sınıflandırıcısı %60 doğruluk ve son olarak sinir ağları ile yaptıkları sınıflandırma işleminde %62 doğruluk oranı ile sınıflandırma işlemlerini gerçekleştirmişlerdir [35].

2. YAPILAN ÇALIŞMALAR VE BULGULAR

2.1. Tezin Özeti

Bu tez çalışmasında BBA uygulamaları için farklı düşünsel durumlarda kaydedilmiş çoklu elektrot elektrokortigografi (ECoG) işaretlerinin sınıflandırılması konusu üzerine çalışılmıştır. Çalışmada kullanılan veriler BCI Competition III organizasyonu tarafından oluşturulmuş verilerdir. Bu yarışmada verilerin oluşturulmasını amacı farklı zamanlarda oluşturulan eğitim ve test veri kümelerini doğru bir şekilde sınıflandırılmasıdır. Eğitim ve test verileri farklı günlerde oluşturulduğundan dolayı deneğin motivasyonu, yorgunluğu gibi durumlardan dolayı verilerin özellikleri değişebileceğinden dolayı sınıflandırmada bu problemin giderilmesi için gerekli normalizasyon algoritmalarının katılımcılar tarafından oluşturularak sınıflandırma işleminin kararlı hale getirilmesi istenmiştir.

Çalışmada kısaca, çoklu elektrot ECoG verilerinde tüm elektrotlardan (kanallardan) elde edilen verileri kullanmak yerine, yapılan uygulamaya göre beyinsel aktivitenin yoğun olduğu bölgelerden alınan verileri kullanarak hem sınıflandırma için çıkartılacak en iyi özneliğin bulunmasını, hem de sınıflandırma aşamasında karar verme süresinin kısalmasını sağlar. Kanal seçme işlemi tüm kanalların frekans domeni incelemesi yapılarak görsel olarak belirlenmiştir. Bu çalışmada farklı frekans bandları denenerek μ ve β frekans bandlarının düşünsel durumla ilişkili olduğu görülerek bu veriler için en iyi sonuç duyu-motor ritimleri denen frekans bandı için bulunmuştur. Bu frekans bandına ait bilgiler bir band geçiren filtre yardımıyla çıkarılarak öznelik çıkarma aşamasında kullanılmıştır

Öznelik çıkarma işlemi BBA uygulamalarının en temel ve en zor konusunu oluşturur. Bu çalışmada farklı sınıflara ait ECoG işaretlerinden dalgacık dönüşümü katsayıları yardımıyla öznelikler çıkartılmıştır. Bu çıkartılan öznelik vektörleri ile değişik sınıflandırma algoritmaları kullanılarak sınıflandırma işlemi yapılmıştır.

Elde edilen yüksek sınıflandırma doğruluğu ECoG tabanlı BBA için büyük bir uygulama potansiyeli olduğunu ve ayrıca farklı oturumlar için BBA uygulamalarının çok zor olmadığını göstermiştir.


2.2. Materyal

Çalışmada kullanılan veri kümesi Almanya'nın Bonn Üniversitesi Epileptoloji Bölümü ve Tübingen Üniversitesi Davranış Nörobiyolojisi ve Medikal Psikoloji Enstitüsü tarafından epilepsi şikâyeti olan bir hastadan elde edilmiştir [36]. Bu veriler "BCI Competition 2005" yarışması için sunulmuştur.

BCI Competition yarışması, BBA teknolojilerinin gelişmesine yardımcı olmak için düzenlenmektedir. Bu organizasyonda BBA teknolojisi alanında önde gelen laboratuvarların deneylerinden elde edilen beyin işaretlerinden oluşan veri kümeleri (data set) vardır [37]. Her bir yarışmada bu veri kümeleri internet vasıtasıyla ilan edilmektedir.

Denek felçli bir hasta olmayıp sadece epilepsi şikâyeti olan biridir. Hastanın sinirsel aktivitesi ECoG kayıtları ile birkaç gün boyunca görüntülenir. Bu süre boyunca hasta düşünsel motor hareketine dayalı BBA deneylerine 2 kez katılır. Deneylerde kişiden iki farklı günde dil hareketi ve sol küçük parmak hareketi gibi 2 farklı olayı düşünsel olarak gerçekleştirilmesi istenmiştir. Beynin elektriksel aktivitesi sağ motor korteks üzerine yerleştirilen bir 8×8 ECoG platin elektrot gridleri ile kayıt edilmiştir. Elektrot gridlerinin sağ motor korteksi tamamen kapladığı varsayılmıştır, gridlerin boyutundan (yaklaşık 8×8 cm) dolayı kortikal alanı çevreleyen kısımlarında elektriksel aktiviteleri de kayıt edilmiştir.

Denemelerin kayıt süresi 3 saniyedir. Her bir denemede kişiden, düşünsel olarak yapması istenen hareket bilgisayar ekranında 0,5. saniyeden denemenin sonuna kadar gösterilmiştir. Örnekleme frekansı 1000 Hz olup tüm değerler μV mertebesindedir.



Şekil 2.1. Denemeler için bilgisayar ekranında gösterilen işaretler

Eğitim verileri 278 ayrı denemeden oluşmaktadır. Bunlardan 139 tanesi düşünsel sol küçük parmağın hareket denemelerine ait olup 139 tanesi ise düşünsel dil hareketine ait denemelerdir. Bu 278 denemenin tamamı aynı gün içerisinde alınmıştır. Test veri kümesi

ise 100 denemeden oluşmaktadır. Test verileri, eğitim verilerinden bir hafta sonra oluşturulmuştur. Sol küçük parmak hareketi ve dil hareketinin d şünsel olarak gerekleřtirilmesine ait deneme verileri, test veri kumesinde rastgele dađıtılmıřtır.

BCI Competition Data Set 1 veri kumesi sınıflandırma yaklařımlarının sađlamlıđını ele almaktadır. Bu grevin zorluđu hastanın elektriksel iřaretlerinin yeni bir oturumda bazı farklı karakteristikler gstermesidir. Bu tip kararsızlıklar (non-stationary) deneđin motivasyonundan, yorgunluđundan vb. durumlardan kaynaklanmaktadır. Buna ek olarak kayıt sistemi elektrotlarının konumu ve empedansları itibariyle k çük deđiřikliklere uđrayabilmektedir. Data set 1 veri kumesi bu durumu yansıtılmaktadır. Eđitim ve test verileri aynı test zamanında ve aynı kiřiden alınmasına rađmen bir hafta iinde 2 farklı g n kayıt yapılmaktadır. Kayıt sırasında EEG yerine ECoG kullanıldıđı iin elektrotların konum ve empedans deđiřimlerinin olduka k çük olacađı beklenmektedir. İlk oturumda katılımcılardan iřaretlenmiř eğitim verileri  zerinde oluřturulan bir sınıflandırıcıyı diđer oturumdaki test verilerine uygulanması istenmektedir.

2.2.1. Literat rde Aynı Veri Kumesini Kullanarak Yapılan alıřmalar

Toplamda 27 katılımcının bařvuru yaptıđı bu yarıřmada 12 katılımcı %80' nin  zerinde sınıflandırma dođruluđu elde etmeyi bařarmıřtır. T m katılımcıların ise ortalama dođruluk oranı %70' tir [38].

Yarıřmada en iyi sınıflandırma yapan katılımcılar ve uyguladıkları yntemler:

1) Tsinghua  niversitesinden Qingguo Wei ve arkadařları %91 dođruluk elde ettiler. alıřmalarında hareket iliřkili potansiyeller (movement related potancials- MRP) ve olay iliřkili desenkronizasyon (event related desynchronization- ERD) gibi duyu-motor korteksin durumunu yansıtan iki elektro-fizyolojik olguyu kullanmıřlardır. İřlem y k n  azaltmak iin eğitim ve test verilerinin t m denemeleri 3000 rnekten 300' e alt rneklenme yapılmıř ve alt rneklemeden sonra tekrar referans noktası oluřturmak iin common average referance (CAR) yntemini kullanmıřlardır. MRP iin 0-3 Hz frekans aralıđı ve ERD iin 8-30 Hz frekans aralıđı kullanılmıřtır. İki znelik common spatial subspace decomposition (CSSD) ile ve FDA ile ıkarılmıř,   nc  znelik ise rnek noktalarının ortalamalarında elde edilmiřtir. Y ksek bir sınıflandırma dođruluđu iin ıkartılan bu   zneliđi birleřtirerek sınıflandırmada kullanmıřlardır. Sınıflandırma iin destek vektr makinelerini kullanmıřlardır [39].

2) Paul Hammon %87 doğruluk oranı ile yarışmada 2. olmayı başardı. Paul Hammon çalışmasında BCI yarışmalarında kullanılan 3 farklı veri kümesini kullanmıştır ve veri kümeleri içerisinde BCI Competition III yarışmasında kullanılan Data Set 1 de vardır. Paul ilk olarak ECoG işaretlerine 250 Hz te alt örnekleme yaparak veri boyutlarını azaltma yoluna giderek işlem süresini kısaltmaya çalışmıştır. Bireysel kanalların doğru akım seviyelerini yok etmek için 8 Hz kesim frekanslı bir yüksek geçiren süzgeç tasarlamıştır. 45 Hz kesim frekanslı bir alçak geçiren süzgeç tasarlayarak şehir şebeke frekansı olan 50 Hz in bozucu etkilerinden kaçınmaya çalışmıştır. Çalışmasında kanal seçme yoluna giderek en iyi kanalları bulmaya çalışmıştır. Uzamsal filtreleme yapmak için ICA ve CSP algoritmalarını kullanmıştır. Veri sınıflandırma işlemi için DVM ve L1-Regularized Logistic Regression algoritmalarını kullanarak yapmış ve bunların yaklaşık olarak aynı doğruluk sağlamasına rağmen ve L1-Regularized Logistic Regression algoritmasının gürültülü verilerde daha iyi sonuçlar verdiğini göstermiştir [40].

3) Yarışmada üçüncülüğü 4 kişi paylaşmıştır. Bunlardan Michal Sapinski ön işlemede tüm kanalları 25 Hz' e alt örnekleme yapmıştır. Öznitelik çıkarma işleminde bazı zaman aralıklarında seçilen kanalların ortalaması ve seçilen kanalların seçilen frekans aralıklarının ortalama gücünü kullanmıştır. Bu öznitelikler göz yardımı ile farklılıklar belirlenerek oluşturulmuştur. Sınıflandırma işleminde logistik regresyon sınıflandırıcıları kullanmıştır [41].

Tablo 2. BCI Competition III Data Set I yarışmasına katılan çalışma gruplarının sonuçları

Sıra No	Katılımcı	Doğruluk (%)	Üniversite	Yardımcı Araştırmacı
1	Qingguo Wei	91	Tsinghua University, Beijing	Fei Meng, Yijun Wang, Shangkai Gao
2	Paul Hammon	87	University of California, San Diego	
3	Michal Sapinski	86	No affiliation, Poland	
3	Mao Dawei	86	Zhejiang University, P.R.C.	Ke Dagan, Xie Mingqiang, Ding Jichang vd.
3	Alexander D'yakonov	86	Moscow State University	
3	Liu Yang	86	National University of Defense Technology Changsha, P.R.C.	Hu Dewen, Zhou Zongtan, Zang Guohua
7	Florian Knoll	84	TU Graz	Alois Schloegl, Martin Hieden, Carmen Vidaurre vd
7	Zhou Zongtan	83	National University of Defense Technology Changsha, P.R.C.	Liu Yang, Hu Dewen
9	Jianzhao Qin	82	South China University of Technology, China	
10	Matthias Krauledat	82	Fraunhofer FIRST, Berlin	
11	Kiyong Yang		University of Southern California	
11	Martin Hieden	81	TU Graz, Austria	Florian Knoll, Alois Schloegl, Carmen Vidaurre
13	Archis Gore	79	Fergusson College, Pune	
13	Elly Gysels	79	CSEM, Neuchatel	
15	Xiaomei Pei	69	Xi'an Jiaotong University, P.R.C.	Guangyu Bin

2.3. Yöntem

2.3.1. Fourier Dönüşümü

Biyomedikal çalışmalarda en önemli işlemlerden birisi işaret analizidir. Bir fiziksel büyüklüğün bilgi içeriği iki temel yolla gösterilmektedir: zamanın fonksiyonu veya frekansın fonksiyonu olarak.

Trigonometrik serilerin teorisi 18. yy başlangıçlarına kadar uzanmaktadır. 1800'lü yıllarda Fourier birçok işaret türünün sinüs ve kosinüs işaretlerinin toplamından oluştuğunun keşfetti. 21.yy da hızlı Fourier dönüşümü algoritmalarının gelişmesi ile ayrık Fourier dönüşümü bilimde yaygın olarak kullanılmaktadır [42].

2.3.1.1. Sürekli Fourier Dönüşümü

$f(t)$ işaretinin Fourier dönüşüm çifti aşağıdaki eşitlikler ile verilmektedir. Eşitlik (1) Fourier dönüşümünü, eşitlik (2) ise ters Fourier dönüşümünü ifade etmektedir.

$$F(f) = \int f(t) e^{-i2\pi ft} dt \quad (1)$$

$$f(t) = \int F(f) e^{i2\pi ft} df \quad (2)$$

2.3.1.2. Ayrık Fourier Dönüşümü

Fourier dönüşümü sonsuz uzunlukta bir dizi için tanımlıdır ve daha önemlisi, sürekli bir değişken olan w açısal frekansının bir fonksiyonudur. Ayrık Fourier Dönüşümü (AFD) en fazla kullanılan sayısal işaret işleme algoritmalarından biridir. AFD matematik, fizik, kimya ve mühendislik gibi alanlarda yaygın olarak kullanılmaktadır [43], [44].

Ayrık Fourier Dönüşümü iki nedenden dolayı önemlidir.

1) Bir işaretin spektral analizini gerçekleştirebilmek için frekans bileşenlerini belirlememize yardımcı olur.

2) Frekans domeninde filtreleme işlemini gerçekleştirebilmek için kullanılabilir

$x(n)$ 'nin AFD ayrıca N -noktalı bir dizidir ve $X(k)$ olarak yazılır ve şöyle tanımlanır.

$$X(k) = \sum_{n=0}^{N-1} x(n) \cdot e^{-\frac{j2\pi nk}{N}}, \quad k=0,1, \dots, N-1 \quad (3)$$

Aşağıdaki notasyon kullanılabilir.

$$X(k) = \sum_{n=0}^{N-1} x(n) \cdot W_N^{nk}, \quad k = 0,1, \dots, N-1 \quad (4)$$

$$W_N = e^{-j2\pi/N} = \cos(2\pi/N) - j\sin(2\pi/N) \quad (5)$$

$$W_N^{mN} = (e^{-j2\pi/N})^{mN} = e^{-2\pi m}, \quad m = -\infty \dots -1, 0, 1, \dots \infty \quad (6)$$

$$W_N^{mN} = 1 \quad (7)$$

Ters ayrık fourier dönüşümü

$$x(n) = \left(\frac{1}{N}\right) \sum_{k=0}^{N-1} X(k) \cdot e^{\frac{j2\pi nk}{N}}, \quad n = 0,1, \dots, N-1 \quad (8)$$

$$x(n) = \left(\frac{1}{N}\right) \sum_{k=0}^{N-1} X(k) \cdot W_N^{-nk}, \quad n = 0,1, \dots, N-1 \quad (9)$$

W_N^{nk} terimi bir sabit olarak düşünüldüğü zaman AFD hesaplaması $N \times (N-1)$ kompleks toplam ve N^2 kompleks çarpma işlemi gerektirmektedir. N uzunluğundaki bir dizinin AFD hesaplamak için $2N^2$ veya N^2 işlem gerekmektedir.

2.3.1.3. Hızlı Fourier Dönüşümü (FFT)

AFD işlemi hemen hemen hiç doğrudan kullanılmaz, bunun yerine hızlı Fourier dönüşümü (FFT) kullanılarak hesaplama gerçekleştirilir. FFT, AFD ve ters AFD hesaplamak için kullanılan verimli bir algoritmadır.

$$X(k) = \sum_{n=0}^{N-1} x(n) \cdot W_N^{nk}, \quad k=0,1, \dots, N-1 \quad (10)$$

Burada $W_N = e^{-j2\pi/N}$

N noktalı $x(n)$ dizisi iki dizinin toplamı olarak yazılabilir. Başka bir ifadeyle tek ve çift dizilerin toplamı olarak yazabiliriz.

$$X(k) = \sum_{n_{cift}=0}^{N-2} x(n) \cdot W_N^{nk} + \sum_{n_{tek}=1}^{N-1} x(n) \cdot W_N^{nk} \quad (11a)$$

$$X(k) = \sum_{m=0}^{N/2-1} x(2m) \cdot W_N^{2mk} + \sum_{m=0}^{N/2-1} x(2m+1) \cdot W_N^{(2m+1)k} \quad (11b)$$

$$X(k) = \sum_{m=0}^{N/2-1} x(2m) \cdot (W_N^2)^{mk} + \sum_{m=0}^{N/2-1} x(2m+1) \cdot (W_N^2)^{mk} \cdot W_N^k \quad (11c)$$

$$W_N^2 = (e^{-j2\pi/N})^2 = e^{-j2\pi2/N} = e^{-j2\pi/(\frac{N}{2})} \quad (12)$$

Böylece $W_N^2 = W_{N/2}$

$$X(k) = \sum_{m=0}^{N/2-1} x(2m) \cdot W_{N/2}^{mk} + W_N^k \sum_{m=0}^{N/2-1} x(2m+1) \cdot W_{N/2}^{mk} \quad (13a)$$

$$X(k) = \sum_{m=0}^{N/2-1} x_{\text{çift}}(m) \cdot W_{N/2}^{mk} + W_N^k \sum_{m=0}^{N/2-1} x_{\text{tek}}(m) \cdot W_{N/2}^{mk} \quad k=0,1, \dots, N-1 \quad (13b)$$

$$X(k) = DFT_{N/2}\{x_{\text{çift}}(m),k\} + W_N^k DFT_{N/2}\{x_{\text{tek}}(m),k\} \quad (13c)$$

2.3.2. Dalgacık Dönüşümü

Dalgacık ifadesi ilk olarak 1909 yılında Alfred Haar tarafından ortaya atılmıştır. Dalgacık analizi yöntemi esas olarak Y. Meyer ve meslektaşları tarafından geliştirilmiştir. 1988 yılında Stephane Mallat önemli katkılar sağlamıştır. Temel algoritma, Stephane Mallat'ın çalışmalarına dayanmaktadır. Bundan sonra, dalgacık üzerindeki araştırmalar uluslararası hale gelmiştir. Bu konudaki tanınmış araştırmacılar; Ingrid Daubechies, Ronald Coifman ve Victor Wickerhauser olarak sayılabilir.

Dalgacık dönüşümünün matematiksel temeli Fourier dönüşümüne dayanmaktadır. Fourier dönüşümünün durağan olmayan sinyallerdeki eksiklerini gidermek için geliştirilmiş farklı bir dönüşüm yöntemidir [57]. Bu analiz yöntemi gürültüye karşı daha az hassasiyet göstermekte ve durağan olmayan sinyallere rahatlıkla uygulanabilmektedir. Bundan dolayı işaret işleme ile uğraşanların ilgisi frekans tabanlı fourier dönüşümünden ölçek tabanlı dalgacık dönüşümüne doğru kaymıştır.

Dalgacık dönüşümünün başlıca uygulama alanları, gürültü yok etme (işaretin veya görüntünün temizlenmesi) ve sıkıştırma (FBI'daki parmak izlerinin sıkıştırılması vb.). Ayrıca; ani değişimlerin olduğu işaretlerdeki, değişimlerin yakalanması için bu yöntem kullanılır. Tıp da EKG ve EEG gibi biyoelektrik işaretler ve manyetik rezonans izgesinin sınıflandırılması gibi birçok uygulama alanı daha vardır [61].

İşaret analizinde en çok kullanılan ve bilinen yöntem olan Fourier analizi ile işaret farklı frekanslardaki sinüslere ayrıştırılır. Diğer bir açıdan bakıldığında, Fourier analizi zaman ortamındaki işareti frekans ortamına dönüştüren matematiksel bir yöntemdir. Birçok işaret için Fourier analizi oldukça kullanışlıdır. Ancak, bu analizin ciddi bir sakıncası vardır. Frekans ortamına dönüştürmek ile zaman bilgisi kaybolur. İşarete Fourier dönüşümü ile baktığımızda olayın ne zaman gerçekleştiğini söylememiz imkânsızdır. Eğer işaretin özelliği zamanla değişmiyorsa, yani işaret durağan (stationary) ise bu durumda önemli değildir. Ancak, birçok işaret durağan olmayan ve keskin geçişlerin olduğu karakterdedir. Ani geçişler ve olayın başlangıç-bitiş yerleri işaret için en önemli bilgileri içermektedir ve Fourier analizi bunları algılamak için uygun değildir.

Dennis Gabor (1946), işareti küçük parçalara ayırıp inceleyerek Fourier dönüşümünün eksikliğini gidermeye çalışmıştır. Bu yöntem, Kısa-Zaman Fourier Dönüşümü (KZFD) denir ve işareti zaman ve frekans ortamında inceler. Matematiksel olarak

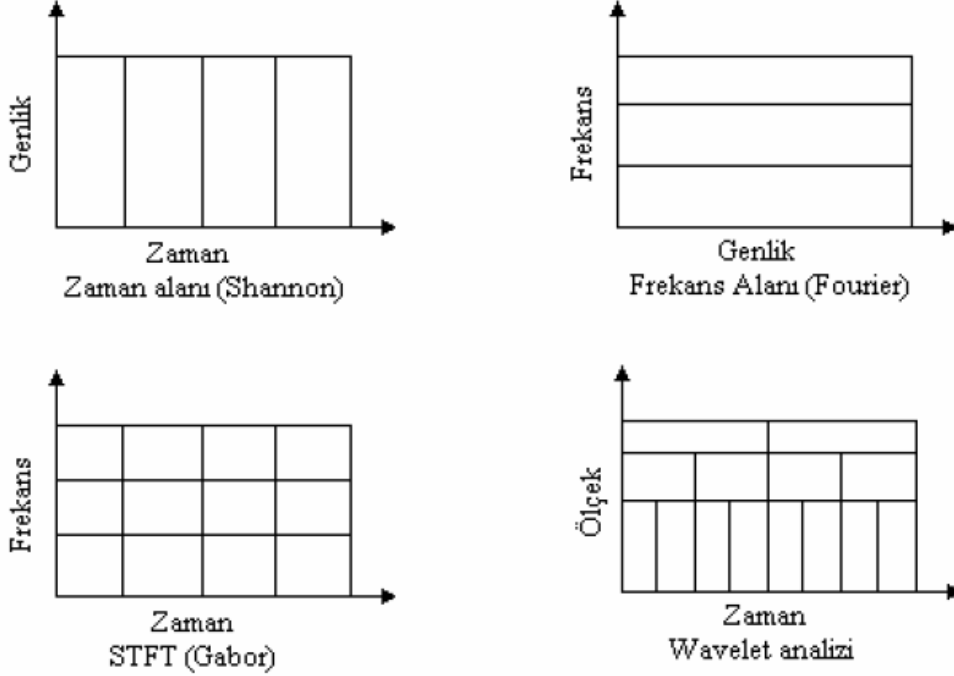
$$KZFD\{x(t)\} \equiv X(\tau, w) = \int_{-\infty}^{\infty} x(t)w(t - \tau)e^{-jw\tau} dt \quad (14)$$

Burada $w(t)$ pencere fonksiyonu ve genellikle merkezi sıfırda olan Hann pencere fonksiyonu veya Gaussian pencere fonksiyonudur. $x(t)$ giriş işaretidir. $X(\tau, w)$ zaman ve frekans üzerinden işaretin genlik ve fazını temsil eden bir fonksiyondur ve $x(t).w(t-\tau)$ nun Fourier dönüşümüdür. Üçgen pencere, Hanning penceresi, Gaussian ve Hamming pencereleri veri analizi için tasarlanmış bazı yumuşak pencerelerdir.

Bu yöntem, bir olayın ne zaman ve hangi frekansta olduğu hakkında bilgi verir. Ancak, bu yöntemin sakıncası; zaman ortamındaki pencerenin boyutu değiştirilirken frekans ortamındaki pencerenin sabit kalmasıdır. Birçok işaret için daha esnek bir yaklaşım gerekmektedir. Dolayısıyla, pencere boyutu zaman veya frekans ortamında değişmelidir.

Dalgacık dönüşümü Kısa Zamanlı Fourier Dönüşümüne (KZFD) bir alternatif olarak geliştirildi. Dalgacık analizi ile pencerelerin boyutu bölgelere göre değişir. Düşük frekans bilgilerine ulaşmak istediğimizde uzun zaman aralığı seçerken yüksek frekans bilgilerine ulaşmak istendiğinde de kısa zaman aralıkları seçilir. Dalgacık analizinde işaret, zaman-frekans yerine zaman-ölçek ortamında incelenir ve en önemli üstünlüklerinden biri; işaretin belirli bir bölgesinin analizinin mümkün olmasıdır. Örneğin; küçük bir süreksizliğe sahip bir işaretin, Fourier dönüşümünü çizdirdiğimizde süreksizliğin nerede olduğunu

göremeyiz. Fakat dalgacık katsayılarını çizdirdiğimizde süreksizliğin nerede olduğu tam olarak gözükmektedir.



Şekil 2.2. Sinyal analiz yöntemleri arasındaki ilişki, [57]

Dalgacık dönüşümünün temel fonksiyonlarına “dalgacık” denir. Bir $\psi(t)$ fonksiyonunun dalgacık adayı olabilmesi için aşağıdaki eşitlik (15) ve eşitlik (16) sağlanmalıdır.

$$E = \int_{-\infty}^{\infty} |\psi(t)|^2 dt < \infty, \psi(t) \in L^2(R) \quad (15)$$

$$\int_{-\infty}^{\infty} \psi(t) dt = 0 \quad (16)$$


Teorik olarak sıfır ortalamalı ve sonlu enerjiye sahip herhangi bir fonksiyon dalgacık sayılabilir. Ancak, dalgacığı seçmek için birçok ölçüt vardır. Dalgacığın, zaman ve frekans ortamındaki sönümlenmesi önemlidir. Zaman ve frekans ortamında iyi lokalize olabilmek için dalgacık, zaman ve frekans ortamında hızlı sönümlenmelidir [62]. Normal bir sinüzoidal sinyal eşitlik (15) ile verilen şartı sağlamaz çünkü $\mp \infty$ da bu sinyalin sıfıra gitmesi gerekmektedir yani öyle bir dalgacık arıyoruz ki $\mp \infty$ da sıfıra gitsin öyle bir ψ fonksiyonu ele alalım ki bütün reel alanı kapsasın. Sonuç olarak $L^2(\mathbb{R})$ de küçük bir dalgacık üretmeliyiz. $L^2(\mathbb{R})$ de ψ fonksiyonunun tüm uzayı kapsamasını istiyoruz. Fakat

bu durumda ψ dalgacığı hızlı bir şekilde azalan fonksiyondur. ψ nin tüm uzayı kapsaması için IR boyunca kaydırılması gerekmektedir. Buna göre $\psi(x - k)$ $k \in \mathbb{Z}$ olarak tanımlanır.

$$\psi_{a,b}(t) = \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right) \quad (17)$$

Eşitlik (17) ile temel dalgacık fonksiyonundan öteleme ve ölçeklemeyle türetilen dalgacık fonksiyonu verilmektedir [56]. Eşitlikte (a) ölçek indisini göstermektedir. Dalgacık analizindeki ölçek parametresi haritalarda kullanılan ölçeğe benzemektedir. Haritalardaki durumda, yüksek ölçekler detaysız global görüntüye(işaretin) karşılık gelmektedir. Düşük ölçekler detaylı görüntüye tekabül etmektedir. Benzer şekilde frekans açısından, düşük frekanslar (yüksek ölçek) işaretin global bilgilerine karşılık gelmektedir, buna karşın yüksek frekanslar (düşük ölçek) işarete saklı bir örüntünün(genellikle tüm işaret boyunca uzanır) detay bilgilerine karşılık gelmektedir(genellikle oldukça kısa sürelidir). Ölçeklendirme buna ağırlıklandırma da denmektedir ya işareti sıkıştırıran ya da genişleten matematiksel bir işlemdir. Yüksek ölçekler işaretin genişliğine (açıldığına), düşük ölçekler işaretin sıkıştırıldığına karşılık düşmektedir. Eşitlik (17)' de (b) indisi ise dalgacığın konumunu göstermektedir.

Fourier analizi, işareti farklı frekanslara sahip sinüslere ayırıp incelemektedir. Dalgacık analizi ise işareti ana dalgacığın kaydırılmış ve ölçeklendirilmiş biçimlerine açarak incelemektedir. Örnek dalgacık fonksiyonları Şekil 2.4. (a) ve (b)'de görülmektedir.



Şekil 2.3. Sonsuz sayıda olabilecek dalgacıklardan bazıları, Meyer dalgacığı ve (b) Meksika şapkası dalgacığı

2.3.2.1. Sürekli Dalgacık Dönüşümü (Continuous Wavelet Transform - CWT)

Dalgacık dönüşümü, KZFD' ne benzer şekilde yapılır. Bir anlamda, KZFD' deki pencere fonksiyonuna benzer bir fonksiyonla (dalgacık) işaret çarpılır ve dönüşüm zaman domeni işaretinin farklı bölümleri için ayrı ayrı gerçekleştirilir. Fakat KZFD ile dalgacık dönüşümü arasında iki önemli fark bulunmaktadır [57].

1) Pencerelemiş işaretin Fourier dönüşümü alınmaz ve böylece sinüzoide denk düşen tek bir tepe olarak görülecektir.

2) Dalgacık dönüşümünün en önemli özelliği her bir spektral bileşeni için dönüşüm hesaplanırken pencere genişliğinin değişmesidir.

Sürekli dalgacık dönüşümü, dalgacık fonksiyonu ψ ile $f(t)$ işaretinin iç çarpımı olarak yazılabilir.

$$C(\text{ölçek}, \text{konum}) = \int_{-\infty}^{\infty} f(t) \cdot \psi^*(\text{ölçek}, \text{konum}, t) dt \quad (18)$$

Eşitlik (18)' deki C, ölçek- a ve konuma- b bağlı bulunan dalgacık dönüşümü katsayılarıdır.

$f(t)$ analizi yapılacak işaret olsun. Ana dalgacık işlemde tüm pencereler için bir prototip olarak kullanılmak üzere seçilir. Bunun için değişik fonksiyonlar bulunmaktadır. Morlet dalgacığı veya Meyer dalgacığı bunun için seçilebilir. Ana dalgacık seçildiği zaman hesaplama işlemi $a=1$ ile başlar ve dalgacık dönüşümü tüm a değerleri (1 den küçük ve büyük) için hesaplanır. Bununla birlikte işarete bağlı olarak tüm a değerlerinin hesaplanması çoğu zaman gerekli değildir. Bunun için a' nın sonlu değer aralıklarında bu hesaplamalar yapılır.

Dalgacık $t=0$ zamanına karşılık gelen noktada işaretin başlangıcında bulunmaktadır. Ölçek "1" deki dalgacık fonksiyonu işaretle çarpılır ve ondan sonra tüm zaman üzerinde integral işlemi yapılır. Bundan sonra toplamların sonucu $1/\sqrt{a}$ sabiti ile çarpılır. Bu çarpma işlemi dönüştürülmüş işaretin her ölçekte aynı enerjiye sahip olması için yapılan enerji normalizasyon işlemidir. Sonuç transformasyon işleminin değeridir. $a=1$ ölçekteki dalgacık $t=b$ lokasyonu için b miktarı kadar sağa doğru kaydırılır ve zaman-frekans ekseninde $a=1$ ve $t=b$ de dönüşümün değeri yukarıdaki eşitlikten hesaplanır.

Bu prosedüre, dalgacık işaretin sonuna ulaşana kadar devam eder. $a=1$ ölçeği için zaman-frekans ekseninde noktaların bir satırı hesaplanmış olur. Bundan sonra a küçük bir

değerle arttırılır ve tüm a değerleri için yukarıdaki prosedür devam ettirilir. a'nın verilen bir değeri için tüm hesaplamalar zaman-frekans ekseninde bir satıra karşılık gelen yerleri doldurur. İstenen tüm a değerleri için hesap işlemleri tamamlandığında işaretin dalgacık dönüşümü hesaplanmış olur. Bu işlem ile ölçek ve pozisyonun bir fonksiyonu olan dalgacık katsayıları üretilir.

Sürekli dalgacık dönüşümü, bilgisayarda hesaplanırken ayrı olarak işlenir. Ancak, ayrı dalgacık dönüşümünden farkı ölçeğin ve kaymanın sürekli olmasıdır.

2.3.2.2. Ayrık Dalgacık Dönüşümü (Discrete Wavelet Transform - DWT)

Sürekli dalgacık dönüşümündeki işlem ve veri kapasitesi çok büyüktür. Bunun yerine işlem verimliliğini arttırmak için konum ve ölçeklerin ikili kuvvetleri alınır ve bu işleme ikili dalgacık (dyadic) dönüşümü denir.

1998'de Mallat, ikili dalgacık dönüşümünü sayısal süzgeçlerle gerçekleştirmiştir. Bu süzgeçler sayesinde dalgacık dönüşümü işlemi hızlandırılmıştır.

Birçok işaret için düşük frekans bilgileri işaretin en önemli kısmıdır. Diğer yandan, yüksek frekans kısmı ise ayrıntılardır (detail). Örneğin, insan sesinde yüksek frekansları ellediğimizde seste değişim olmasına rağmen kişinin ne söylediği hala anlaşılabilir. Ancak, düşük frekanslar elendiğinde anlamsız bir ses duyulur.

Dalgacık analizinde; yüksek ölçek katsayılarına “yaklaşıklık (approximation)”, düşük ölçek katsayılarına da “ayrıntı (detail)” katsayıları denir. Yüksek geçiren süzgecin çıkışı ayrıntı, alçak geçiren süzgecin çıkışı yaklaşıklık katsayılarını verir. Böylece işaret süzgeçlerden geçirilerek alt bantlarına ayrılır ve işaretin boyutunun değişmemesi için süzgeçlerin çıkışlarının örnek sayısı yarıya indirilir. Bu işlem kullanıcı tarafından belirlenen ölçeğe kadar devam eder.

2.3.2.3. Çoklu Çözünürlük Analizi (Multiresolution Analysis)

Yüksek frekanslarda iyi zaman çözünürlüğü ve zayıf frekans çözünürlüğü, alçak frekanslarda ise iyi frekans çözünürlüğü zayıf zaman çözünürlüğü vermesi için tasarlandı. Bu yaklaşım özellikle işaret kısa bir zaman aralığında yüksek frekans bileşenlerine sahipse

ve uzun zaman aralığında düşük frekans bileşenlerine sahipse anlamlı olmaktadır. Pratik uygulamalarda karşılaşılan işaretler genellikle bu türdendir.

2.3.2.5. Morlet Dalgacı

Bu tez çalışmasında kullanılan dalgacık türü olarak Morlet dalgacı seçilmiştir. Matematikte, Morlet dalgacı 1984 yılında Goupilaud, Grossmann ve Morlet tarafından formüle edilmiştir.

$$\psi_{\sigma}(t) = c_{\sigma} \pi^{\frac{-1}{4}} e^{\frac{-t^2}{2}} (e^{i\sigma t} - K_{\sigma}) \quad (19)$$

Burada $K_{\sigma} = e^{\frac{-\sigma^2}{2}}$ kabul edilebilirlik kriteri olarak tanımlanmaktadır c_{σ} ise normalizasyon sabitidir.

$$c_{\sigma} = (1 + e^{-\sigma^2} - 2e^{\frac{-3\sigma^2}{4}})^{\frac{-1}{2}} \quad (20)$$


Morlet dalgacığının fourier dönüşümü

$$\psi_{\sigma}\sigma(w) = c_{\sigma} \pi^{\frac{-1}{4}} (e^{\frac{-1(\sigma-w)^2}{2}} - K_{\sigma} e^{\frac{-w^2}{2}}) \quad (21)$$

Merkez frekansı (ω_{ψ}) $\psi_{\sigma}(w)$ ' in global maksimum yeridir.

$$(w_{\psi} - \sigma)^2 - 1 = (w_{\psi}^2 - 1)e^{-\sigma w_{\psi}} \quad (22)$$

σ parametresi, Morlet dalgacıklarında zaman ve frekans çözünürlükleri arasında değiş tokuşa izin verir. Genellikle koşul olarak $\sigma > 5$ kullanılır. $\sigma > 5$ koşulu altında Morlet dalgacığını frekansı alışılagelmiş olarak $w_{\psi} \cong \sigma$ seçilir.



Şekil 2.4. Morlet dalgacı

2.3.3. Filtreler

EEG ve ECoG işaretlerinin analizinde kullanılan iki önemli özellik vardır. Bunlar olay ilişkili potansiyeller (event-related potential –ERP) ve olay ilişkili senkronizasyon/desenkronizasyon (event-related synchronization/desynchronization –ERS/ERD)’ dur. ECoG işaretlerinin α , β , γ gibi frekans bandlarına ayrıldığı Bölüm 1.1.2.2.1.’ de belirtilmişti. Bu frekans bandlarına ait bilgileri elde etmek için sayısal filtreler kullanılır.

Bir sayısal filtre, transfer fonksiyonu veya eşdeğer fark eşitliği ile karakterize edilir. Doğrusal zamanla değişmeyen sayısal bir filtre için transfer fonksiyonu z-domeninde eşitlik (23) de verilmektedir. Nedensel ise aşağıdaki forma sahiptir.

$$H(z) = \frac{B(z)}{A(z)} = \frac{b_0 + b_1 z^{-1} + b_2 z^{-2} + \dots + b_N z^{-N}}{1 + a_1 z^{-1} + a_2 z^{-2} + \dots + a_M z^{-M}} \quad (23)$$

Filtrenin derecesi N veya M’ den daha büyüktür. İmpuls cevabı genellikle H(z) veya h(n) ile gösterilir ve Kroncker delta fonksiyonuna filtrenin vereceği cevabın bir ölçütüdür.

Bu form tipik olarak sonsuz impuls cevabı davranışına(IIR) sebep olan bir rekursif filtre içindir. Payda bir olursa bu form o zaman sonlu impuls (FIR) cevabı filtre içindir.


Verilen bir sayısal filtrenin davranışını analiz etmek için çok değişik matematiksel teknikler kullanılabilir. İlgilenilen frekans bandı için M ve N uzunluklu a ve b dizileri tasarlanır. Bu diziler Butterworth veya Chebyshev filtre tasarlama teknikleri kullanılarak elde edilebilir.

Paydanın a_k katsayıları geri besleme katsayılarıdır. Payın b_k katsayıları ileri besleme katsayılarıdır. Sonuç doğrusal fark denklemi

$$y[n] = -\sum_{k=1}^N a_k y[n-k] + \sum_{k=0}^M b_k x[n-k] \quad (24)$$

Bu eşitlik sonraki çıkışı $y[n]$ için daha önceki çıkışları $y[n-p]$, şu anki girişler $x[n]$ ve daha önceki girişlere $x[n-p]$ bağlı olduğunu göstermektedir.

Bu çalışmada band geçiren Butterworth filtre kullanılmıştır. Butterworth filtreler geçirim bandında son derece düz bir genlik cevabı ile karakterize edilirler. Butterworth filtreler geçirme bandı ve söndürme bandındaki monotonluk için dik bir azalmadan feragat ederler. Eğer Butterworth filtrelerin bu düzgünlüğü gerekmiyorsa eliptik veya Chebyshev filtreler genellikle daha düşük dereceli bir filtre ile daha dik bir söndürme karakteristiği sağlayabilirler. Şekil 2.5.' de filtrelere ait karakteristikler görülmektedir.



Şekil 2.5. Bazı sayısal filtre karakteristikleri

Zaman domeni filtrelere bir alternatif olarak frekans domeni filtre kullanılabilir. Zaman domeninden FFT kullanılarak frekans domenine geçilir. İstenilen frekans aralığı frekans domeninde seçilerek ve ters FFT ile tekrar zaman domenine dönülür.

2.3.4. Sınıflandırma

Sınıflandırma yöntemlerinin amacı veri kümesini sahip olduğu özelliklere göre sınıf ya da kategorilere ayırmaktır. Sınıflandırma yöntemleri eğitilmiş (supervised) ve eğitimsiz (unsupervised) sınıflandırma olmak üzere ikiye ayrılmaktadır. Sınıflandırma işleminde oluşacak hatayı (yanlış sınıflandırma) minimum yapacak olan sınıflandırma yönteminin

seçilmesi gerekmektedir. Sınıflandırma yöntemlerinde sınıflandırma işlemleri öncesinde veri boyutunun azaltılması yoluna gidilmekte, bunun için de öznitelik çıkartımı ve öznitelik seçimi yöntemlerinden faydalanılmaktadır.

2.3.4.1. Eğitimsiz (Unsupervised) Sınıflandırma

Eğitimsiz sınıflandırma, verinin, kullanıcı müdahalesi olmadan algoritmalar vasıtasıyla otomatik olarak kümelendirilmesi temeline dayanmaktadır. Eğitimsiz sınıflandırma yöntemlerinde, sınıflandırılacak verinin tüm değerleri kullanılarak kümelemeler elde edilmektedir [45]. Denetimsiz sınıflandırma yöntemleri içerisinde en yaygın olarak kullanılan yöntem K-ortalama (K-means) yöntemidir [46].

2.3.4.2. Eğitilmiş (Supervised) Sınıflandırma

Eğitim ve test veri kümelerinden oluşan denetimli sınıflandırma yöntemlerinde verinin hangi sınıflara ayrılacağı, ya da veriden hangi sınıfların elde edilmek istenildiği önceden bilinmektedir [47]. Eğitilmiş sınıflandırma için eğitim ve test verileri bulunmaktadır. Eğitim aşamasında eğitim verileri kullanılarak geliştirilen algoritma sayesinde daha önceden görülmemiş test verilerinin hangi sınıfa ait olduğu bulunmaktadır. Test aşamasında yeni giriş verileri, eğitim işlemi sonucunda elde edilen parametreler kullanılarak sınıflandırma işlemi gerçekleştirilmektedir. Test (sınıflandırma) aşamasında eğitim verileri artık kullanılmamakta sadece elde edilen parametreler kullanılmaktadır. İkili sınıflandırma problemi için eğitim seti $(x_1, r_1), \dots, (x_i, r_i) \in \mathbb{R}^n \times \{+1, -1\}$ kullanılarak oluşturulan $f: \mathbb{R}^n \rightarrow \{+1, -1\}$ sayesinde yeni giriş değerlerinin hangi sınıfta olduğu tahmin edilmektedir. Burada x_i eğitim kümesindeki i . veriyi ve r_i bu verinin ait olduğu sınıfın bilgisini göstermektedir. İkili sınıflandırma problemi için r_i , +1 ya da -1 olarak düşünülmektedir [48].

2.3.4.3. Doğrusal Ayırma Analizi

Boyut indirgemede kullanılan en yaygın yöntem Temel Bileşen Analizidir. Bu teknik daha sonra üzerine izdüşümü yapacağı yönler için verideki en büyük varyansı bulmaya

çalışır. Bu yolla, bazı gürültülü yönleri çıkartarak verinin daha düşük boyutlu gösterimini elde ederiz. TBA eğitimsiz (unsupervised) bir yöntemdir yani verinin etiket bilgilerini içermemektedir. Etiket bilgilerini içermediğinden dolayı sınıflandırmada bu kötü bir izdüşümü olacaktır. Bu bilgi verici izdüşümü bulmak için etiket bilgilerini nasıl kullanacağız önemli olmaktadır. DAA bunun için aşağıdaki formülde Fisher kriteri J 'yi maksimum yaparak w vektörünü bulmaya çalışmaktadır. DAA, çoğunlukla sınıflandırma, öznitelik çıkartma ve boyut indirgemede kullanılmaktadır.

$$J(w) = \frac{w^T S_B w}{w^T S_W w} \quad (25)$$

J ; sınıf içi dağılımı minimize yaparken sınıflar arası dağılımı maksimize etmek için belirlenir.

T ; transpoz

Burada S_B sınıflar arasındaki dağılım matrisidir ve S_W ise sınıf içerisindeki dağılım matrisidir. Dağılım matrislerinin tanımları şu şekildedir.

$$S_B = \sum_c N_c (\mu_c - \bar{x})(\mu_c - \bar{x})^T \quad (26)$$

$$S_W = \sum_c \sum_{i \in c} (x_i - \mu_c)(x_i - \mu_c)^T \quad (27)$$

$$\mu_c = \frac{1}{N_c} \sum_{i \in c} x_i \quad (28)$$

μ_c ; c sınıfındaki örneklerin ortalaması

$$\bar{x} = \frac{1}{N} \sum_i x_i = \frac{1}{N} \sum_c N_c \mu_c \quad (29)$$

Burada N_c , c sınıfındaki durum sayısıdır.

Genelde S_B iki sınıf için $S'_B = (\mu_1 - \mu_2)(\mu_1 - \mu_2)^T$ olarak ifade edilmektedir. Bu sınıf 1 in dağılımının sınıf 2 ye göre dağılımıdır. $S_B = \frac{N_1 N_2}{N} S'_B$ olarak gösterilebilir. Burada J fonksiyonunu bir sabit sayıyla çarpmak, sonucu değiştirmeyecektir.

Toplam dağılım,

$$S_T = \sum_i (x_i - \bar{x})(x_i - \bar{x})^T \quad (30)$$

$$S_T = S_W + S_B \quad (31)$$

Bunu J fonksiyonunda yerine yazarsak

$$J(w) = \frac{w^T S_T w}{w^T S_W w} - 1 \quad (32)$$

Böylece sınıf içi dağılımları minimize ederken verinin toplam dağılımını maksimize yapıyor olarak yorumlayabiliriz.

$w \rightarrow \alpha w$ vektörü olarak tekrar ölçeklendirme yaptıktan sonra elde edilen değişken J olarak bilinir ve bu önemli bir sonuçtur. w skaler bir sayı olduğu için, w değişkenini basitçe paydası $w^T S_W w = 1$ olacak şekilde seçebiliriz.

J fonksiyonunu maksimize etme işlemini aşağıdaki eşitliklerle ifade edebiliriz.

$$\min_w -\frac{1}{2} w^T S_B w \quad (33)$$

$$w^T S_W w = 1 \quad (34)$$

Lagrange göre

$$Lp = -\frac{1}{2} w^T S_B w + \frac{1}{2} \lambda (w^T S_W w - 1) \quad (35)$$

Aşağıdaki denklem çözüm için elde edilmeli

$$S_B w = \lambda S_W w \Rightarrow S_W^{-1} S_B w = \lambda w \quad (36)$$

$S_W^{-1} S_B$ matrisi simetrik olsa bu denklem özdeğer eşitliğine benzemektedir

Aşağıdaki dönüşümü uygularsak S_B yi $S_B^{\frac{1}{2}} S_B^{\frac{1}{2}}$ olarak yazabiliriz.

$$S_B = U \Lambda U^T \rightarrow S_B^{\frac{1}{2}} = U \Lambda^{\frac{1}{2}} U^T \quad (37)$$

$V = S_B^{\frac{1}{2}} w$ olarak tanımlayarak

$$S_B^{\frac{1}{2}} S_W^{-1} S_B^{\frac{1}{2}} v = \lambda v \quad (38)$$

Simetrik ve pozitif tanımlı $S_B^{\frac{1}{2}} S_W^{-1} S_B^{\frac{1}{2}}$ matrisi için bu bir özdeğer problemi olmaktadır.

$w_k = S_B^{-2} v_k$ Çözümüne benzer şekilde v_k ve λ_k çözümlerini bulabiliriz.

Çözümleri J içerisinde kullanırsak

$$J(w) = \frac{w^T S_B w}{w^T S_W w} = \lambda_k \frac{w_k^T S_W w_k}{w_k^T S_W w_k} = \lambda_k \quad (39)$$

DAA farklı sınıf örneklerin ayırımında kullanılmasına rağmen genelde iki farklı sınıf verinin ayırımında kullanılmaktadır. Fisher ayırma çok boyutlu uzayda iki sınıf arasında doğrusal ayırma için kullanılan bir methodtur. Her dağılımın sadece bir ve ikinci momentlerine dayalı olduğundan hesaplaması son derece hızlıdır. Doğrusal ayırma analizi (DAA) oldukça az işlem gerektirdiği için online BBA sistemlerine uygundur. Bundan dolayı düşünsel tabanlı BBA sistemlerinde başarıyla kullanılmaktadır [49]. Aynı sınıfa ait olmayan verilerin ayırımını maksimum yapmaya çalıştığı için bu DAA' ni oldukça güvenilir ve sağlam yapmaktadır. Eğer iki sınıf eşit varyanslı gauss değil ise bu ayırım için minimum sınıflandırma hatası vermeyeceği için iyi bir sonuç vermeyecektir. Başlıca sakıncası kompleks doğrusal olmayan EEG ve ECoG verilerinde DDA' nin doğrusallığı çok iyi sonuçlar vermemektedir [50].

2.3.4.4. Destek Vektör Makineleri

Destek Vektör Makineleri (DVM), temeli istatistiksel öğrenme teorisine dayanan, güçlü ve sık kullanılan öğrenme algoritmalarıdır. DVM algoritmaları AT&T Bell Laboratuvarlarında Vapnik ve arkadaşları tarafından geliştirilmiştir. Görüntülerin sınıflandırılması, yüz tanıma, ses tanıma ve kanser hücrelerinin tanınması [51] gibi farklı alanlarda örüntü tanıma uygulamalarında kullanılmıştır ve yapısal risk minimizasyonu prensibi ile formülize edilmiştir. Yapısal risk minimizasyonu genelleştirme hatasındaki üst sınırı en küçük değerine getirir. DVM uygulamaları diğer geleneksel metotlardan daha iyi sonuçlar verdiği için dolayı oldukça popülerdir.

DVM çok basit bir fikir üzerine kurulmuştur: Örüntü vektörlerinin en iyi ayırma hiper düzlemini (en büyük marjin hiper düzlemi) oluşturacak çok boyutlu öznitelik uzayına eşlenmesi ve sınıflandırılmasıdır. Hiper düzlemleri kullanarak sınıfları ayıran sınıflandırıcılar doğrusal ayırıcılar olarak bilinirler. Bundan dolayı DVM de bu gruba girmektedir. Destek vektör makineleri temelde doğrusal olarak ayırt edilebilen iki sınıf

problemlerin çözümünden yola çıkarak doğrusal olarak ayırt edilemeyen veya çoklu sınıf problemlerin çözümü için genelleştirilebilir.



Şekil 2.6. Destek Vektör Makineleri giriş uzayını yüksek boyutlu bir öznitelik uzayına eşleştirmektedir

2.3.4.4.1. Doğrusal Olarak Ayrılabilen Veriler

Eğitim verileri ($\{x_i, i = 1, \dots, l\}$), $y_i = +1$ ve $y_i = -1$ etiketleriyle sınıf 1 veya sınıf 2 ye ait olduğu ikili bir sınıflandırma işlemini ele alalım. Doğrusal ayırma fonksiyonunu eşitlik (40)' daki gibi belirtelim.

$$g(x) = w^T x + b \quad (40)$$

Burada w hiper-düzlemin normali ve b eğilim değeri olarak adlandırılır.

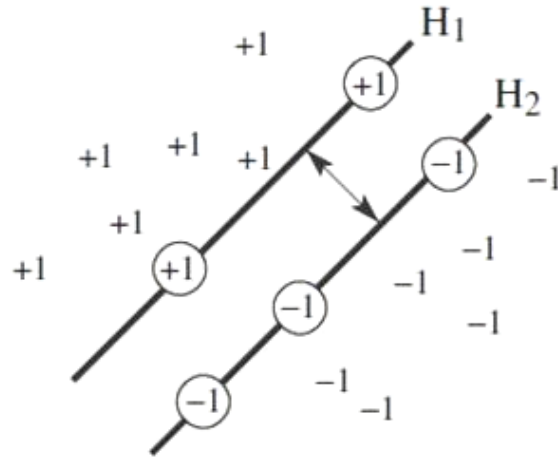
Bu durumda karar kuralı aşağıdaki gibidir.

$$w^T x + b \begin{cases} > 0 \\ < 0 \end{cases} \Rightarrow x \in \begin{cases} \text{sınıf 1, karşı düşen sayısal değer } y_i = +1 \\ \text{sınıf 2, karşı düşen sayısal değer } y_i = -1 \end{cases} \quad (41)$$

Böylece tüm eğitim verileri (42) koşuluna göre doğru sınıflandırılmış olmaktadır

$$y_i (w^T x + b) > 0 \quad (42)$$

w ve b sonsuz sayıda değer alabileceğinden birden fazla hiper düzlem bulunmaktadır. Fakat en büyük marjin bir tanedir ve bizim amacımız onu tespit etmektir. Marjinin büyüklüğü oranında ayırma hiper düzlemi ile tanımlanan doğrusal sınıflandırıcının genelleştirme hatasının da o kadar küçük olacağı varsayılmıştır.



Şekil 2.7. Kuramsal hiper düzlemler ve en büyük marjin gösterimi

Şekil 2.7.' de her iki veri kümesi için kuramsal hiper düzlemler gösterilmektedir. $H_1 = w^T x + b = 1$ ve $H_2 = w^T x + b = -1$ düzlemlerine kuramsal hiper düzlem denmektedir. En büyük marjin $w^T x + b = 1$ ve $w^T x + b = -1$ arası mesafedir.

$$\frac{2}{\|w\|} = \frac{2}{\sqrt{w^T w}} \quad (43)$$

$$w^T x_i + b \geq +1, y_i = +1 \text{ için} \quad (44)$$

$$w^T x_i + b \geq -1, y_i = -1 \text{ için} \quad (45)$$

Kuramsal hiper düzlemlerin üzerine düşen noktalar destek vektörleri olarak bilinir. Destek vektörleri şekilde yuvarlak içerisinde alınmışlardır.

Marjini maksimize yapmak için w minimize yapılır. Bu marjı maksimize yaparken kullanılan w ve b değerleri ve x giriş verisi olmak üzere, $w x_i + b$ denkleminin işaretini bulmaya çalışılır. Bu bir kuadratik programlama problemidir [63].

$$\min_{w,b} \frac{1}{2} w^T w \quad (46)$$

$$y_i (w^T x_i + b) \geq +1, i = 1, \dots, l \quad (47)$$


Karar fonksiyonu

$$f(x) = \text{sign}(w^T x + b) \quad (48)$$

x test verisi ve w ile b birden fazla değer alabilir.

2.3.4.4.2. Doğrusal Olarak Ayrılamayan Veriler

Pratik uygulamalarda birçok problemde sınıflar arasında doğrusal sınır bulunmamaktadır, bundan dolayı bu tip problemlerde en uygun ayırma hiper düzlemini bulmaya çalışmak doğru olmayacaktır. Bu durumda girdi uzayından öznitelik uzayına geçmek gerekir. Öznitelik uzayı $\phi(x) = (\phi_1(x), \phi_2(x), \dots)$ şeklinde olduğunu düşünürsek bu öznitelik vektörü çok yüksek boyutlu olacaktır.



Şekil 2.8. Öznitelik uzayında doğrusal ayırma

Şekil 2.8' de görüleceği üzere girdi uzayında doğrusal olarak ayrılamayan veri daha yüksek boyutlu bir uzayda görüntülenir. Bu uzay öznitelik uzayı olarak adlandırılır.

Bu çeşit problemler için doğrusal olmayan verileri sınıflandırmaya yönelik negatif olmayan bir ζ_i değişkeni kullanılması Cartes ve Vapnik tarafından önerilmiştir. Bu değişken ($\zeta_i, i=1, \dots, \ell$) olmak üzere ℓ adet olarak verilirse

$$w^T x_i + b \geq +1 - \zeta_i, y_i = +1 \text{ için} \quad (49)$$

$$w^T x_i + b \leq -1 + \zeta_i, y_i = -1 \text{ için} \quad (50)$$

Denklemini elde ederiz. Böylece doğrusal yöntemden doğrusal olmayan yönteme geçiş yapabilmek için giriş verilerini giriş verilerini çok boyutlu öznitelik uzayına eşleştirme yapmış oluruz. Ayırma hiper düzlemi tarafından yanlış sınıflandırılan her bir veri için $\zeta_i > 1$ olmak zorundadır. $\sum_i \zeta_i$, eğitim hataları sayısının üst sınırıdır. Dolayısıyla hata maliyetlerini arttırmak için hedef fonksiyona kullanıcı tarafından seçilecek bir

düzenleyici C parametresi eklenmiştir, C parametresinin değerinin yüksek olması hatalara daha yüksek ceza atanmasına yol açacaktır. Yukarıdaki sınırlamalara göre (51) ifadesini minimize edersek.

$$\frac{1}{2}w^T w + C \sum_i \zeta_i \quad (51)$$

Lagrange' nin birincil biçimi denklem (52)' deki şekle dönüşmüş olmaktadır.

$$L(w, b, \alpha) = \frac{1}{2}w^T w + C \sum_i \zeta_i - \sum_{i=1}^n \alpha_i (y_i(w^T x_i + b) - 1 + \zeta_i) - \sum_{i=1}^n r_i \zeta_i \quad (52)$$

α_i pozitif Lagrange çarpıcılar olmak üzere ve $r_i; \zeta_i$ değerlerinin pozitif olmasını sağlamak için eklenmiştir. Çözümü biraz daha kolaylaştırmak için yukarıdaki Lagrange problemi dual problemine dönüştürülmelidir. Bunu için (52) ile gösterilen Lagrange denkleminin (w, b)'ye göre türevi alınarak aşağıdaki tanımlamalar elde edilmektedir.

$$\sum_{i=1}^n \alpha_i y_i = 0 \quad (53)$$

$$W = \sum_{i=1}^n \alpha_i y_i x_i \quad (54)$$

$$C - \alpha_i - r_i = 0 \quad (55)$$

Bu sonuçlar Lagrange birincil biçiminde yerine konursa Lagrange dual biçimi elde edilir.

$$L_D = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j y_i y_j x_i^T x_j \quad (56)$$

$$0 \leq \alpha_i \leq C \quad \text{ve} \quad \sum_{i=1}^n \alpha_i y_i = 0 \quad (57)$$

Gerekli parametreler L_D en büyük yapılarak hesaplanır. Doğrusal olmayan destek vektör makineleri ise veriyi öncelikle farklı bir uzaya eşlemekte ve sınıflandırma işlemini bu yeni (genellikle daha yüksek boyutlu) öznelik uzayında gerçekleştirmektedir. Çoğu zaman eşleme fonksiyonları bilinmesine gerek yoktur, bunun yerine bir çekirdek fonksiyonu kullanılır.

Sonuç olarak destek vektör makinesi aşağıdaki eşitlik (58) ile ifade edilebilir:

$$f(x) = \text{sign}(\sum_i \alpha_i y_i k(x_i, x) + b) \quad (58)$$


Parametreler ise aşağıdaki fonksiyon en büyük yapılarak bulunur,

$$L_D = \sum_{i=1} \alpha_i - \frac{1}{2} \sum_i \sum_j \alpha_i \alpha_j y_i y_j k(x_i, x_j) \quad (59)$$

$$0 \leq \alpha_i \leq C \text{ ve } \sum_i \alpha_i y_i = 0 \quad (60)$$

2.3.4.4.3. Doğrusal Olmayan Destek Vektör Makineleri

Destek vektör makinelerini doğrusal olarak ayırt edilemeyen sınıflarda kullanmak için kernel (çekirdek) fonksiyonları devreye girer ve n boyutlu bir veri kümesi $m > n$ olmak üzere m boyutlu yeni bir veri kümesine dönüştürülerek, yüksek boyutta doğrusal sınıflandırma işlemi gerçekleştirilir.



Şekil 2.9. DVM sınıflandırma modelleri (a) doğrusal (dot) kernel, eşitlik (60); (b) 2.dereceden polinomial kernel, eşitlik (61)

Çekirdek fonksiyonları DVM algoritmasında önemli rol oynar. Çeşitli çekirdek fonksiyonları tanımlanmıştır. Bunlardan bazıları aşağıda sunulduğu üzere, lineer, polinom, radyal tabanlı fonksiyon ve sigmoid kernel olmak üzere dört temel grup altında toplanabilir. Lineer kernel, radyal tabanlı kernelin özel bir hali gibi düşünülebilir. Ayrıca, Keerthi and Lin (2003) belirli parametreler için sigmoid kernelin radyal tabanlı kernel gibi bir davranış gösterdiğini ifade etmişlerdir. Literatürde uzaktan algılama uygulamaları için radyal tabanlı kernelin en iyi sonuçları verdiği ifade edilmektedir [58].

6Doğrusal Kernel:

$$K(x_i, x_j) = x_i^T x_j \quad (61)$$

Polinomial Kernel:

$$K(x_i, x_j) = (1 + x_i^T x_j)^d \quad , d \text{ polinom derecesi} \quad (62)$$

Gauss (radyal tabanlı kernel):

$$K(x_i, x_j) = e^{-\frac{|x_i - x_j|^2}{2\sigma^2}} \quad , \sigma \text{ Gauss Kernelinin Boyutu} \quad (62)$$

Sigmoid Kernel:

$$K(x_i, x_j) = \tanh(b(x_i^T x_j) + r) \quad , b \text{ ve } r \text{ kernel parametreleri} \quad (63)$$

Doğru çekirdek fonksiyonun seçimi sınıflandırma işleminin başarısında oldukça etkilidir. DVM temelde ikili sınıflandırıcı olduğundan çoklu sınıf problemleri basit olarak veri kümesinin değişik şekillerde ikiye bölünmesi, her bir ikili veri kümesi için DVM algoritmasının çalıştırılması ve sonuçların birleştirilmesi ile çözümlenir.

Destek vektör makineleri bir kernel fonksiyonu yardımıyla doğrusal olmayan dönüşümler yapılabilen ve bu şekilde verilerin yüksek boyutta doğrusal olarak ayrılabilmesine imkan sağlamaktadır [59]. Sonuç olarak; doğrusal olarak ayrılabilen iki sınıflı bir problemde iki sınıfın birbirinden ayrılması ile ilgili karar kuralı (64) eşitliği şeklinde yazılabilir [60].

$$f(x) = \text{sign}(\sum \lambda_i y_i \phi(x) \cdot \phi(x_i) + b) \quad (64)$$

2.3.4.5. k- En Yakın Komşuluk Yöntemi

k-en yakın komşuluk algoritması parametrik olmayan öğrenme algoritmalarından biridir. Eğitim veri kümesine ait örnekler sınıf etiketleriyle birlikte verilmekte ve sınıflandırıcı bu eğitim verileriyle eğitilerek daha önce karşılaşmadığı bir örneğin sınıfını tahmin etmek için kullanılır. k-en yakın komşuluk uygulaması yeni sorgu örneğini sınıflandırmak için kullanılan bir komşuluk sınıflandırma algoritmasıdır. Bir sorgu örneği

verildiği zaman, bu sorgu noktasına en yakın k tane eğitim noktası bulunur. Sınıflandırma ise bu k tane nesnenin en fazla olanı ile yapılır. k-en yakın komşuluk basit, verimli ve sağlamlığından dolayı sınıflandırma işlemlerinde sıklıkla kullanılan yöntemlerden biridir. Çoğu sofistike makine öğrenme algoritmalarına kıyasla oldukça başarılı sonuçlar vermektedir [52]. İki örnek arasındaki yakınlık veya uzaklıkları ölçen bir uzaklık fonksiyonu esasına dayanmaktadır. x ve y örnekleri arası uzaklık fonksiyonu olarak genellikle standart Euclidean uzaklığı $d(x,y)$ kullanılmaktadır. Genelde ölçüt olarak Euclidean uzaklığının kullanımı yaygınsa da problemimize göre alternatif başka ölçütlerin kullanımı ile daha iyi sonuçların alınabileceği unutulmamalıdır. d boyutlu örüntüler için genel bir ölçüt sınıfı Minkowski ölçütüdür:

$$L_k(a_i(x), a_i(y)) = \left(\sum_{i=1}^d |a_i(x) - a_i(y)|^k \right)^{1/k} \quad (65)$$

$a_i(x)$; x örneğine ait öznitelik vektörü

$a_i(y)$; y örneğine ait öznitelik vektörü

Bu ifade L_k norm olarak da adlandırılmaktadır. Buradan, Euclidean uzaklığı L_2 norma, Manhattan uzaklığı da L_1 norma karşı düşer.

x örneğinin sınıfı $c(x)$ ile gösterilirse

$$c(x) = \arg \max_{c \in C} \sum_{i=1}^k \delta(c, c(y_i)) \quad (66)$$

Burada y_1, y_2, \dots, y_k x örneğinin k tane en yakın komşuları

Eğer $c = c(y_i)$ ise $\delta(c, c(y_i)) = 1$ olur ve diğer durumlarda $\delta(c, c(y_i)) = 0$ dır.

k-en yakın komşuluk algoritmasının performansı öncelikli olarak uzaklık mesafesine bağlı olmasının yanında k değerinin seçimine de bağlıdır. k değerinin seçilmesi kolay değildir. Genellikle k değerinin yüksek seçilmesi gürültüye karşı daha duyarsız yapmakta ve sınıflar arası sınırları daha yumuşatmaktadır.

Gürültülü eğitim dokümanlarına karşı dirençlidir. Eğitim dokümanları sayısı fazla ise etkilidir. Bunlara karşılık k parametreye ihtiyaç duyar. k-en yakın komşuluk algoritması bir tembel öğrenme örneğidir. Tembel öğrenme basitçe eğitim sırasında eğitim verilerini saklar ve sınıflandırma zamanına kadar öğrenimini geciktirir. Uzaklık bazlı öğrenme algoritması, en iyi sonuçları elde etmek için, hangi uzaklık tipinin ve hangi niteliğin kullanılacağı konusunda açık değildir. Bu çalışmada Kosinüs uzaklığına dayalı en yakın komşuluk yöntemi uygulanmıştır. Genel formülü aşağıdaki eşitlik (67)' de verilmiştir.

$$\cos(q, r) = d_i = \frac{\sum_y q(y).r(y)}{\sqrt{\sum_y q(y)^2.r(y)^2}} \quad (67)$$

Burada $q(y)$ öznitelik uzayında eğitim noktalarını, $r(y)$ test noktalarını, d_i ($i=1,2,\dots,\infty$) i. denemeye ait uzaklığı belirtir. Test örneği verildiğinde en düşük d_i değerine karşı gelen eğitim örneği bulunur ve sınıfı o test örneği için seçilir.

2.3.5. Bilgi Transfer Hızı

BBA teknolojisinin yaygınlaşması ve daha fazla gelişmesi için bazı konular çok önemlidir. Bilgi transfer hızı bu konulardandır. Şu anki BBA sistemleri oldukça düşük band genişliğine sahip olmakla birlikte bu cihazların en iyisi 5-25 bit/dk maksimum bilgi transfer hızına sahiptir [53]. Bu hızda bilgisayara bir kelime bile yazmak dakikalar alabilmektedir. Eğer bu hız artırılırsa BBA sistemleri hastalara çevreleriyle interaktif olabilmesi için daha kullanışlı bir yol sağlayabilecektir. Uygulamanın tipine bağlı olarak sistemden farklı özellikler beklenir. Bir protezi kontrol etmek için minimum hata oranıyla birlikte kararlı bir kontrol işareti kullanışlı bir yol olacaktır [49]. Bu durumda sistemin hızı daha az önemlidir. Eğer bir kişi sanal klavye uygulamasında harfleri seçerken veya heceleme cihazında işlem yaparken karar hızı önemli bir konu olacaktır. Bu açıdan karar hızı BBA sisteminde bir karar oluşturmak için kullanıcıya verilen süreyi ifade eder.

İletişim sistemlerinin standart bir ölçüsü bit hızıdır. Bit hızı birim zamanda iletilen bilgi miktarıdır. Bit hızı hem karar hızına (deneme uzunluğu) hem de sınıflandırma doğruluğa bağlıdır.

Shannon Teoremine göre bit hızı eşitlik (68)' de verilmektedir.

$$B = \log_2 N + P \log_2 P + (1 - P) \log_2 \left[\frac{1-P}{N-1} \right] \quad (68)$$

N: farklı durum sayısı

P: sınıflandırma doğruluğu

$$ITR(\text{bit/dk}) = \left[\log_2 N + P \log_2 P + (1 - P) \log_2 \left[\frac{1-P}{N-1} \right] \right] \frac{60}{D} \quad (69)$$

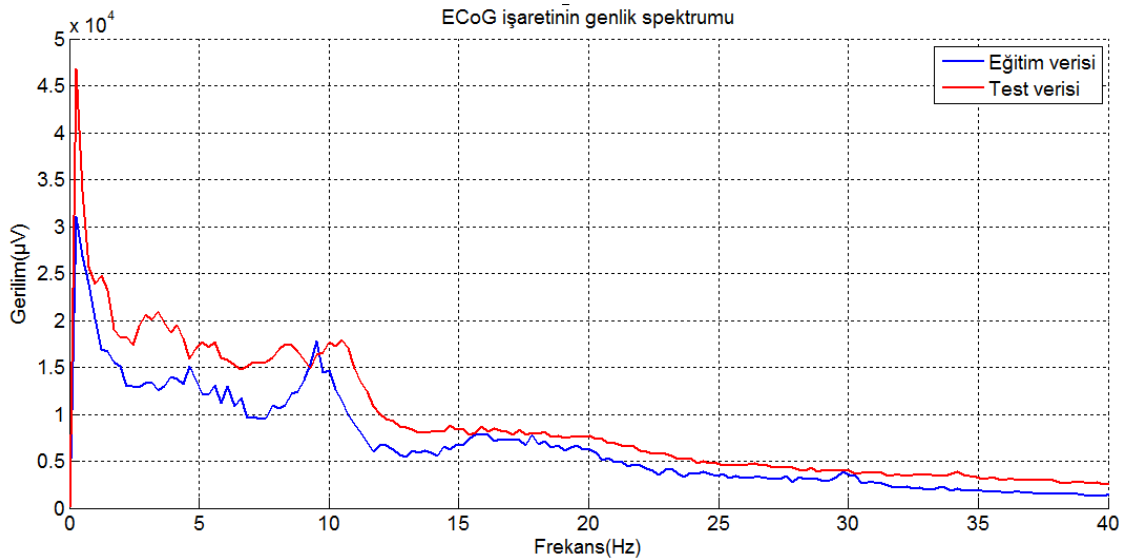
D: karar hızı veya deneme uzunluğu (sn)

BBA sistemlerinin performansı doğruluk ve bit hızı (bit/dk) olarak ölçülmektedir. ITR doğrudan deneme uzunluğundan etkilenmektedir. Bundan dolayı maksimum ITR sağlandığı bir kritik deneme uzunluğu olmak zorundadır. Bizim amacımız en yüksek transfer hızı için deneme uzunluğunun ne olacağı hakkındadır.

2.4. Öznitelik Çıkarma Çalışmaları ve Sınıflandırma

Bir hareketin yapılması veya düşünel olarak gerçekleştirilmesi beyinde benzer değişikliklere neden olduğu bilinmektedir [54]. Bu elektro-fizyolojik özellikler düşünel parmak ve dil hareketlerinin sınıflandırılmasında kullanılabilir.

Bu çalışmada kullanılan veri kümesinin anahtar konusu bir hafta aralıklarla oluşturulan eğitim ve test verilerinin doğru bir şekilde sınıflandırılmasıdır. Farklı oturumlarda oluşturulan eğitim ve test verileri farklı değişiklikler gösterebilir. Şekil 2.10.'da eğitim ve test verilerine ait grafik gösterilmektedir. Grafikte eğitim ve test verilerine ait tüm denemelerin ortalama genlik spektrumları gösterilmektedir. Eğitim ve test verilerinin grafikleri incelendiğinde test verilerinin genlik spektrumunun daha yüksek olduğu görülmektedir. Bu durum deneğin beyin faaliyetinin eğitim ve test oturumları için değiştiğini göstermektedir.

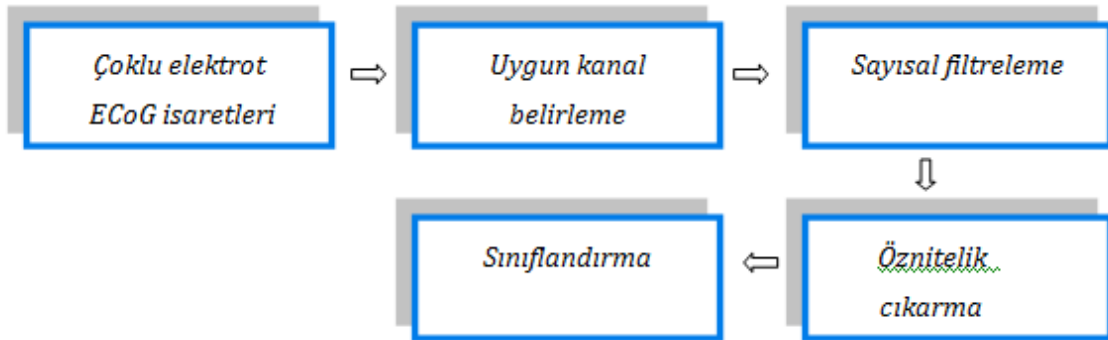


Şekil 2.10. Eğitim ve test veri kümesine ait tüm denemelerinin ortalama genlik spektrumları (38. kanal)

Kişinin beyin elektriksel aktivitesinin uzamsal dağılımı iki oturumda değişmezse, sadece genlikte bir artış veya azalış olursa bunun bir normalizasyon problemi oluşturacağı ve bu durumun normalizasyon işlemi yapılarak giderileceği göz önüne alınarak çalışmalar yapıldı.

Her bir deneme için iki sınıf arasında ayırımın yapılabilmesi için işaretlere ait özniteliklerinin çıkartılması gerekir. Bundan dolayı BCI Competition III Data Set 1' de verilen eğitim kümesine ait 278 adet denemeyi verilen eğitim etiketlerine göre düşünsel sol küçük parmak hareketi (DPH) denemeleri ve düşünsel dil çıkarma hareketi (DDH) denemelerine ayırdık. Eğitim verilerinin iki sınıfa $DDH_{(139|64|3000)}$ ve $DPH_{(139|64|3000)}$ ayrılmış şekli; burada 139 deneme sayısı, 64 kanal sayısı ve 3000 üç saniye boyunca alınan örnek sayısını ifade etmektedir. 100 adet test denemesinin ne olduğunu bilmiyoruz. Amacımız bu eğitim verilerinden her bir düşünsel harekete ait öznitelikleri çıkararak bunlarla sınıflandırıcıya eğitmek ve bulunan sınıflandırma parametrelerini test verilerinin sınıflandırılması için kullanmaktır.

Düşünsel parmak hareketi ve düşünsel dil hareketi durumlarında kayıt edilen ECoG işaretlerinin sınıflandırılması için kullanılan yöntem Şekil 2.11.' de gösterilen adımlardan oluşmaktadır.



Şekil 2.11. ECoG verilerinin sınıflandırılmasında kullanılan akış diyagramı

Kanal seçimi: Çoklu elektrot ECoG verileri için öznitelik çıkarmada uygun kanalların belirlenmesi

Frekans bandı seçimi: Düşünsel hareketle ilgili frekans bandındaki bilgilerin çıkarılması için sayısal filtre kullanılması

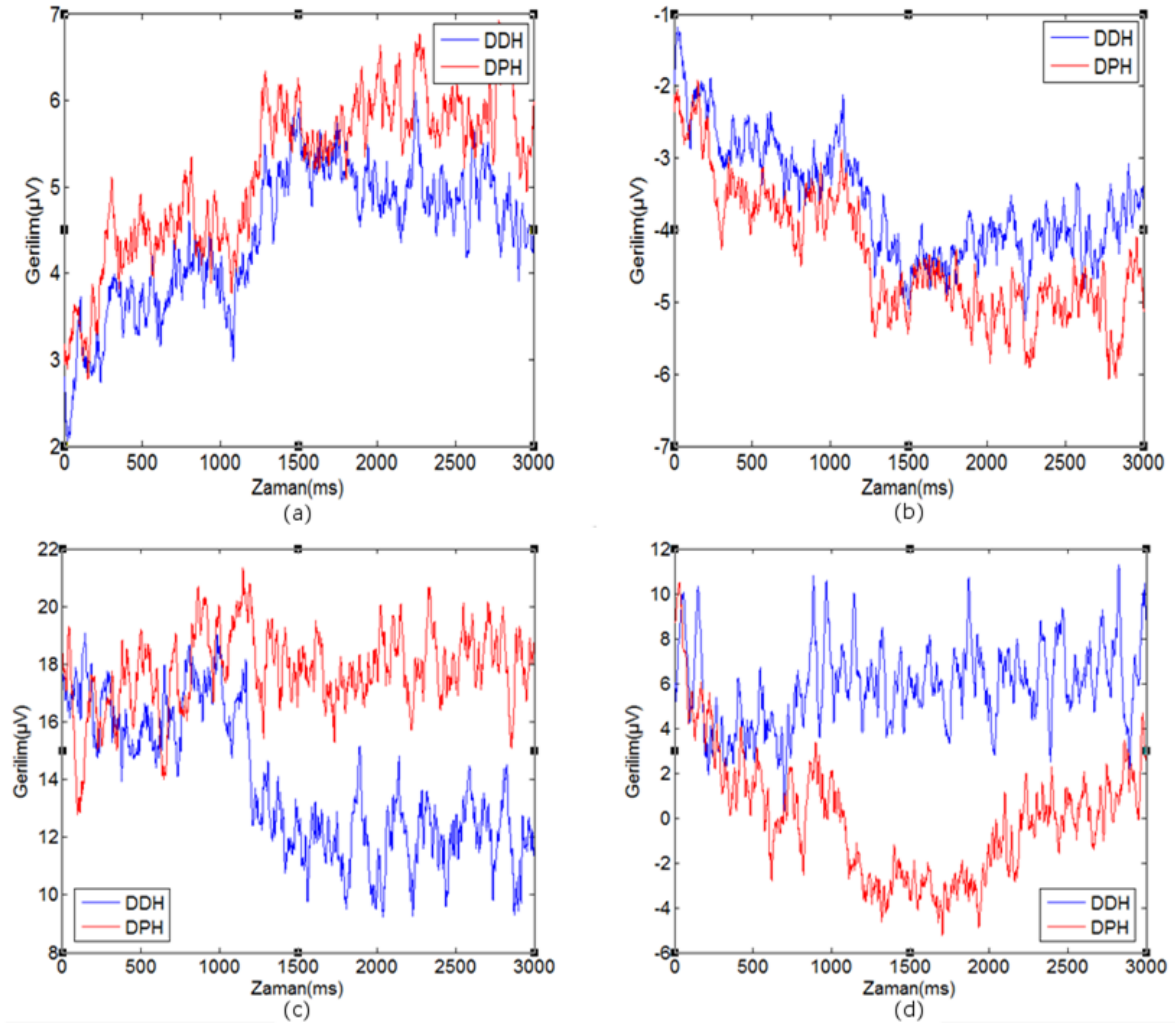
Öznitelik Çıkarma: Dalgacık dönüşümü katsayılarını kullanarak öznitelik çıkarma

Sınıflandırma: Çıkarılan öznitelik vektörlerini kullanarak KNN, DVM ve DAA ile sınıflandırma işleminin yapılması

2.4.1. Görsel Olarak Kanal Seçimi

Çoklu elektrot kullanılarak kaydedilen ECoG verileri incelenirken öznitelik çıkarma işlemi için uygun elektrotların seçimi önemli bir konudur. Beynin farklı bölgeleri farklı görevler için daha duyarlı olmaktadır. Bundan dolayı tüm kanalların verilerini kullanmak yerine uygun kanalların seçilerek bunlara ait verilerin kullanılması ile özniteliklerin çıkarılmasını daha doğru olacaktır. Böylece tüm kanallar için gelecek işlem yükünden kaçınılmış olur.

Öznitelik çıkarmada kullanılacak uygun kanalları belirlemek için, eğitim verilerine ait kanalların zaman domeni ve frekans domeni ortalamalarına bakılarak farklılık gösteren kanallar belirlenebilir. Brett D. Mensh ve diğerleri EEG işaretleriyle ilgili olarak yaptıkları çalışmalarında kanalların frekans bandındaki durumlarını inceleyerek farklılık gösteren kanalları görsel olarak belirlemeye çalışmışlardır [55]. Bu bilgiler göz önüne alınarak, eğitim verilerine ait her bir kanalın tüm denemelerinin zaman domeni ortalamaları incelenerek kanalların ne gibi farklılıklar gösterdiği incelenmiştir. Şekil 2.12. incelendiğinde 12. kanal ve 38. kanala ait DDH ve DPH arasındaki genlik farkının 1. kanal ve 2. kanal gibi diğer kanallardan daha fazla olduğu görülmektedir. Bu şekilde tüm kanallar incelenerek iki farklı sınıf işaret arasındaki bu genlik farkları gözlemlenmiştir.



Şekil 2.12. Eğitim verilerine ait bazı kanalların DDH ve DPH sınıflarına ait tüm denemelerinin zaman domeni ortalamaları (a) 1. Kanal, (b) 2. Kanal, (c) 12. Kanal, (d) 38. Kanal

ECoG ve EEG gibi biyoelektrik işaretlerin analizinde frekans bilgileri çok önemlidir. Frekans domeninde verilerimizi incelemek için zaman domeninden frekans domenine geçmemiz gerekiyor. Fourier dönüşümü yöntemi yardımıyla işaretlerin frekans domeni incelemelerini yapabiliriz. DDH ve DPH işaretlerinin tüm denemelerine ait Fourier dönüşümleri hesaplanması için eşitlik (70) ile verilen FFT algoritması kullanılır.

$$X(k + 1) = \sum_{n=0}^{N-1} x(n + 1)W_N^{kn} \quad (70)$$

$$W_N = e^{-j(2\pi/N)} \quad (71)$$


FFT işlemi yapılmadan önce işaretlerin DC bileşenleri yok edildi. FFT işleminden sonra işaretlerin genlik spektrumları Şekil 2.13.'de gösterilmektedir. Tüm kanalların genlik

spektrumları incelendiğinde 12. kanalda DPH ait denemelerin genlik spektrumu daha yüksek olmasına karşın 38. kanalda DDH denemeleri genlik spektrumu daha yüksek çıkmaktadır. 12. kanal ve 38. kanalda DDH ve DPH ait işaretlerin birbirine zıt olarak değiştiği fark edilmiştir. Bundan yola çıkarak 12. kanalın DPH' ni ve 38. kanalın DDH 'ni temsil ettiği varsayılmıştır. Ayrıca tüm kanallar incelendiğinde diğer bazı kanallarda benzer özellikler gösterdiği görülmüştür. Belirlenen bu iyi kanalların uzamsal olarak birbirine yakın (bitişik) olduklarına ve büyük olasılıkla motor korteks üzerinde bulduklarını düşünüyoruz. Böylece bu görsel işlem ile öznitelik çıkarmada kullanılacak kanalları iyi ve kötü kanallar olarak belirleyerek kanal seçme gerçekleştirilmiş oldu.

2.4.2. Frekans Bandı Seçimi

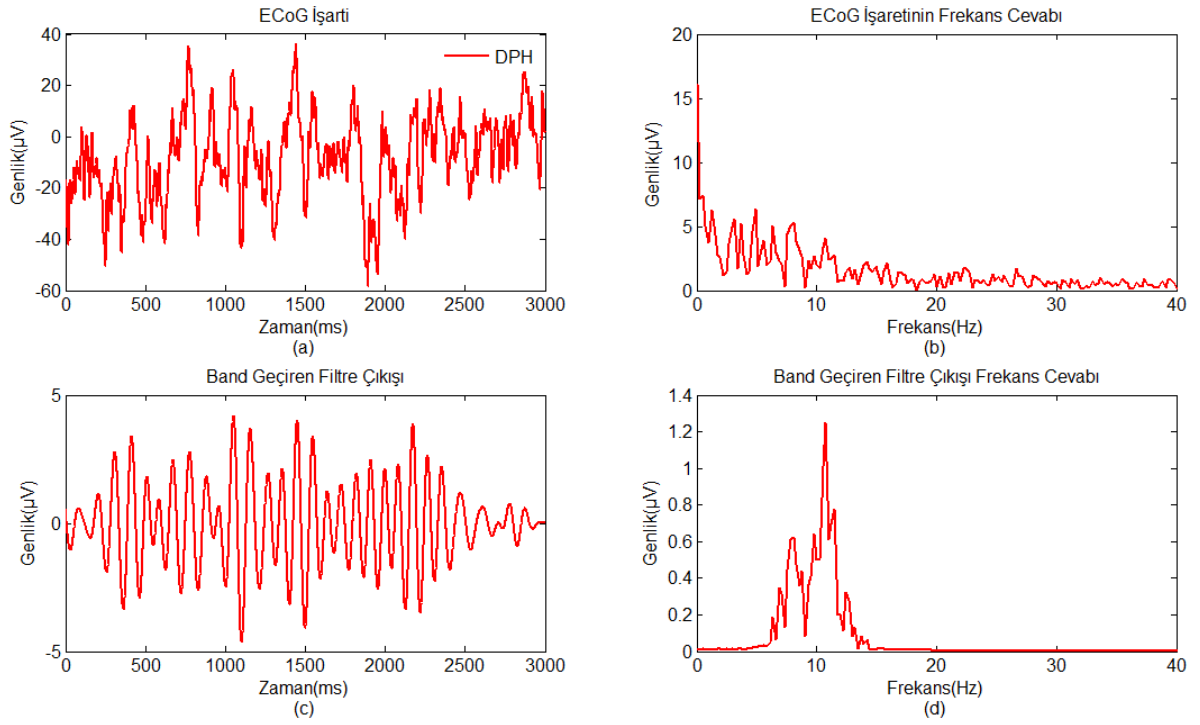
Yavaş kortikal potansiyeller, duyu-motor ritimleri ilişkili düşümsel hareket (motor imagery) olayları ve görsel tetiklenen potansiyeller gibi beyin işaretlerindeki değişik olaylar EEG tabanlı BBA uygulamalarında kullanılmaktadırlar. Birçok BBA grubu duyu-motor ritimlerini ECoG işaretlerini sınıflandırmada kullanmaktadır. Duyu motor ritimleri (DMR) genellikle 10 Hz frekanslı kemer şeklinde bir μ ritmi içerir. Duyu motor ritimleri hareket icra edilirken veya harekete hazırlanırken düşer (desenkronizasyon), dinlenme boyunca veya hareket sonrası artar (senkronizasyon) [49]. Yani DMR' de görülen artış veya azalış için hareketin icra edilmesi gerekli değildir. Önceki çalışmalar bir motor hareketi düşümsel olarak yapıldığı zaman duyu-motor (sensori-motor) korteks üzerinde ERD ve ERS gibi elektro-fizyolojik olayların mu (8-13 Hz) ve beta (18-26 Hz) ritimlerinde bulduklarını göstermiştir [10].

Eğitim verilerine ait Şekil 2.13.' deki grafikler incelendiğinde seçilen 12. kanal ve 38. kanalın bazı frekans bandlarının (mü ve beta) farklılık gösterdiği belli olmaktadır. Grafiklerden görüldüğü üzere 12. kanal ve 38. kanala ait denemelerin genlik spektrumları 7-13 Hz ve 16-24 Hz arası frekans bölgesinde değişim göstermektedir. Bu farklılık gösteren bölgenin düşümsel hareket ile güçlü bir şekilde ilişkili olduğu bilinmektedir. Bundan dolayı bu bölgenin işaretlerin sınıflandırılmasına yönelik bir öznitelik oluşturduğu ve öznitelik çıkarma işleminin bu frekans bandı için uygun olduğu varsayılmıştır.

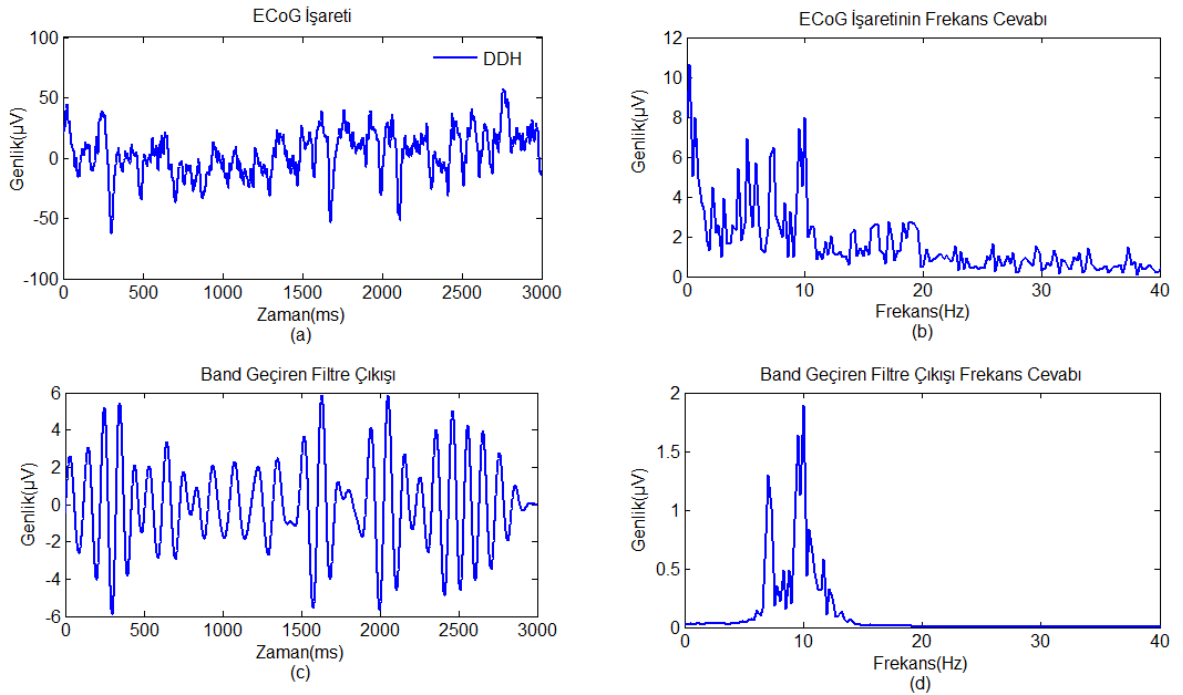


Şekil 2.13. Eğitim kümesine ait bazı kanalların genlik spektrumları (a) 1. kanal, (b) 2. kanal, (c) 12. kanal, (d) 38. kanal

Herhangi bir frekans bandındaki bilgiler band geçiren filtre ile çıkarılabilir. Bu işlem için 5. dereceden band geçiren bir Butterworth filtre veya FFT tabanlı bir filtre tasarlandı. Butterworth filtre oldukça düz bir geçiş bandı karakteristiğine sahiptir. Band geçiren filtrenin kesim frekansları Şekil 2.13' den 7-13 Hz olarak belirlendi. Filtrelenmiş işaret sadece ECoG işaretlerini içermektedir (delta, teta, alfa ve beta), yani bu istenmeyen frekansların (ani gerilim dalgalanmaları ve şekilde görüldüğü üzere 50 Hz şehir şebeke frekansı) bastırılması demektir. Şekil 2.14' de ve Şekil 2.15' de sırasıyla 38. kanala ait DPH ve DDH işaretlerinin 5. dereceden band geçiren bir Butterworth filtre çıkışına ait grafikleri gösterilmektedir.



Şekil 2.14. Kanal 38 için DPH ait bir denemenin Butterworth filtre ile 7-13 Hz frekans bölgesinin filtrelenmesi



Şekil 2.15. Kanal 38 için DDH ait bir denemenin Butterworth filtre ile 7-13 Hz frekans bölgesinin filtrelenmesi

2.4.3. Dalgacık Dönüşümü İşlemi ile Öznitelik Çıkarma

Öznitelik çıkarma aşamasında aynı veri kümesine farklı matematiksel yöntemler uygulanarak farklı öznitelikler çıkarmak mümkündür. Öznitelik çıkarma işlemi farklı düşünce durumlarında kaydedilen ECoG işaretleri ile ilgili özniteliklerin çıkarılıp öznitelik vektörünün oluşturulmasına kapsamaktadır.


Klasik Fourier dönüşümü durağan işaretlerde başarıyla kullanılmasına karşın EEG ve ECoG işaretleri gibi durağan olmayan bir karakteristik gösteren işaretler için uygun değildir.

ECoG işaretindeki olaya-bağlı desenkronizasyon (ERD) ve olaya-bağlı senkronizasyon (ERS) örüntüleri kullanılarak düşünsel motor olayına ilişkin öznitelikler çıkarılabilir. 12. kanalda DPH ait denemelerin genlik spektrumu daha yüksek olmasına karşın 38. kanalda DDH' ne ait denemelerin genlik spektrumu daha yüksek çıkmaktadır. Bu tez çalışmasında iki düşünsel hareket olayı arasındaki öznitelikleri çıkarmak için sürekli dalgacık dönüşümü kullanılacaktır. Dalgacık dönüşümü dalgacıklar kullanılarak bir fonksiyonu temsil edilmesidir. Dalgacık dönüşümü denklem (72)' de verilmektedir.

$$C(\text{ölçek}, \text{konum}) = \int_{-\infty}^{\infty} f(t) \cdot \psi^*(\text{ölçek}, \text{konum}, t) dt \quad (72)$$

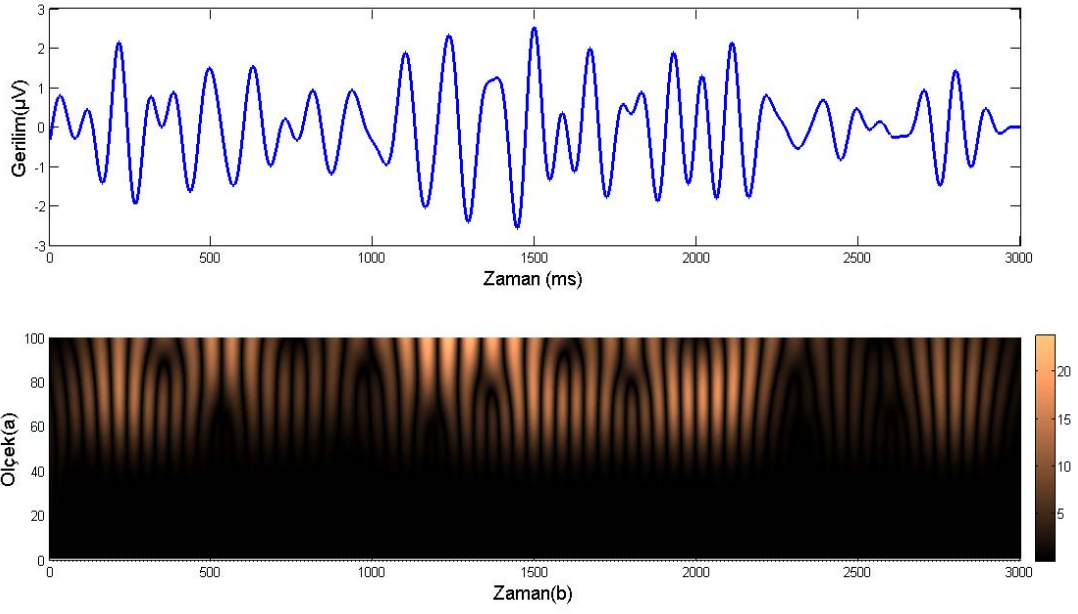
Dalgacıklar matematiksel araçlar olduğu için değişik veri çeşitlerinde öznitelik çıkarmak için kullanılabilirler. Dalgacık katsayıları ana dalgacık fonksiyonunun seçimine bağlıdır. Ana dalgacık hem zaman hem frekans uzayında yeri belirlenmiş olup sıfır ortalamaya sahip olacak şekilde oluşturulur. Ana dalgacık olarak birçok dalgacık olmasına karşın bu çalışmada en iyi sonucu veren Morlet dalgacığı seçilmiştir. Morlet dalgacığına ait denklem (73)'de verilmektedir.

$$\psi_{\sigma}(t) = c_{\sigma} \pi^{\frac{-1}{4}} e^{\frac{-t^2}{2}} (e^{i\sigma t} - K_{\sigma}) \quad (73)$$




Şekil 2.16. Bir denemeye ait işaret ve bunun Morlet dalgacığı ile dalgacık dönüşümü işleminin yapılması


Çalışmanın bu bölümünde ECoG verilerine sürekli dalgacık dönüşümü uygulanarak DPH ve DDH durumlarında ortaya çıkan farklılıklar incelenmiştir. Morlet dalgacığı Şekil 2.16.' da görüldüğü gibi filtrelenmiş DDH veya DPH denemeleri ile eşitlik (72) ile verilen dalgacık dönüşümü işlemi yapılarak dalgacık katsayıları elde edilmiştir. Tüm DDH ve DPH denemelerine ait dalgacık katsayıları hesaplanarak sonuçlar Şekil 2.17. ve Şekil 2.18.' de grafikler halinde gösterilmektedir. Grafikler incelendiğinde 12. kanal ve 38. kanala ait verilere uygulanan dalgacık dönüşümü katsayılarına ait farklılıklar gösterdiği gözlemlenmiştir. Grafiklerden ECoG işaretinin frekansının sıklaştığı zamanlar daha koyu, frekansın az olduğu zamanlar daha açık olduğu görülmektedir. Eğitim verilerinden alınan birer örnekle bu durum Şekil 2.17. ve Şekil 2.18.' de gösterilmiştir.




Şekil 2.17. DDH ait filtrelenmiş ECoG işareti ve bu işarete ait dalgacık katsayı grafikleri



Şekil 2.18. DPH ait filtrelenmiş ECoG işareti ve bu işarete ait dalgacık katsayı grafikleri



Şekil 2.19. Kanal 12 için, (a) DDH denemelerinin ortalaması, (b) DPH denemelerinin ortalamaları



Şekil 2.20. Kanal 38 için, (a) DDH denemelerinin ortalaması, (b) DPH denemelerinin ortalamaları

DPH ve DDH ait dalgacık katsayılarının grafiklerinden görüleceği üzere farklıklar vardır. Dalgacık katsayıları, zaman ve frekans bölgesinde düşünel hareketine ait ECoG işaretinin enerji dağılımını göstermektedir. Çıkarılan öznelik vektörlerinin boyutunun indirgenmesi için ECoG işaretinin zaman-frekans dağılımını temsil etmekte kullanılan istatistiksel özellikler şunlardır.

Dalgacık katsayılarının maksimumu

Dalgacık katsayılarının minimumu

Dalgacık katsayılarının ortalaması

Dalgacık katsayılarının standart sapması

Eşitlik (74)' de her bir deneme için dalgacık dönüşümü katsayılarının ortalamasının nasıl hesaplandığı belirtilmiştir. 12. kanal ve 38. kanala ait DDH ve DPH ne ait denemelerin dalgacık katsayıları hesaplandıktan sonra ortalamaları eşitlik (74)' den hesaplanarak öznelik vektörleri oluşturulmuştur.

$$\bar{x} = \frac{1}{N} \sum_{i=1}^N x_i \quad (74)$$

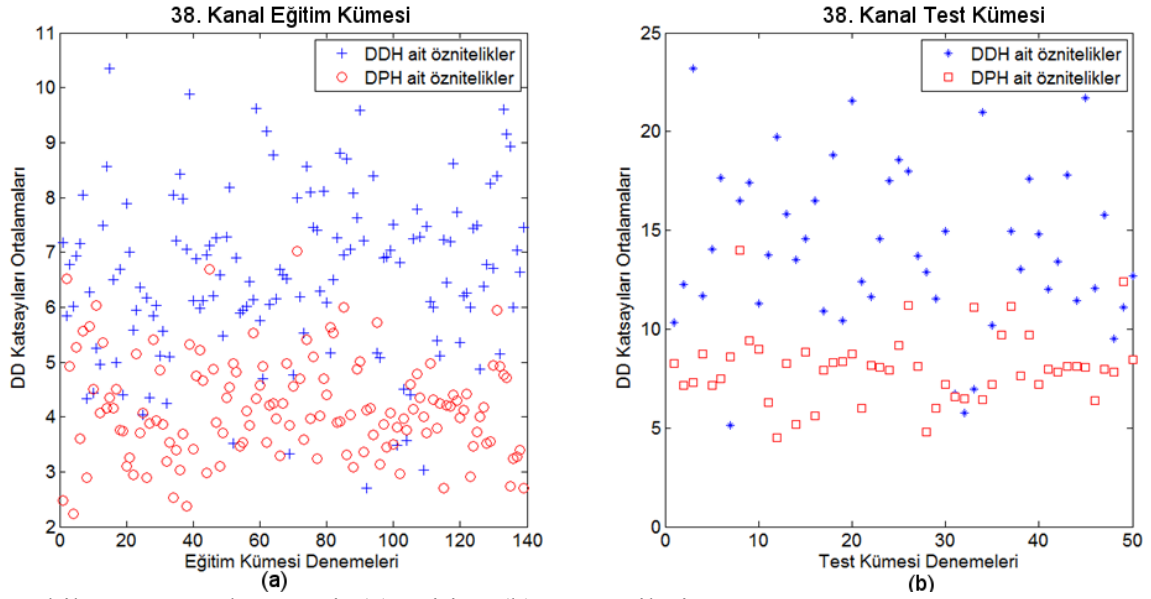
x_i : dalgacık dönüşüm katsayıları

N: ölçek×konum

$$\bar{x}_{DDH} = \frac{1}{N} \sum_{i=1}^N \underset{DDH}{x_i} \quad (75)$$

$$\bar{x}_{DPH} = \frac{1}{N} \sum_{i=1}^N \underset{DPH}{x_i} \quad (76)$$

Eşitlik (75) ile DDH denemelerine ait dalgacık katsayı ortalamaları \bar{x}_{DDH} ve eşitlik (76) ile DPH denemelerine ait dalgacık katsayı ortalamaları \bar{x}_{DPH} hesaplanarak öznelik vektörleri oluşturulmuştur.



Şekil 2.21. Kanal 38' e ait (a) eğitim, (b) test verileri

Şekil 2.21. (a) incelendiğinde eğitim verilerine ait mavi + işareti ile gösterilen DDH ile kırmızı o işareti ile gösterilen DPH arasında oldukça iyi bir ayrışma olduğu gözükmemektedir. Benzer şekilde test verilerinde de iki sınıf arasında iyi bir ayrışma olduğu şekilde gözükmemektedir. BCI Competition Data Set I verilerinin oluşturulmasını nedeni farklı oturumlarda sınıflandırma performansını test edilmesidir. Eğitim ve test verileri farklı oturumlarda oluşturulduklarından grafiklerden görüleceği üzere dalgacık dönüşümü katsayı ortalamaları arasında skala farklılığı görülmektedir. Eğitim kümesi denemeleri [0,11] arasında test veri kümeleri [0,25] arasında bir dağılıma sahiptir. Bu sorunu gidermek için normalizasyon yapılması gerekmektedir. Test verilerinin DDH ve DPH sınıflarına ait dalgacık katsayı ortalamalarının standart sapmaları Şekil 2.21.' den de görüleceği üzere daha büyüktür ve yaklaşık olarak iki katı kadardır. Sınıflandırmada genlik değişiminin etkisi öznelitlikler normalize edilerek aşılabilir. 38. kanal DDH' ne ait $A = \bar{x}_{DDH}$ ve DPH' ne ait $B = \bar{x}_{DPH}$ olarak belirtilirse.

Normalizasyon için

$$x_1 = \frac{A}{\sqrt{A^2+B^2}} \quad (77)$$

$$x_2 = \frac{B}{\sqrt{A^2+B^2}} \quad (78)$$

x_1 ; 38. kanal için DDH' ne ait normalize edilmiş öznelitlikleri vermektedir

x_2 ; 38. kanal için DPH' ne ait normalize edilmiş öznelitlikleri vermektedir

Aynı şekilde 12. kanal için, DDH' ne ait $C = \bar{x}_{DCH}$ ve DPH' ne ait $D = \bar{x}_{DPH}$ öznitelikler ve bu öznitelik vektörleri de eşitlik (79) ve eşitlik (80)' den normalize edilerek öznitelik vektörleri oluşturulur.


$$x_3 = \frac{C}{\sqrt{C^2+D^2}} \quad (79)$$

$$x_4 = \frac{D}{\sqrt{C^2+D^2}} \quad (80)$$

x_3 ; 12. kanal için DDH' ne ait normalize edilmiş öznitelikler

x_4 ; 12. kanal için DPH' ne ait normalize edilmiş öznitelikler

Farklı kanallardan gelen işaretleri birleştirerek sınıflandırma için kullanılabilir. Seçtiğimiz iyi kanallardan ikisini (12. kanal ve 38. kanal) kullanarak öznitelik vektörleri oluşturduk.



Şekil 2.22. (a) Eğitim verilerine ait kanal 12 ve kanal 38 kullanılarak oluşturulan öznitelik uzayı, (b) test verilerine ait öznitelik uzayı

Normalizasyon işleminden sonra Şekil 2.22.' de görüldüğü gibi eğitim ve test verileri arasındaki skala sorunu ortadan kalkmıştır.

2.4.4. Sınıflandırma

Dalgacık dönüşümü katsayıları ortalamaları kullanılarak çıkartılan öznelik vektörleri normalize edildikten sonra x_1, x_2, x_3 ve x_4 öznelik vektörleri ile bir öznelik uzayı oluşturulmuştur. Bu öznelik uzayında $F_d=[x_1, x_3]$ ve $F_p=[x_2, x_4]$ olarak DDH ve DPH' ne ait veri tabanları oluşturulmuştur. Şekil 2.22.' den anlaşılacağı üzere DDH ve DPH işaretleri farklı bölgelerde yoğunlaşmıştır. Bu aşamada işaretleri sınıflandırmak için kaydedilen öznelik vektörleri ile oluşturulan veri tabanları üç farklı sınıflandırıcı k-en yakın komşuluk (KNN), Destek Vektör Makinesi (DVM) ve Doğrusal Ayırma Analizi (DAA) sınıflandırıcılarına uygulanmıştır. KNN algoritması hızlı ve kolay bir algoritma olduğundan dolayı kullanılmıştır. DVM için doğrusal, polinomial ve radyal tabanlı kernel fonksiyonlarını test ederek uygun kernel fonksiyonlarını belirlenmiştir. Eğitim ve test verilerine ait iki sınıf verinin oldukça doğrusal olduğu Şekil 2.22.' den görüldüğünden doğrusal bir sınıflandırıcı olan DDA' da kullanılarak farklı sınıflandırma yöntemleri ile öznelikler test edilmiştir.

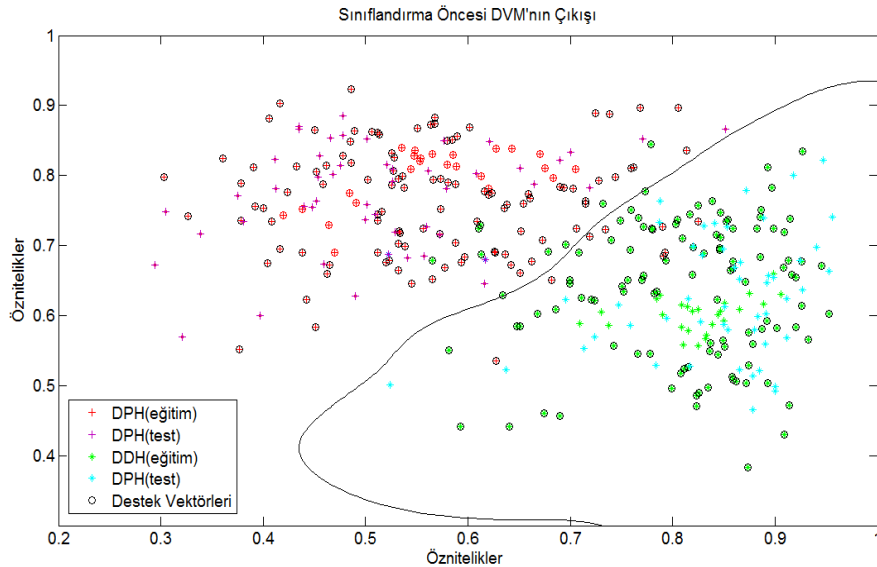
3. SONUÇLAR

Dalgacık dönüşümü katsayıları ile elde edilen öznitelik vektörlerinin k-en yakın komşuluk (KNN), Destek vektör makiması (DVM) ve Doğrusal ayırma Analizi (DAA) ile yapılan sınıflandırma sonuçları Tablo 3’ de gösterilmektedir. Tabloda görüldüğü üzere en iyi sınıflandırma doğruluğu KNN ve DVM yöntemiyle elde edilmiştir.

Tablo 3. ECoG verilerine yönelik dalgacık katsayılarının ortalamaları kullanılarak yapılan sınıflandırma sonuçları

Sınıflandırma	% Doğruluk
KNN	96
DVM	96
DAA	95

Şekil 2.23.’ de DVM sınıflandırıcısının son kararı vermeden önce eğitim ve test kümesinin dağılımları ve destek vektörleri gösterilmektedir.



Şekil 2.23.DVM sınıflandırıcısı ile eğitim ve test verilerinin sınıflandırma sonuçları.Kırmızı renkli + işareti DPH ait eğitim verilerini ve mor + işareti DPH ait test verilerini göstermektedir. Buna karşın yeşil * işareti DDH ait eğitim verilerini ve mavi * işareti DDH ait test verilerini göstermektedir.


Bu çalışmada BCI Competition Data Set 1 ile elde edilen sınıflandırma doğruluğu literatürde aynı verileri kullanılarak elde edilen sonuçlardan daha iyidir [5]. Sonuçlar açısından önemli olan şey eğitim ve test verileri farklı oturumlarda alınmasına rağmen sınıflandırma doğruluğunun oldukça yüksek oluşudur.

Bir diğer sonuç olarak, deneme süresi (karar hızı) değiştirilerek her bir durum için ITR hesaplandı. Amaç maksimum ITR sağlayacak deneme uzunluğunu bulmaktır.

Eğer sınıflandırma doğruluğu %100 olduğu varsayılırsa bu tezde kullanılan veriler için

$$ITR \left(\frac{bit}{dk} \right) = \left(\log_2 2 + 0.9999 \log_2 0.9999 + (1 - 0.9999) \log_2 \left[\frac{1 - 0.9999}{2 - 1} \right] \right) \frac{60}{3}$$

$$= 20 \left(\frac{bit}{dk} \right)$$



Şekil 2.24. (a) deneme uzunluğu ile sınıflandırma doğruluğu arasındaki ilişki, (b) deneme uzunluğu ile bit transfer hızı (bit/dk) arasındaki ilişki

Tablo 4. Farklı deneme uzunlukları için sınıflandırma doğrulukları ve transfer hızı

	Sınıflandırma Doğruluğu (%)	Transfer Hızı (bit/dk)
0-0.5 sn	72	13.35
0-1.0 sn	82	19.20
0-1.5 sn	90	21.24
0-2.0 sn	92	17.93
0-2.5 sn	94	16.14
0-3.0 sn	96	15

4. TARTIŞMA

Farklı oturumlarda alınan verilerin sınıflandırılması BBA arařtırmaları ve bir BBA sistemi uygulaması için çok önemli bir konudur. Eđer bu farklı oturumlarda sınıflandırma yapabilme yeteneđi yoksa BBA sistemleri sürekli güncellemeleri gerekebilir. Bu pratik kullanım için sorun olacaktır ve BBA sistemlerini zorlařtıracaktır.

En iyi sınıflandırma sonuçlarını elde etmek için zaman, frekans ve uzamsal karakteristikleri eşzamanlı olarak ele alınmalıdır. Zaman aralıđının, frekans bandının ve elektrotların seçimi ile daha yüksek sınıflandırma dođruluđuna katkı sađlayacaktır. Frekans domeninde frekans bandının sınıflandırma dođruluđu üzerine etkisi büyüktür. Bu tez çalışmasında farklı frekans bandları da denenmiřtir ve en iyi sonuç 7-13 Hz frekans bandı için bulunmuřtur.

Uzamsal karakteristikler dikkatli bir şekilde seçilmelidir. Bu tez çalışmasında sınıflandırmaya ait öznitelik vektörlerinin çıkarılması elektrotların seçimine dođrudan bađlıdır. Eđer optimal elektrotlar veya uzamsal paternler dođru bir şekilde seçilmez ise sınıflandırma dođruluđu daha kötü olacaktır. Bu tez çalışmasında öznitelik çıkarmak için kullanılan kanalların dıřında 29,30,31,39 ve 46. kanallarında öznitelik çıkarma açısından uygun oldukları bulunmuřtur. Bu kanallarda öznitelik çıkarma açısından denenmiřtir.

Bu çalışmada elde edilen yüksek sınıflandırma dođruluđu ECoG tabanlı BBA için büyük bir uygulama potansiyeli olduđunu ve ayrıca farklı oturumlar için BBA uygulamalarının çok zor olmadıđını göstermiřtir.

5. ÖNERİLER

Bu çalışmada BBA uygulamaları için farklı düşünsel durumlarda kaydedilmiş ECoG işaretlerinin sınıflandırılması üzerine çalışılmıştır. Ele alınan işaretin hangi sınıfa ait olduğuna karar verebilmek için öncelikle eğitim verileri üzerinde incelemeler yapılarak farklı sınıflara ait ECoG işaretlerinden öznitelikler çıkartılmalıdır. Öznitelik çıkarma işlemi BBA uygulamalarının en temel ve en zor konusunu oluşturur. 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 ECoG 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 mühimdir.

Çoklu elektrot kullanılarak kaydedilen ECoG verileri incelenirken, hangi elektrot öznitelik çıkarma için daha uygundur konusu da önemlidir. Beynin farklı bölgeleri farklı görevler için daha duyarlıdır. Çoklu elektrot ECoG 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. Bu çalışmada ki verilerde diğer seçilen kanallar (29. kanal veya 39. kanal) kullanılarak yani kanal sayısı artırılarak sınıflandırma doğruluğu ve bilgi transfer hızı artırılabilir.

KAYNAKLAR

1. Ersoy, M. E., EEG İşaret Analiz Metotlarının Karşılaştırmalı Bir Çalışması, Yüksek Lisans Tezi, Uludağ Üniversitesi Fen Bilimleri Enstitüsü, 2003.
2. Korürek, M., İTÜ, www2.itu.edu.tr/~dokur/EMG_Giris/EMG_07.pdf, 12 Ocak 2009
3. Gohlenhofen, K., Physiologie: Lehrbuch, Kompendium, Fragen und Antworten, Verlag Urban & Schwarzenberg, 1997, ISBN 3-541-16351-8.
4. <http://www.aof.anadolu.edu.tr/kitap/EHSM//1211/unite03.pdf>, 12 Nisan 2009
5. Tangermann, M. W., Feature Selection for Brain-Computer Interfaces, Tübingen, 2007.
6. Jasper, H. ve Penfield, W., Electrocorticograms in man: Effects of voluntary movement upon the electrical activity of the precentral gyrus, Arch. Psychiat. Nervenkr. 183 (1949) 163–174.
7. Toro, C., Deuschl, G., Thather, R., Sato, S., Kufta, C. ve Hallett, M., Event related desynchronization and movement-related cortical potentials on the ECoG and EEG, Electroencephalogr. Clin. Neurophysiol. 93 (1994) 380–389.
8. Carmena, J. M., Lebedev, M. A., Crist, R. E., O'Doherty, J. E., Santucci, D. M., Dimitrov, D. F., Patil, P. G., Henriquez, C. S. ve Nicolelis, M. A., Learning to control a brain-machine interface for reaching and grasping by primates, PLoS Biol. E42 (2003).
9. Hochberg, L. R., Serruya, M. D., Friehs G. M., Mukand, J. A., Saleh, M., Caplan, A. H., Branner, A., Chen, D., Penn, R. D. ve Donoghue, J. P., Neuronal ensemble control of prosthetic devices by a human with tetraplegia, Nature 442 (2006) 7099, 164–171.
10. Raethjen, J., Lindemann, M., Dümpelmann, M., Wenzelburger, R., Stolze, H., Pfister, G., Elger, C. E., Timmer, J. ve Deuschl G., Corticomuscular coherence in the 6-15Hz band: is the cortex involved in the generation of physiologic tremor?, Experimental Brain Research 142 (2002) 1, 32–40.
11. Kuruvilla, A., Flink, R., Intraoperative electrocorticography in epilepsy surgery: useful or not?", Seizure 12 (2003) 577–584.

12. Donoghue, J. P. ve Sanes, J. N., Motor areas of the cerebral cortex. Journal of Clinical Neurophysiology, 11(1994) 382–396.
13. Taylor, D. M., Tillery, S. I. ve Schwartz, A. B., Direct cortical control of 3D neuroprosthetic devices. Science, 296:1829–1832, 2002.
14. Logothetis N., The underpinning of the Bold functional magnetic resonance imaging signal, Journal of Neuroscience 23 (2003) 3963–3971.
15. Shain W., Controlling cellular reactive responses around neural prosthetic devices using peripheral and local intervention strategies, IEEE Trans. Neural Syst. Rehabil. Eng. 11 (2003) 186–8.
16. Lal, T. N., Hinterberger, T., Widman, G., Schröder, M., Hill, J., Rosenstiel, W., Elger, C. E., Schölkopf, B. ve Birbaumer, N., Methods Towards Invasive Human Brain Computer Interfaces, Advances in Neural Information Processing Systems 17 (NIPS), MIT Press, Eds. Cambridge, MA, USA, 17 (2005) 737-744.
17. J. J., Vidal, Toward Direct Brain-Computer Communication, Annual Review of Biophysics and Bioengineering, 2 (1973) 157-180.
18. J. J., Vidal, Real-time Detection of Brain Events in EEG, Special Issue on Biological Signal Processing and Analysis, 65, 5 (1977) 633-664.
19. Wolpaw, R. J., Birbaumer, N., McFarland, D. J., Pfurtscheller, G. ve Vaughan, T. M., Brain-Computer Interfaces for Communication and Control, Clinical Neurophysiology, 113 (2002) 767-791.
20. Wolpaw, R. J., Birbaumer, N., McFarland, D. J., Pfurtscheller, G. ve Vaughan, T.M., Brain-Computer Interfaces for Communication and Control, Clinical Neurophysiology, 113 (2002) 767-791.
21. BCI-Info Portal for Brain-Computer Interfaces, <http://www.bciinfo.tugraz.at/Members/graimann/definitions/scp>, 24 Kasım 2007
22. BCI-Info Portal for Brain-Computer Interfaces, <http://www.bciinfo.tugraz.at/Members/graimann/definitions/P300>, 24 Kasım 2007.
23. McFarland, D. J., Miner, L. A., Vaughan, T. M. ve Wolpaw, J. R., Mu and Beta Rhythm Topographies During Motor Imagery and Actual Movement, Brain Topogr., 12, 3 (2000) 177-186.
24. Felton, E. A., Human Factors Studies of BCI, University of Wisconsin, Madison, 2007.
25. Hill, N. J., Lal, T. N., Schröder, M., Hinterberger, T., Wilhelm, B., Nijboer, F., Mochty, U., Widman, G., Elger, C., Schölkopf, B., Kübler, A., Birbaumer, N., Classifying EEG and ECoG, 2006.

26. Hill, N. J., Lal, T. N., Schröder, M., Hinterberger, T., Widman, G., C. E. Elger, Schölkopf, B. ve Birbaumer, N., Classifying Event-Related Desynchronization in EEG, ECoG and MEG Signals, Springer Berlin, (2006) 41-74.
27. Shenoy, P., Miller, K. J., Ojemann, J. ve Rao, R., Generalizable features for electrocorticographic bcis. Technical Report 2006-11-03, UWCSE, 2006.
28. Miller, K. J.. Real-time mapping of hand motor areas using highfrequency spectral changes. Submitted, 2007.
29. Shenoy, P., Miller, K. J., Ojemann, J. G., Rao, R. P. N., Generalized Features for Electrocorticographic BCIs, Biomedical Engineering, 55, 1 (2008) 273 – 280.
30. Leuthardt, E.C.; Miller, K.J.; Schalk, G.; Rao, R.P.N.; Ojemann, J.G., Electrocoigraphy-based brain computer Interface-the seattle experience, Neural Systems and Rehabilitation Engineering, 14, 2 (2006) 194 – 198.
31. Hill, N. J., Lal, T. N., Schroder, M., Hinterberger, T., Wilhelm, B., Nijboer, F., Mochty, U., Widman, G., Elger, C., Scholkopf, B., Kubler, A. ve Birbaumer, N., Classifying EEG and ECoG Signals without Subject Training for Fast BCI Implementation: Comparison of Non-Paralysed and Completely Paralysed Subjects, 2005.
32. Graimann, B., Huggins, J. E., Levine, S. P. ve Pfurtscheller, G., Detection of ERP and ERD/ERS patterns in single ECoG channels, Neural Engineering, Conference Proceedings. First International IEEE EMBS Conference, 20-22 Mart 2003, 614 – 617.
33. Fan, J.-F., Shao, C.-X., Li, S.-X. ve Chen, X.-P., ECoG Signal Classification Based on Nonlinear Dynamics Using GA-MLPNN, 2007,1113-1119.
34. Demirer, R. M., Ozerdem, M. S. ve Bayrak, C., Classification of imaginary movements in ECoG with a hybrid approach based on multi-dimensional Hilbert-SVM solution, 178, 1 (2009) 214-218.
35. Rasmyl, M. Z., Yousry2, O. M., Adel1, T. M., Gamal Al Din1, W. O. ve Kadahl, Y. M., First Attempts Towards a Brain Computer Interface (BCI) in Egypt, Department of Biomedical Engineering, Cairo University, Giza, Egypt, Institute of Biomedical Engineering, Lübeck University, Schleswig-Holsteins, Germany.
36. Birbaumer, N., Prof. Rosenstiel, Bernhard Schölkopf ve Prof. Elger, BCI Competition III.
37. BCI Competition III, http://ida.first.fraunhofer.de/projects/bci/competition_iii, 12 Kasım 2008.

38. BCI Competition III, http://ida.first.fraunhofer.de/projects/bci/competition_iii/results, 12 Kasım 2008.
39. Wei, Q. ve Tu, W., Channel Selection by Genetic Algorithms for Classifying Single - Trial ECoG during Motor Imagery, Department of Electronic Engineering, Nanchang University, Nanchang 330031, China, 30th Annual International IEEE EMBS Conference Vancouver, British Columbia, Canada, Ağustos, 2008.
40. Hammon, P. S. ve Desa, V. R., Preprocessing and Meta-Classification for Brain-Computer Interfaces, IEEE Transactions on Biomedical Engineering, 54, 3 (2007).
41. BCI Competition III, http://ida.first.fraunhofer.de/projects/bci/competition_iii/results/tuebingen/MichalSapinski_desc.txt, 12 Kasım 2008.
42. Duhamel, P. ve Hollman, H., Existence of a $2n$ FFT Algorithm with a number of multiplications lower than $1.2n^+$, *Electron. Lett.*, 20 (1984) 690-692.
43. Nussbaumer, H. J., Fast Fourier Transform and Convolution Algorithms, Springer, Edition 2, December, 1982.
44. Madisetti, V. K. ve Williams, D. B., The Digital Signal Processing Handbook, CRC Press LLC (with IEEE Press), 1998.
45. Long, W. ve Srihann, S., Land cover classification of SSC image:unsupervised and supervised classification using ERDAS Imagine, IEEE International, Geoscience and Remote Sensing Symposium, 2707 – 2712, 2004
46. Goswami, A., Ruoming Jin ve Agrawal, G., Fast and exact out-of-core k-means clustering, Fourth IEEE International Conference on Data Mining, 83-90, Brighton, UK, 2004.
47. Long, W. ve Srihann, S., Land cover classification of SSC image:unsupervised and supervised classification using ERDAS Imagine, IEEE International, Geoscience and Remote Sensing Symposium, 2707 – 2712, 2004.
48. Begüm DEMİR ,Akıllı Hiperspektral Sınıflandırma Yüksek Lisans Tezi, Kocaeli Üniversitesi, Fen Bilimleri Enstitüsü, 2007.
49. Pfurtscheller, G., EEG event-related desynchronization (ERD) and event-related synchronization (ERS) *Electroencephalography: Basic Principles, Clinical Applications and Related Fields* 4th edn, ed E Niedermeyer and F H Lopes da Silva (Baltimore, MD: Williams and Wilkins) 958–67, 1999.
50. Garcia G. N., Ebrahimi, T. ve Vesin, J.M., Support vector EEG classification in the Fourier and time-frequency correlation domains Conference Proc. 1st Int. IEEE EMBS Conf. on Neural Engineering, 2003.

51. Li, Y., Liu, Q. ve Ruan, X., Cancer molecular classification based on support vector machines, Fifth World Congress on Intelligent Control and Automation,(WCICA), 5521 – 5524, 2004.
52. Informative K-Nearest Neighbor Pattern Classification, Yang Song¹, Jian Huang², U.S.A.
53. Mcfarland, D. J., Sarnacki, W. A. ve Wolpaw, J. R., Brain-computer interface (bci) operation: optimizing information transfer rates. Biological Psychology, 63, 3(2003) 237-251.
54. Pfurscheller, G., Lopes da Silva, F. H., Event-related EEG/MEG synchronization and desynchronization: basic principles: Clinical Neurophysiology 110 (1999) 1842-1857.
55. Mensh, B. D., Justin, W. ve Seung, S., Combining Gamma-Band Power With Slow Cortical Potential To Improve Classification of EEG,2004.
56. Torrence, C., Compo, P. C., A Practical Guide To Wavelet Analysis, Bulletin of American Meteorological Society, 79,1 (1998) 61-78.
57. Polikar, R., The Engineer's Ultimate Guide To Wavelet Analysis, The Wavelet Tutorial, <http://Engineering.Rowan.Edu/~Polikar/Wavelets/Wtpart3.Html>, 12 Kasım 2008.
58. Yıldırım, S., Destek Arıza Teşhisinde Destek Vektör Makinelerinin Kullanımı,Yüksek Lisans Tezi, Fırat Üniversitesi, Fen Bilimleri Enstitüsü, 2006.
59. Gunn, Sr., Support Vector Machines for Classification and Regression, Technical Report, University of Southampton, 1998.
60. Osuna, E. E., Freund, R., Girosi, F., Support Vector Machines: Training and Applications,<http://cbcl.mit.edu/cbcl/publications/aipublications/15001999/AIM1602.ps>, 10 Mayıs 2008.
61. Misiti, M., Misiti, Y., Oppenheim, G., Poggi, J, Wavelet Toolbox User's Guide, The MathWorks, Inc., 1997.
62. Tufekci, Z., Gowdy, J. N., Feature extraction using discrete wavelet transform for speech recognition. In Proceedings of the IEEE Southeastcon , 116-123, 2000.
63. Boser, B. , Guyon, I. ve Vapnik, V., A training algorithm for optimal margin classifiers. Proceedings of the Fifth Annual Workshop on Computational Learning, 1992.

ÖZGEÇMİŞ

01.07.1983 tarihinde Yozgat ili Sorgun ilçesinde doğdu. Liseyi Yozgat Şehitler Fen Lisesinde tamamladı. 2001 yılında Karadeniz Teknik Üniversitesi, Mühendislik Mimarlık Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü'nü kazandı. 2006 yılında aynı bölümden mezun oldu. Aynı yıl güz döneminde Elektrik Elektronik Mühendisliği Anabilim Dalı'nda yüksek lisans eğitimine başladı. 2007 yılında özel bir firmada mühendis olarak çalışma hayatına başladı. Yabancı dil olarak İngilizce bilmektedir.